



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ
ΕΡΓΑΣΤΗΡΙΟ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ ΚΑΙ ΔΙΟΙΚΗΣΗΣ

Μοντέλα Τεχνητής Νοημοσύνης και Αλγόριθμοι
Βελτιστοποίησης για Κατανεμημένη Παραγωγή, Ευελιξία σε
Μικροδίκτυα και Εξοικονόμηση Ενέργειας σε Κτίρια

ΔΙΔΑΚΤΟΡΙΚΗ ΔΙΑΤΡΙΒΗ

ΤΟΥ

ΕΛΙΣΣΑΙΟΥ Β. ΣΑΡΜΑ

Επιβλέπων: Ιωάννης Ψαρράς
Καθηγητής Ε.Μ.Π.

Αθήνα, Νοέμβριος 2023



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ
ΕΡΓΑΣΤΗΡΙΟ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ ΚΑΙ ΔΙΟΙΚΗΣΗΣ

Μοντέλα Τεχνητής Νοημοσύνης και Αλγόριθμοι
Βελτιστοποίησης για Κατανεμημένη Παραγωγή, Ευελιξία σε
Μικροδίκτυα και Εξοικονόμηση Ενέργειας σε Κτίρια

ΔΙΔΑΚΤΟΡΙΚΗ ΔΙΑΤΡΙΒΗ

ΤΟΥ

ΕΛΙΣΣΑΙΟΥ Β. ΣΑΡΜΑ

Συμβουλευτική Επιτροπή: Ι. Ψαρράς, Καθηγητής Ε.Μ.Π (επιβλέπων)
Χ. Δούκας, Καθηγητής Ε.Μ.Π.
Δ. Ασκούνης, Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την επταμελή εξεταστική επιτροπή την 24η Νοεμβρίου 2023.

..... Ψαρράς Ι. Καθηγητής Ε.Μ.Π. Δούκας Χ. Καθηγητής Ε.Μ.Π. Ασκούνης Δ. Καθηγητής Ε.Μ.Π.
..... Μαρινάκης Ευ. Επ. Καθηγητής Ε.Μ.Π. Μέντζας Γ. Καθηγητής Ε.Μ.Π. Φλάμος Α. Καθηγητής ΠΑ.ΠΕΙ.
 Τσιχριντζής Γ. Καθηγητής ΠΑ.ΠΕΙ.	

Αθήνα, Νοέμβριος 2023

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

.....
Ελισσαίος Β. Σαρμάς

Διδάκτωρ Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

Copyright © Ελισσαίος Σαρμάς, 2023.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ' ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα.

Περίληψη

Ο ενεργειακός τομέας βιώνει σήμερα σημαντικές και πρωτοφανείς αλλαγές λόγω διαφόρων παραγόντων, μεταξύ των οποίων η έντονη ανησυχία για τη βιωσιμότητα του πλανήτη. Η Συμφωνία του Παρισιού του 2015, η οποία απαιτεί τον σχεδιασμό και την εφαρμογή βιώσιμων, ισχυρών και κοινωνικά αποδεκτών πολιτικών για την καταπολέμηση της κλιματικής αλλαγής σε παγκόσμιο επίπεδο, αποτελεί σαφή ένδειξη αυτής της ανησυχίας. Η αντιμετώπιση αυτής της πρόκλησης απαιτεί μια συντονισμένη προσπάθεια μετασχηματισμού και μετατόπισης του ενεργειακού τομέα από τα συστήματα παραγωγής και κατανάλωσης που βασίζονται στα ορυκτά καύσιμα σε εναλλακτικές πηγές ενέργειας, όπως η ηλιακή, η αιολική, το υδρογόνο και οι μπαταρίες ιόντων λιθίου, μεταξύ άλλων. Αυτή η διαδικασία ενεργειακής μετάβασης είναι πολύπλοκη και έχει πολλαπλές κοινωνικές, τεχνολογικές και περιβαλλοντικές επιπτώσεις πέραν του στόχου της απαλλαγής από τον άνθρακα.

Η παρούσα διδακτορική διατριβή έχει ως στόχο να συμβάλει σε αυτόν τον παγκόσμιο στόχο με την ανάπτυξη σύγχρονων μεθόδων μάθησης και μαθηματικών αλγορίθμων βελτιστοποίησης για τον τομέα της ενέργειας και των κτιρίων, με ιδιαίτερη έμφαση σε τρεις μεγάλες κατηγορίες (Ανανεώσιμες πηγές ενέργειας, Κατανεμημένοι ενεργειακοί πόροι σε επίπεδο μικροδικτύων και Ενεργειακή απόδοση κτιρίων). Μέσω της ανάπτυξης μοντέλων τεχνητής νοημοσύνης και μαθηματικής βελτιστοποίησης, η διατριβή παρουσιάζει λύσεις που αντιμετωπίζουν προβλήματα σε κάθε μία από αυτές τις κατηγορίες αναλύοντας διεξοδικά τις βασικές παραμέτρους και τις αλληλεπιδράσεις μεταξύ τους.

Η συμβολή της διατριβής στην ανθρωπότητα έγκειται στην ανάπτυξη μιας ολοκληρωμένης βιβλιοθήκης μοντέλων τεχνητής νοημοσύνης και αλγορίθμων βελτιστοποίησης που μπορούν να βελτιώσουν σημαντικά την αποδοτικότητα και την αποτελεσματικότητα της διαχείρισης της ενέργειας, των ανανεώσιμων πηγών ενέργειας και της ενεργειακής απόδοσης των κτιρίων. Η διατριβή προτείνει μια ολοκληρωμένη μεθοδολογία για την επιλογή μοντέλων, αλγορίθμων και χαρακτηριστικών εισόδου για ενεργειακά προβλήματα διαφορετικών κατηγοριών προβλημάτων και την ενσωμάτωσή τους σε ένα ενιαίο μεθοδολογικό πλαίσιο. Επιπλέον, η διατριβή παρέχει μια διεξοδική ανάλυση της αλληλεξάρτησης των τριών κύριων τομέων εφαρμογής, η οποία είναι απαραίτητη για την ανάπτυξη αποτελεσματικών μοντέλων και αλγορίθμων.

Παρέχοντας πρακτική επικύρωση των προτεινόμενων μοντέλων και αλγορίθμων με τη χρήση πραγματικών δεδομένων και περιπτώσεων δοκιμής, η διατριβή προσφέρει μια απτή συμβολή στην παγκόσμια προσπάθεια καταπολέμησης της κλιματικής αλλαγής μέσω της ενεργειακής μετάβασης. Οι προτεινόμενες λύσεις μπορούν να διευκολύνουν τη μετάβαση σε βιώσιμα ενεργειακά συστήματα, αντιμετωπίζοντας τις προκλήσεις που σχετίζονται με την αποανθρακοποίηση, την ψηφιοποίηση, την αποκέντρωση και τον εκδημοκρατισμό της ενέργειας. Τελικά, το παρόν ερευνητικό έργο στοχεύει να έχει ουσιαστικό και διαρκή αντίκτυπο στην ανθρωπότητα, προωθώντας την κατανόηση της ενέργειας και των κτιρίων και παρέχοντας πρακτικές λύσεις για την αντιμετώπιση των πιεστικών προκλήσεων που αντιμετωπίζουμε σήμερα.

Τέλος, εκτός από τη συμβολή στον τομέα της βελτιστοποίησης του ενεργειακού και κτιριακού τομέα, η διατριβή προτείνει νέες τεχνικές στην εφαρμογή της τεχνητής νοημοσύνης. Η μάθηση μεταφοράς, η αυξητική μάθηση και η μετα-μάθηση παρουσιάζονται ως νέες προσεγγίσεις για την επίλυση των προβλημάτων που σχετίζονται με τις ανανεώσιμες πηγές ενέργειας, τους καταναμημένους ενεργειακούς πόρους και την ενεργειακή απόδοση των κτιρίων. Οι τεχνικές αυτές επιτρέπουν την ανάπτυξη μοντέλων που μπορούν να προσαρμοστούν σε διαφορετικές εφαρμογές, επιτρέποντας τη βελτιστοποίηση του ενεργειακού τομέα με πιο αποδοτικό και αποτελεσματικό τρόπο, ανοίγοντας το δρόμο για μελλοντική έρευνα στον τομέα αυτό.

Λέξεις Κλειδιά: Τεχνητή νοημοσύνη; μηχανική μάθηση; βελτιστοποίηση; ενεργειακός τομέας; ανανεώσιμες πηγές ενέργειας; μικροδίκτυα; κτίρια; ψηφιοποίηση

Abstract

The energy sector is currently experiencing significant and unprecedented changes due to several factors, including the pressing concern about the sustainability of the planet. The Paris Agreement of 2015, which calls for the design and implementation of sustainable, strong, and socially acceptable policies to combat climate change globally, is a clear indication of this concern. Addressing this challenge requires a concerted effort to transform and shift the energy sector from fossil fuel-based production and consumption systems to alternative energy sources such as solar, wind, hydrogen, and lithium-ion batteries, among others. This process of energy transition is complex and has multiple social, technological, and environmental implications beyond the goal of decarbonization.

This PhD thesis aims to contribute to this global goal by developing modern learning methods and mathematical optimization algorithms for the energy and building sector, with a specific focus on three broad categories (Renewable Energy Sources, Distributed Energy Resources at the microgrid level, and Energy Efficiency of Buildings). Through the development of artificial intelligence and mathematical optimization models, the thesis presents solutions that address problems in each of these categories by thoroughly analyzing the key parameters and interactions between them.

The contribution of the thesis to humanity lies in the development of an integrated library of artificial intelligence models and optimization algorithms that can significantly improve the efficiency and effectiveness of energy management, renewable energy sources, and energy efficiency of buildings. The thesis proposes an integrated methodology for the selection of models, algorithms, and input features for energy problems of different problem classes and their integration into a single methodological framework. In addition, the thesis provides a thorough analysis of the interdependence of the three main application areas, which is essential for the development of effective models and algorithms.

By providing practical validation of the proposed models and algorithms using real-world data and test cases, the thesis offers a tangible contribution to the global effort to combat climate change through energy transition. The proposed solutions can facilitate the transition to sustainable energy systems by addressing challenges related to the Decarbonization, Digitization, Decentralization, and Democratization of energy. Ultimately, this research project aims to make a meaningful and lasting impact on humanity by advancing our understanding of energy and buildings and by providing practical solutions to address the pressing challenges we face today.

Finally, in addition to the contribution to the field of energy and building sector optimization, the thesis proposes novel techniques in the application of artificial intelligence. Transfer learning, incremental learning and meta-learning are introduced as novel approaches for solving the problems related to renewable energy sources, distributed energy resources and energy efficiency of buildings. These techniques enable the development of models that can be adapted to different applications,

allowing for the optimization of the energy sector in a more efficient and effective manner, paving the way for future research in this field.

Keywords: Artificial Intelligence; Machine Learning; Optimization; Energy Sector; Renewable Energy Sources; Microgrids; Buildings; Digitization

Πρόλογος

Η διδακτορική διατριβή έλαβε χώρα στη Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου, στο πλαίσιο των δραστηριοτήτων του Εργαστηρίου Συστημάτων Αποφάσεων και Διοίκησης, το διάστημα Νοέμβριος 2020 – Οκτώβριος 2023.

Η διατριβή πραγματοποιήθηκε υπό την επίβλεψη και την συνεχή καθοδήγηση του Καθηγητή κ. Ι. Ψαρρά, στον οποίο οφείλω ιδιαίτερες ευχαριστίες. Επίσης, θα ήθελα να εκφράσω την αμέριστη ευγνωμοσύνη μου στον Καθηγητή κ. Χάρη Δούκα και στον Επίκουρο Καθηγητή κ. Ευάγγελο Μαρινάκη για την εμπιστοσύνη που μου έδειξαν αυτά τα χρόνια σε ένα ευρύ πλαίσιο ερευνητικών δραστηριοτήτων. Η συνεργασία μου μαζί τους υπήρξε για εμένα ένα τεράστιο σχολείο, που ουσιαστικά διαμόρφωσε τον επαγγελματικό μου χαρακτήρα.

Θα ήθελα επιπλέον να ευχαριστήσω θερμά τον Καθηγητή κ. Δ. Ασκούνη ο οποίος με βοήθησε σημαντικά κατά τη διάρκεια αυτής της τριετίας, καθώς και τον Καθηγητή κ. Γ. Μέντζα, τον Καθηγητή κ. Γ. Τσιχριντζή και τον Καθηγητή κ. Α. Φλάμο για την τιμή που μου έκαναν να παραβρεθούν στην εξέταση υποστήριξης της διατριβής μου.

Ακόμη, θα ήθελα να ευχαριστήσω μέσα από την καρδιά μου όλους τους συνεργάτες μου στο Εργαστήριο Συστημάτων Αποφάσεων και Διοίκησης, οι οποίοι συνέβαλαν με τον τρόπο τους στην επίτευξη αυτής της ερευνητικής προσπάθειας.

Κλείνοντας, οφείλω ένα μεγάλο ευχαριστώ στην οικογένειά και τους φίλους μου, και ιδιαίτερα στους γονείς μου Βασίλειο και Αθηνά-Δήμητρα και στους αδερφούς μου Χαράλαμπο και Αλέξανδρο, για την αμέριστη συμπαράσταση τους και την πολύπλευρη υποστήριξή τους ώστε να μπορέσω να ακολουθήσω τα όνειρά μου.

Αθήνα, Νοέμβριος 2023

Ελισσαίος Σαρμάς

Πίνακας Περιεχομένων

Περίληψη	2
Abstract	4
Πρόλογος	6
1 Εισαγωγή	19
1.1 Πρόβλημα	19
1.2 Αντικείμενο & Στόχος Διατριβής	25
1.3 Συμβολή Διατριβής	26
1.4 Δομή Διδακτορικής Διατριβής	32
2 Επισκόπηση Μεθόδων Τεχνητής Νοημοσύνης & Αλγορίθμων Βελτιστοποίησης	40
2.1 Εισαγωγή	40
2.2 Μηχανική Μάθηση	41
2.2.1 Μέθοδοι Επιβλεπόμενης Μάθησης	42
2.2.2 Μέθοδοι Μη Επιβλεπόμενης Μάθησης	53
2.2.3 Μέθοδοι Ενισχυτικής Μάθησης	56
2.3 Βαθιά Μάθηση	58
2.3.1 Νευρωνικά Δίκτυα Πρόσθιας Τροφοδότησης	59
2.3.2 Συνελικτικά Νευρωνικά Δίκτυα	63
2.3.3 Αναδρομικά Νευρωνικά Δίκτυα	65
2.4 Αλγόριθμοι Βελτιστοποίησης	66
2.4.1 Αιτιοκρατικοί Αλγόριθμοι	68
2.4.2 Στοχαστικοί Αλγόριθμοι	72
2.5 Συμπεράσματα	74
3 Διατύπωση Προβλήματος και Επισκόπηση Συσχετιζόμενης Βιβλιογραφίας	83
3.1 Εισαγωγή	83
3.2 Ο ρόλος των Μεγάλων Δεδομένων στον Ενεργειακό Τομέα	85
3.3 Τεχνητή Νοημοσύνη και Κατανεμημένη Παραγωγή	87
3.3.1 Προβλεπτικά Μοντέλα ΑΠΕ	87
3.3.2 Ανίχνευση Σφαλμάτων και Προγνωστική Συντήρηση	93
3.3.3 Βέλτιστη Τοποθέτηση ΑΠΕ	94
3.4 Τεχνητή Νοημοσύνη και Ευελιξία σε Έξυπνα Δίκτυα	97
3.4.1 Μοντέλα Πρόβλεψης Φορτίου	97
3.4.2 Απόκριση Ζήτησης και Αγορά Ενέργειας	99
3.4.3 Βελτιστοποίηση Ευέλικτων Φορτίων και Διαχείριση Ζήτησης	100
3.4.4 Συστήματα Αποθήκευσης Ενέργειας	101

3.5	Τεχνητή Νοημοσύνη και Ενεργειακή Αποδοτικότητα Κτιρίων	103
3.5.1	Σχεδιασμός Κτιρίου	103
3.5.2	Κατασκευή Κτιρίου	106
3.5.3	Λειτουργία Κτιρίου	107
3.5.4	Ανακαίνιση Κτιρίου	109
3.6	Συμπεράσματα	111
4	Περιγραφή Επιμέρους Προβλημάτων, Στάδια Ανάπτυξης Μοντέλων & Προτεινόμενη Αρχιτεκτονική	126
4.1	Εισαγωγή	126
4.2	Προδιαγραφή Ενδιαφερομένων Μερών, Διατύπωση Επιμέρους Προβλημάτων & Καθορισμός Δεδομένων	127
4.2.1	Ενδιαφερόμενα Μέρη	127
4.2.2	Προβλήματα	130
4.2.3	Δεδομένα	133
4.3	Στάδια Ανάπτυξης Μοντέλων και Αλγορίθμων	134
4.3.1	Επιλογή Προβλήματος και Συλλογή Δεδομένων	134
4.3.2	Προεπεξεργασία Δεδομένων και Σχεδιασμός Χαρακτηριστικών	135
4.3.3	Εκπαίδευση, Αξιολόγηση και Επιλογή Μοντέλου	137
4.3.4	Ανάπτυξη και Παρακολούθηση Μοντέλου	138
4.4	Προτεινόμενη Αρχιτεκτονική	138
4.4.1	Επίπεδο Δεδομένων	139
4.4.2	Επίπεδο Μοντέλων	140
4.4.3	Επίπεδο Εφαρμογών	141
4.5	Συμπεράσματα	142
5	Μοντέλο Βαθιάς Μάθησης για την Πρόβλεψη Παραγωγής Φ/Β Συστημάτων	146
5.1	Εισαγωγή	146
5.2	Αναλυτική Διατύπωση Προβλήματος	148
5.2.1	Επισκόπηση και Κατηγοριοποίηση	149
5.2.2	Μέθοδοι Βαθιάς Μάθησης	150
5.3	Προτεινόμενο Μοντέλο	152
5.3.1	Αρχιτεκτονική Μοντέλου	152
5.3.2	Το μοντέλο LSTM	154
5.3.3	Baseline Μοντέλα Πρόβλεψης	156
5.3.4	Μοντέλο Μετα-Μάθησης	161
5.4	Μελέτη Περίπτωσης	162
5.4.1	Σύνολο Δεδομένων	163
5.4.2	Πειραματική Μοντελοποίηση	164
5.4.3	Μέθοδοι Πρόβλεψης	167
5.4.4	Μετρικές Αξιολόγησης	167
5.4.5	Αποτελέσματα και Σχολιασμός	168
5.5	Συμπεράσματα	170
6	Τεχνικές Μεταφοράς Μάθησης για την Πρόβλεψη Παραγωγής Φ/Β υπό καθεστώς Έλλειψης Δεδομένων	179
6.1	Εισαγωγή	179
6.2	Αναλυτική Διατύπωση Προβλήματος	180
6.3	Προτεινόμενο Μοντέλο	182
6.3.1	Μεταφορά Μάθησης	182

6.3.2	Το μοντέλο LSTM	183
6.3.3	Αρχιτεκτονικές Μοντέλων	184
6.4	Μελέτη Περίπτωσης	185
6.4.1	Σύνολο Δεδομένων	185
6.4.2	Επίδοση Baseline Μοντέλου	187
6.4.3	Στρατηγικές Μεταφοράς Μάθησης	189
6.4.4	Επιπτώσεις Διαθεσιμότητας Δεδομένων	191
6.5	Συμπεράσματα	193
7	Μοντέλο Πρόβλεψης Ενεργειακής Κατανάλωσης Κτιρίων για την Εκτίμηση της Εξοικονόμησης Ενέργειας	199
7.1	Εισαγωγή	199
7.2	Αναλυτική Διατύπωση Προβλήματος	201
7.2.1	Μοντελοποίηση Baseline Κατανάλωσης	201
7.2.2	Συσχετιζόμενη Βιβλιογραφία	203
7.3	Προτεινόμενο Μοντέλο	204
7.3.1	Αρχιτεκτονική Μοντέλου	205
7.3.2	Baseline Μοντέλα Παλινδρόμησης	205
7.4	Μελέτη Περίπτωσης	208
7.4.1	Σύνολο Δεδομένων	209
7.4.2	Πειραματικός Σχεδιασμός	210
7.4.3	Αποτελέσματα	213
7.5	Συμπεράσματα	213
8	Μοντέλο Μετα-μάθησης για την Αξιολόγηση Επενδύσεων Εν-εργειακής Αποδοτικότητας	220
8.1	Εισαγωγή	220
8.2	Αναλυτική Διατύπωση Προβλήματος	222
8.3	Προτεινόμενο Μοντέλο	224
8.3.1	Αρχιτεκτονική Μοντέλου	224
8.3.2	Baseline Μοντέλα Ταξινόμησης	226
8.3.3	Μοντέλο Μετα-Μάθησης	230
8.3.4	Σύσταση Χρηματοδότησης	231
8.4	Μελέτη Περίπτωσης	232
8.4.1	Σύνολο Δεδομένων	232
8.4.2	Εκπαίδευση και Ρύθμιση Υπερπαραμέτρων	233
8.4.3	Αποτελέσματα Προβλεπτικών Μοντέλων	235
8.5	Συμπεράσματα	238
9	Μοντέλο Βελτιστοποίησης Προγραμματισμού Αντλιών Ύδρευσης για την Εξομάλυνση Αιχμών Φορτίου	245
9.1	Εισαγωγή	245
9.2	Αναλυτική Διατύπωση Προβλήματος	247
9.2.1	Διατύπωση Προβλήματος	247
9.2.2	Τεχνικές Βελτιστοποίησης Συστημάτων Ύδρευσης	248
9.2.3	Πρόβλεψη Παραγωγής	249
9.2.4	Πρόβλεψη Φορτίου	250
9.3	Προτεινόμενο Μοντέλο	250
9.3.1	Μοντέλα Πρόβλεψης	251
9.3.2	Μοντέλα Βελτιστοποίησης	253
9.4	Μελέτη Περίπτωσης	256

9.4.1	Σύνολο Δεδομένων	256
9.4.2	Πειραματικός Σχεδιασμός	258
9.4.3	Ακρίβεια Μοντέλων Πρόβλεψης	261
9.4.4	Αποτελέσματα Βελτιστοποίησης	263
9.5	Συμπεράσματα	268
10	Μοντέλο Βελτιστοποίησης Λειτουργίας Ηλεκτρικών Οχημάτων και Συστήματος Αποθήκευσης Ενέργειας για την Ενεργειακή Αυτονομία Μικροδικτύου	277
10.1	Εισαγωγή	277
10.2	Αναλυτική Διατύπωση Προβλήματος	279
10.2.1	Πρόβλεψη Παραγωγής ΑΠΕ	279
10.2.2	Πρόβλεψη Κατανάλωσης Κτιρίων	280
10.2.3	Διαχείριση Ευέλικτων Φορτίων	281
10.2.4	Διαστασιολόγηση Μέσων Αποθήκευσης Ενέργειας	282
10.3	Προτεινόμενο Μοντέλο	283
10.3.1	Μοντέλα Πρόβλεψης	283
10.3.2	Μοντέλα Βελτιστοποίησης	285
10.4	Μελέτη Περίπτωσης	289
10.4.1	Σύνολο Δεδομένων	290
10.4.2	Επίδοση Προβλεπτικών Μοντέλων	292
10.4.3	Βελτιστοποίηση Διαχείρισης Ενέργειας	293
10.5	Συμπεράσματα	298
11	Συμπεράσματα - Προοπτικές	306
11.1	Συμπεράσματα	306
11.2	Προοπτικές	308
	Λίστα Δημοσιεύσεων	312

Κατάλογος Σχημάτων

1.1	Τα 4 'D's μέσω των οποίων μπορεί να εκφραστεί η ενεργειακή μετάβαση.	20
1.2	Τα 5 κυριότερα χαρακτηριστικά που διέπουν τα Μεγάλα Δεδομένα.	21
1.3	Συμβολή	26
1.4	Οι τρεις επιμέρους κατηγορίες των μοντέλων της Διδακτορικής Διατριβής	27
1.5	Δομή της Διδακτορικής Διατριβής	32
2.1	Επισκόπηση του επιστημονικού πεδίου της TN.	40
2.2	Η διαδικασία της Επιβλεπόμενης Μάθησης.	42
2.3	Σχηματική απεικόνιση του μοντέλου Linear Regression.	44
2.4	Σχηματική απεικόνιση του μοντέλου Support Vector Machine.	47
2.5	Σχηματική απεικόνιση του μοντέλου Decision Tree.	49
2.6	Σχηματική απεικόνιση του μοντέλου Random Forest.	51
2.7	Σχηματική απεικόνιση του μοντέλου k-nearest neighbors.	52
2.8	Η διαδικασία της Μη Επιβλεπόμενης Μάθησης.	53
2.9	Η διαδικασία της Ενισχυτικής Μάθησης.	57
2.10	Σχηματική απεικόνιση του μοντέλου Perceptron.	61
2.11	Σχηματική απεικόνιση του μοντέλου Multi-layer Perceptron.	62
2.12	Σχηματική απεικόνιση του μοντέλου CNN.	64
2.13	Σχηματική απεικόνιση του μοντέλου RNN.	66
2.14	Επισκόπηση των αλγορίθμων βελτιστοποίησης.	67
3.1	Παρουσίαση των τριών επιμέρους κατηγοριών εφαρμογών της TN στον τομέα της ενέργειας.	84
3.2	Διαφορετικοί τρόποι παροχής ευελιξίας μέσω της μετατόπισης ευέλικτων φορτίων.	101
4.1	Ενδιαφερόμενα Μέρη	128
4.2	Μεθοδολογία	135
4.3	Αρχιτεκτονική	139
5.1	Η προτεινόμενη μέθοδος μετα-μάθησης.	154
5.2	Επισκόπηση της μονάδας LSTM.	155
5.3	Η προτεινόμενη αρχιτεκτονική του μοντέλου stacked LSTM (StackLSTM).	158
5.4	Η προτεινόμενη αρχιτεκτονική του μοντέλου bidirectional LSTM (BiLSTM).	159
5.5	Η προτεινόμενη αρχιτεκτονική του μοντέλου CNN-LSTM.	160
5.6	Η προτεινόμενη αρχιτεκτονική του μοντέλου ConvLSTM.	161
5.7	Τοποθεσία των τριών Φ/Β συστημάτων που εξετάστηκαν στη μελέτη περίπτωσης.	163

5.8	Ωριαία κατανομή του συντελεστή δυναμικότητας (υπολογίζεται με χρήση προσθετικής αποσύνθεσης με κινητούς μέσους όρους; Spiliotis et al., 2020) για τα εξεταζόμενα Φ/Β συστήματα. Η χαμηλή διακύμανση γύρω από το εποχικό προφίλ (μπλε γραμμή) υποδηλώνει ισχυρή ημερήσια εποχικότητα (οι παρατηρήσεις επικαλύπτονται κάθε 24 ώρες).	164
5.9	Συνάρτηση αυτοσυσχέτισης της Φ/Β παραγωγής στο εργοστάσιο "Joao" (αριστερά) υπολογισμένη κατά τη διάρκεια της εβδομάδας (168 ώρες) και μέσος ημερήσιος συντελεστής δυναμικότητας (δεξιά) για κάθε μήνα του έτους.	165
5.10	Συσχέτιση κατά ζεύγη της ηλεκτρικής ενέργειας που παράγεται στο Φ/Β "Joao" (συντελεστής δυναμικότητας) και των τριών διαθέσιμων καιρικών μεταβλητών. Στο άνω μέρος του τριγωνικού πίνακα παρουσιάζονται οι συντελεστές συσχέτισης Pearson των μεταβλητών, ενώ στο κάτω μέρος του τα αντίστοιχα διαγράμματα διασποράς. Η κύρια διαγώνιος παρουσιάζει τις κατανομές (ιστογράμματα) των μεταβλητών.	165
5.11	Αποτελέσματα του τεστ Nemenyi σε επίπεδο σημαντικότητας 5% για το RMSE. Οι δοκιμές αφορούν εγγραφές όπου η πραγματική παραγωγή Φ/Β είναι μεγαλύτερη από το μηδέν.	169
5.12	Ακρίβεια πρόβλεψης (RMSE) για διαφορετικούς συντελεστές δυναμικότητας. Το RMSE του συντελεστή δυναμικότητας x % αντιστοιχεί στα μέσα σφάλματα πρόβλεψης των συντελεστών δυναμικότητας μέχρι x %.	169
6.1	Σχηματική αναπαράσταση της διαδικασίας μεταφοράς μάθησης.	182
6.2	Χάρτης που απεικονίζει τις τοποθεσίες των επιθεωρημένων Φ/Β συστημάτων. Τα 7 Φ/Β συστήματα βρίσκονται σε τέσσερις διαφορετικές πόλεις της Πορτογαλίας (Λισαβόνα, Setubal, Faro, Braga), επιτρέποντας την αξιολόγηση της απόδοσης του μοντέλου ανεξάρτητα από την πόλη. Η εικόνα στα δεξιά προσφέρει εστίαση στην πόλη της Λισαβόνας, όπου βρίσκονται 4 Φ/Β συστήματα (ο χάρτης δημιουργήθηκε με το https://www.mapcustomizer.com/ , OpenStreetMap contributors)	186
6.3	Η αναμενόμενη ισχύς σε συνθήκες clear sky για το βασικό Φ/Β σύστημα ως συνάρτηση της ώρας της ημέρας (που κυμαίνεται μεταξύ 0 και 23) και της ημέρας του έτους (που κυμαίνεται μεταξύ 0 και 255)	189
6.4	Παράδειγμα που απεικονίζει τις επιδόσεις του μοντέλου πρόβλεψης ηλιακής ενέργειας σε σύγκριση με το μοντέλο smart persistence. Ο οριζόντιος άξονας δείχνει το ωριαίο χρονικό βήμα της περιόδου αξιολόγησης, ενώ ο κατακόρυφος άξονας δείχνει την παραγωγή ηλιακής ενέργειας. Το παράδειγμα αναφέρεται σε μια τυχαία επιλεγμένη καλοκαιρινή εβδομάδα (μεταξύ των ωρών 54 και 222 του συνόλου επικύρωσης, που αντιστοιχούν στις 04-08-2020 και 11-08-2020) και σε μια τυχαία επιλεγμένη χειμερινή εβδομάδα (μεταξύ των ωρών 4060 και 4228 του συνόλου επικύρωσης, που αντιστοιχούν στις 18-01-2021 και 25-01-2021) της περιόδου αξιολόγησης.	190
6.5	Boxplot που συνοψίζει την απόδοση των τεσσάρων στοιβαγμένων μοντέλων LSTM για τα έξι Φ/Β με βάση το RMSE. Η βάση συμβολίζει το μοντέλο στο οποίο δεν έχει εφαρμοστεί TL, ενώ οι TL1, TL2, TL3 συμβολίζουν τις τρεις στρατηγικές TL, αντίστοιχα.	192

6.6	Συγκριτική απόδοση των τεσσάρων μοντέλων με βάση το δείκτη RMSE για περίοδο εκπαίδευσης 3 μηνών, 6 μηνών, 9 μηνών και 12 μηνών για τα έξι Φ/Β του τομέα-στόχου.	193
7.1	Υπολογισμός εξοικονόμησης ενέργειας σύμφωνα με το πλαίσιο IPMVP. Η εξοικονόμηση μπορεί να εκτιμηθεί με μετρήσεις πριν και μετά την εγκατάσταση του ECM, αλλά απαιτείται επίσης κανονικοποίηση της ενέργειας βάσης για την ενσωμάτωση των καιρικών και άλλων επιδράσεων.	202
7.2	Το προτεινόμενο μεθοδολογικό πλαίσιο για την εκτίμηση της εξοικονόμησης ενέργειας με βάση μοντέλα ML και ensembling.	206
7.3	Χρονοσειρές της θερμοκρασίας (μπλε χρώμα) και της κατανάλωσης ηλεκτρικής ενέργειας (πράσινο χρώμα) με την πάροδο του χρόνου.	209
7.4	Ιστόγραμμα θερμοκρασίας και ηλεκτρικής ενέργειας που παρουσιάζει την κατανομή των χρονοσειρών θερμοκρασίας και ηλεκτρικής ενέργειας για ένα συγκεκριμένο κτίριο.”	210
7.5	Το κοινό διάγραμμα της θερμοκρασίας και της ηλεκτρικής ενέργειας αναδεικνύει τη συσχέτιση μεταξύ των δύο χρονοσειρών.	211
7.6	Αποσύνθεση της χρονοσειράς κατανάλωσης ηλεκτρικής ενέργειας.	212
8.1	Επισκόπηση της προτεινόμενης μεθοδολογίας. Η σύσταση σχετικά με το ποσοστό επιχορήγησης της χρηματοδότησης των μελλοντικών επενδύσεων βασίζεται σε μια προσέγγιση βασισμένη σε δεδομένα, η οποία αξιοποιεί χρήσιμες γνώσεις από προηγούμενα έργα, που χαρακτηρίζονται με βάση την επιτευχθείσα μείωση της κατανάλωσης ενέργειας και το κόστος της επένδυσης (πραγματοποιηθείσα χρησιμότητα). Η έξοδος των βασικών μεθόδων ταξινόμησης, καθώς και του μετα-μαθητή, παρέχει το ποσοστό της συνιστώμενης επιχορηγούμενης χρηματοδότησης.	225
8.2	Επισκόπηση του προτεινόμενου στοιβαγμένου μοντέλου συνόλου. Οι βασικές μέθοδοι ταξινόμησης (επίπεδο-0) εκπαιδεύονται σύμφωνα με τη διαδικασία που περιγράφεται στο Σχήμα 8.1 και παρέχουν προβλέψεις για μελλοντικές επενδύσεις. Αυτές οι προβλέψεις τροφοδοτούνται στη συνέχεια στον μετα-μαθητή μαζί με τα διανύσματα εισόδου των βασικών μεθόδων. Η έξοδος του μετα-μαθητή είναι η τελική πρόβλεψη του στοιβαγμένου μοντέλου συνόλου, δηλαδή η πρόβλεψη του καταλληλότερου ταξινομητή βασικής γραμμής.	231
8.3	Επενδυτική σήμανση των εξεταζόμενων επενδύσεων με βάση την κατάταξη της επενδυτικής αποτελεσματικότητας.	233
8.4	Διάγραμμα ζεύγους των επενδυτικών μεταβλητών που εξετάζονται από τις προτεινόμενες μεθόδους ταξινόμησης στην εξεταζόμενη μελέτη περίπτωσης: Κόστος (€), Έτος κατασκευής του κτιρίου, Προγραμματισμένη μείωση CO ₂ (kgCO ₂), Κατανάλωση ενέργειας πριν (MWh), Συνολική επιφάνεια θέρμανσης (m ²), Όροφοι	234
8.5	Σύγκριση των βασικών ταξινομητών και της στοιβαξης στη διαδικασία στρωματοποιημένης 10πλής επικύρωσης. Στο αριστερό υπο-σχήμα φαίνεται το F1 score των ταξινομητών, ενώ στο δεξί η ακρίβειά τους.	236
8.6	Πίνακας σύγχυσης για το μοντέλο στοιβαξης στο σύνολο δοκιμών.	237
8.7	Καμπύλη ROC για τις τρεις κλάσεις με βάση τις παραγόμενες πιθανοτικές προβλέψεις του ταξινομητή στοιβαξης.	238

9.1	Διάγραμμα ροής του αλγορίθμου βελτιστοποίησης που χρησιμοποιείται για τον προγραμματισμό των ωρών λειτουργίας των αντλιών (ευέλικτος τρόπος λειτουργίας).	255
9.2	Ωριαίες χρονοσειρές που αντιπροσωπεύουν τη συνολική ηλεκτρική ενέργεια που καταναλώνεται (kW) στο νησί της Τήλου, τον συντελεστή ισχύος των Φ/B (%) και την ηλεκτρική ενέργεια που καταναλώνεται (kW) από τα πέντε αντλιοστάσια νερού (σύνολο των πέντε σταθμών).	257
9.3	Ημερήσια κατανάλωση ηλεκτρικής ενέργειας των πέντε αντλιοστασίων που εξετάστηκαν στην παρούσα μελέτη. Το ημερήσιο πρόγραμμα λειτουργίας αλλάζει σε διάφορους μήνες αλλά παραμένει το ίδιο εντός κάθε μήνα. Η συνολική ηλεκτρική ενέργεια που καταναλώνεται από τους σταθμούς εμφανίζεται με μωβ χρώμα.	258
9.4	Κατανομή των εποχιακών δεικτών (υπολογίζεται με χρήση προσθετικής αποσύνθεσης με κινητούς μέσους όρους; Spiliotis et al., 2020) για τη συνολική κατανάλωση ηλεκτρικής ενέργειας (αριστερά), τον συντελεστή ισχύος των Φ/B (μέση) και την κατανάλωση των αντλιοστασίων νερού (δεξιά). Η χαμηλή διακύμανση των δεικτών γύρω από το εποχικό προφίλ (μπλε γραμμή) υποδηλώνει χρονοσειρές με έντονη ημερήσια εποχικότητα (οι παρατηρήσεις επικαλύπτονται κάθε 24 ώρες).	259
9.5	Κατανομές (ιστογράμματα) των μεταβλητών που εξετάζονται από την προτεινόμενη μέθοδο βελτιστοποίησης στην εξεταζόμενη μελέτη περίπτωσης (κατανάλωση ηλεκτρικής ενέργειας, συντελεστής ισχύος Φ/B και προβλέψεις καιρού)	259
9.6	Συνάρτηση αυτοσυσχέτισης της συνολικής κατανάλωσης ηλεκτρικής ενέργειας που υπολογίζεται κατά τη διάρκεια της εβδομάδας (168 ώρες) και του έτους (8760 ώρες)	261
9.7	Συντελεστής ισχύος Φ/B (%) σε σύγκριση με την ηλιακή ακτινοβολία (W/m^2), τη θερμοκρασία ($^{\circ}C$), τη νεφοκάλυψη και την ταχύτητα του ανέμου (m/s). Οι συντελεστές συσχέτισης Pearson είναι 0,82, 0,30, -0,11 και 0,22 αντίστοιχα.	262
9.8	Παραδείγματα που απεικονίζουν τις επιδόσεις των μοντέλων πρόβλεψης της κατανάλωσης ηλεκτρικής ενέργειας (επάνω) και της ηλιακής ενέργειας (κάτω). Τα παραδείγματα αναφέρονται σε δύο τυχαία επιλεγμένες καλοκαιρινές (2020-07-31 έως 2020-08-06) και χειμερινές (2020-12-04 έως 2020-12-10) εβδομάδες της περιόδου αξιολόγησης.	264
9.9	Παραδείγματα που απεικονίζουν τον τρόπο με τον οποίο προσαρμόζεται η συνολική κατανάλωση ηλεκτρικής ενέργειας του νησιού όταν λαμβάνονται υπόψη οι ευέλικτοι και οι περιορισμένοι τρόποι βελτιστοποίησης λειτουργίας για την εξοικονόμηση αιχμών. Τα παραδείγματα αναφέρονται σε δύο τυχαία επιλεγμένες καλοκαιρινές (2020-07-31 έως 2020-08-06) και χειμερινές (2020-12-04 έως 2020-12-10) εβδομάδες της περιόδου αξιολόγησης. Παρουσιάζεται επίσης η ηλιακή ενέργεια για να διευκολυνθούν οι συγκρίσεις.	265

9.10	Μετατόπιση φορτίου που πραγματοποιείται στο πλαίσιο του ευέλικτου και του περιορισμένου τρόπου βελτιστοποίησης λειτουργίας. Κάθε γραμμή αντιπροσωπεύει τις ημερήσιες διαφορές που αναφέρθηκαν μεταξύ της λειτουργίας BaU και των βελτιστοποιημένων λειτουργιών (ευέλικτη ή περιορισμένη). Οι θετικές τιμές υποδεικνύουν ώρες κατά τις οποίες ο αλγόριθμος πρότεινε τη λειτουργία των αντλιοστασίων νερού, ενώ οι αρνητικές τιμές υποδεικνύουν ώρες κατά τις οποίες ο αλγόριθμος πρότεινε τη λειτουργία των αντλιοστασίων νερού.	266
9.11	Απόδοση της προτεινόμενης μεθόδου (ευέλικτος τρόπος λειτουργίας) όσον αφορά την εξοικονόμηση αιχμής (SD_{day}) όταν η παραγωγή ηλεκτρικής ενέργειας από Φ/Β αυξάνεται κατά έναν παράγοντα από 1 έως 40. Οι βελτιώσεις σε σχέση με τη λειτουργία BaU παρέχονται τόσο σε απόλυτες τιμές όσο και σε ποσοστά.	268
10.1	Επισκόπηση των δομικών στοιχείων του προτεινόμενου πλαισίου, που απεικονίζει την απαιτούμενη είσοδο (πηγές δεδομένων και περιορισμοί χρήστη), καθώς και τις μονάδες πρόβλεψης (μοντέλα πρόβλεψης Φ/Β και φορτίου) και διαχείρισης ενέργειας (προγραμματισμός συνεδριών φόρτισης EV και έλεγχος φόρτισης/εκφόρτισης ESS) που αναπτύχθηκαν στην παρούσα μελέτη.	283
10.2	Η συνολική αρχιτεκτονική του χρησιμοποιούμενου μοντέλου πρόβλεψης CNN-LSTM.	284
10.3	Διάγραμμα ροής του ευρετικού αλγορίθμου βελτιστοποίησης που αναπτύχθηκε για τη βελτιστοποίηση του προγραμματισμού των ωρών φόρτισης των ηλεκτροκίνητων οχημάτων.	287
10.4	Μια επισκόπηση της τοπολογίας του συστήματος μικροδικτύου που εξετάστηκε στην παρούσα μελέτη, απεικονίζοντας την κατεύθυνση των θετικών ροών ισχύος.	288
10.5	Γραφική αναπαράσταση των ροών ισχύος κατά τη διάρκεια των δύο πιθανών σεναρίων: (α) η παραγωγή ενέργειας είναι μεγαλύτερη από τη ζήτηση (αριστερό σχήμα), (β) η ζήτηση είναι μεγαλύτερη από την παραγωγή ενέργειας (δεξί σχήμα).	289
10.6	Η υποδομή της πραγματικής περίπτωσης χρήσης στο Terni της Ιταλίας. Το εξεταζόμενο μικροδίκτυο αποτελείται από ένα τριώροφο κτίριο με γραφεία (πάνω αριστερά), δύο χώρους στάθμευσης με Φ/Β πάνελ (πάνω δεξιά), τρεις σταθμούς φόρτισης ηλεκτρικών οχημάτων (κάτω αριστερά) και ένα BESS (κάτω δεξιά).	291
10.7	Παράδειγμα που δείχνει πώς το προτεινόμενο πλαίσιο βελτιστοποίησης επηρεάζει το χρονοδιάγραμμα των περιόδων φόρτισης EV (πάνω αριστερά), το καθαρό φορτίο και την κατάσταση φόρτισης της μπαταρίας (πάνω δεξιά), το DfG (κάτω αριστερά) και το RPF (κάτω δεξιά). Το παράδειγμα αναφέρεται σε μια τυχαία επιλεγμένη ημερομηνία της περιόδου αξιολόγησης (2021-10-25) υποθέτοντας ότι (i) μια μπαταρία χωρητικότητας ίσης με 50 kWh χρησιμοποιείται για την αποθήκευση της ενέργειας που παράγεται από το Φ/Β σύστημα και (ii) 5 EV ενδιφέρονται για φόρτιση κατά τη διάρκεια της ημέρας.	296

- 10.8 Επίδραση του βέλτιστου προγραμματισμού των περιόδων φόρτισης του EV όταν δεν υπάρχει διαθέσιμη μπαταρία για την αποθήκευση της ενέργειας που παράγεται από το Φ/Β σύστημα. Τα στοιχεία αντιστοιχούν στην πλήρη περίοδο προσομοίωσης (σύνολο ενός ημερολογιακού έτους), υποθέτοντας ότι διάφορα EV ενδιαφέρονται να φορτίσουν στην εξεταζόμενη εγκατάσταση. Στο σενάριο BaU (business as usual) υποτίθεται ότι όλοι οι οδηγοί EV ξεκινούν τη φόρτιση των αυτοκινήτων τους στις 8:00, ενώ στο βελτιστοποιημένο σενάριο η ώρα έναρξης της συνεδρίας καθορίζεται με βάση την πραγματική ηλεκτρική ενέργεια που παράγεται από τη Φ/Β εγκατάσταση και καταναλώνεται από την εγκατάσταση. 297
- 10.9 Επίδραση του ESS στον βέλτιστο προγραμματισμό των περιόδων φόρτισης EV. Τα στοιχεία αντιστοιχούν στην πλήρη περίοδο προσομοίωσης (σύνολο ενός ημερολογιακού έτους), υποθέτοντας ότι διάφορα EV ενδιαφέρονται να φορτίσουν στην εξεταζόμενη εγκατάσταση και ότι υπάρχουν διαθέσιμες μπαταρίες διαφόρων χωρητικότητας για την αποθήκευση της ενέργειας που παράγεται από το Φ/Β σύστημα. Σε όλες τις περιπτώσεις, ο χρόνος έναρξης της συνεδρίας φόρτισης καθορίζεται με βάση την πραγματική ηλεκτρική ενέργεια που παράγεται από τη Φ/Β εγκατάσταση και καταναλώνεται από την εγκατάσταση. 298
- 10.10 Επίδραση του σφάλματος πρόβλεψης στον βέλτιστο προγραμματισμό των περιόδων φόρτισης EV. Τα στοιχεία (σχετική ενέργεια) αντιστοιχούν στην πλήρη περίοδο προσομοίωσης (άθροισμα ενός ημερολογιακού έτους) υποθέτοντας ότι διάφορα EV ενδιαφέρονται να φορτίσουν στην εξεταζόμενη εγκατάσταση και ότι υπάρχουν μπαταρίες διαφόρων χωρητικότητας για την αποθήκευση της ενέργειας που παράγεται από το Φ/Β φόρτισης καθορίζεται με βάση την προβλεπόμενη ηλεκτρική ενέργεια που παράγεται από τη Φ/Β εγκατάσταση και καταναλώνεται από την εγκατάσταση. 299

Κατάλογος Πινάκων

2.1	Σύγκριση των αλγορίθμων βελτιστοποίησης.	68
3.1	Ενδεικτικές μελέτες εφαρμογών TN σε προβλήματα ΑΠΕ.	88
3.2	Ενδεικτικές μελέτες εφαρμογών TN στους κατανεμημένους ενεργειακούς πόρους σε επίπεδο δικτύου.	98
3.3	Ενδεικτικές μελέτες εφαρμογών TN για την ενεργειακή αποδοτικότητα στον κτιριακό τομέα.	104
4.1	Stakeholders and Analytics Services	132
5.1	Βιβλιογραφική ανασκόπηση μεθόδων BM για βραχυπρόθεσμες προβλέψεις παραγωγής Φ/B συστημάτων.	153
5.2	Προφίλ καιρού που δημιουργήθηκαν για το Φ/B εργοστάσιο "Joao". Για κάθε ένα από τα τρία προφίλ αναφέρεται ο μέσος όρος και η τυπική απόκλιση (σε παρένθεση) των μεταβλητών που χρησιμοποιήθηκαν για τη δημιουργία των συστάδων.	167
5.3	Συνολική ακρίβεια (RMSE και δείκτης ικανότητας πρόβλεψης) ανά μέθοδο πρόβλεψης και Φ/B σύστημα. Η ακριβέστερη μέθοδος πρόβλεψης για κάθε μονάδα και μέτρο ακρίβειας επισημαίνεται με έντονα γράμματα.	168
6.1	Στοιχεία των Φ/B συστημάτων που χρησιμοποιήθηκαν για την πειραματική εφαρμογή της μελέτης.	185
6.2	Μέση απόδοση πρόβλεψης (ακρίβεια) του μοντέλου έξυπνης εμμονής και των στοιβαγμένων μοντέλων LSTM με και χωρίς TL. Τα <i>RMSE</i> , <i>MBE</i> και <i>MAE</i> μετρώνται σε KWh, ενώ για τα R^2 και $nRMSE$ δίνεται το ποσοστό για κάθε μοντέλο.	191
7.1	Ανασκόπηση της βιβλιογραφίας σχετικά με τις μελέτες βασικής ενεργειακής μοντελοποίησης.	203
7.2	Σύγκριση μετρικών για κάθε κτίριο με τη χρήση διαφορετικών μοντέλων πρόβλεψης.	214
8.1	Απόδοση ταξινόμησης (μέσος όρος και τυπική απόκλιση) των βασικών μεθόδων και του μοντέλου στοιβαξης στη διαδικασία στρωματοποιημένης 10πλής επικύρωσης. Οι καλύτερες τιμές ανά στήλη εμφανίζονται με έντονη γραφή.	236
8.2	Απόδοση ταξινόμησης του μοντέλου στοιβαξης στο σύνολο δοκιμών.	237

- 9.1 Ο χώρος αναζήτησης και οι επιλεγμένες τιμές των υπερ-παραμέτρων για τα τρία μοντέλα πρόβλεψης που χρησιμοποιήθηκαν στην παρούσα μελέτη. Οι τιμές αναφέρονται χωριστά για τις σειρές παραγωγής Φ/B και κατανάλωσης ηλεκτρικής ενέργειας. 253
- 9.2 Απόδοση πρόβλεψης (ακρίβεια) του συνόλου των μοντέλων MM που χρησιμοποιήθηκαν στη μελέτη περίπτωσης. 263
- 9.3 Απόδοση της προτεινόμενης μεθόδου όσον αφορά την εξοικονόμηση αιχμής. Χρησιμοποιούνται διάφοροι δείκτες KPI για την αξιολόγηση της ημερήσιας και εβδομαδιαίας απόκλισης της κατανάλωσης ηλεκτρικής ενέργειας της Τήλου όταν δεν μετατοπίζονται φορτία (BaU), επιτρέπεται η ευέλικτη μετατόπιση φορτίου και πραγματοποιείται περιορισμένη μετατόπιση φορτίου. Παρέχονται επίσης οι ποσοστιαίες βελτιώσεις των δύο τρόπων βελτιστοποίησης της μετατόπισης φορτίου σε σχέση με τον τρόπο λειτουργίας BaU. 266
- 9.4 Απόδοση της προτεινόμενης μεθόδου όσον αφορά την εξοικονόμηση αιχμής (SD_{day}) όταν η παραγωγή ηλεκτρικής ενέργειας από Φ/B αυξάνεται κατά 10 και 40 φορές. Για τη διευκόλυνση των συγκρίσεων, οι βελτιώσεις των δύο τρόπων λειτουργίας μετατόπισης φορτίου σε σχέση με τον τρόπο λειτουργίας BaU παρέχονται ως ποσοστά. 267
- 9.5 Συνοπτική παρουσίαση του μοντέλου αιτιώδους γραμμικής παλινδρόμησης που χρησιμοποιήθηκε για τη συσχέτιση των κερδών που επιτυγχάνονται από την προτεινόμενη μέθοδο όσον αφορά τη σταθερότητα της κατανάλωσης ηλεκτρικής ενέργειας (KPI SD_{day}) με το σφάλμα πρόβλεψης της κατανάλωσης ηλεκτρικής ενέργειας (e_c), το σφάλμα πρόβλεψης της παραγωγής ηλεκτρικής ενέργειας από Φ/B (e_p) και το ποσό του φορτίου που μπορεί να μετατοπιστεί (SL). Οι συντελεστές με σημαντικότητα μεγαλύτερη από 95% σημειώνονται με (*). . . 269
- 10.1 Χαρακτηριστικά που χρησιμοποιούνται ως μεταβλητές εισόδου στα μοντέλα παραγωγής Φ/B και κατανάλωσης ηλεκτρικής ενέργειας. 284

Κεφάλαιο 1

Εισαγωγή

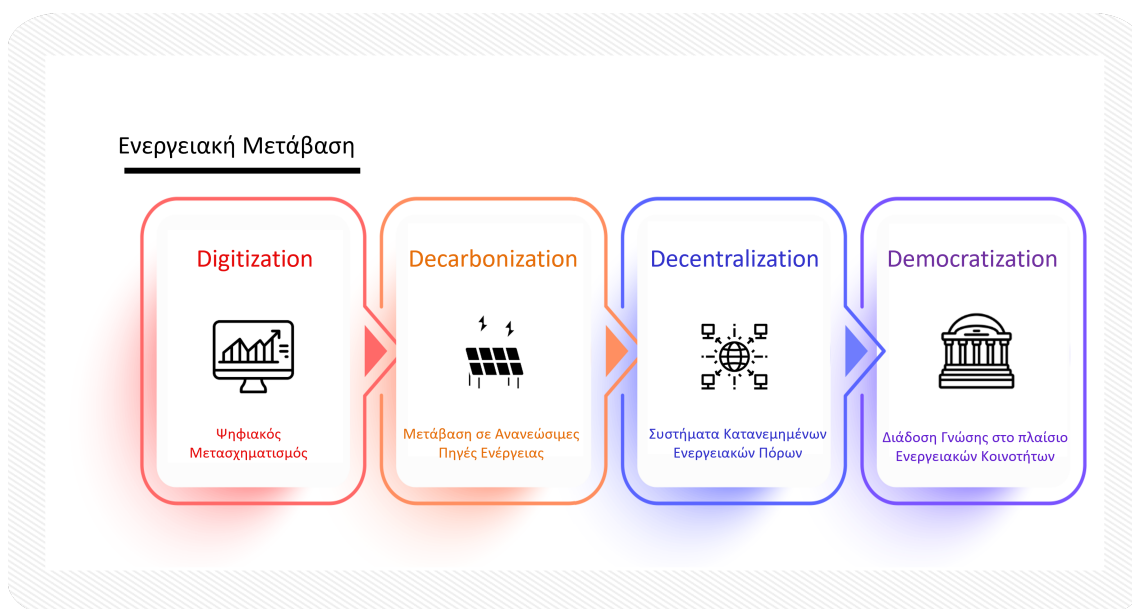
1.1 Πρόβλημα

Η ενεργειακή μετάβαση και τα 4 ‘D’s

Ο ενεργειακός τομέας υφίσταται αδιαμφισβήτητα θεμελιώδεις και πρωτοφανείς αλλαγές. Οι αλλαγές αυτές οφείλονται σε πολλαπλά αίτια, με κυριότερο μεταξύ αυτών να είναι η έντονη ανησυχία για τη βιωσιμότητα του πλανήτη υπό την παρούσα κατάσταση, η οποία εκφράζεται μέσω της Συμφωνίας του Παρισιού (*Paris Agreement*) που διατυπώθηκε το 2015 ([Agreement, 2015](#); [Tollefson and Weiss, 2015](#)) και εστιάζει στο σχεδιασμό και την εφαρμογή βιώσιμων, ισχυρών και κοινωνικά αποδεκτών και δίκαιων πολιτικών για την καταπολέμηση της κλιματικής αλλαγής σε ένα παγκόσμιο πλαίσιο ([Doukas et al., 2018](#)).

Παράλληλα, η διαρκώς αυξανόμενη δυναμική των σύγχρονων τεχνολογιών όπως, για παράδειγμα, το Διαδίκτυο των Πραγμάτων (*Internet of Things - IoT*), η Τεχνητή Νοημοσύνη - TN (*Artificial Intelligence - AI*) και οι τεχνολογίες *Blockchain* δημιουργούν μια ξεχωριστή ευκαιρία για την εντατικοποίηση της ενεργειακής μετάβασης ([Doukas, 2022](#)). Η ενεργειακή μετάβαση μπορεί να οριστεί, με απλά λόγια, ως η διαδικασία μετασχηματισμού και μετατόπισης του ενεργειακού τομέα από συστήματα παραγωγής και κατανάλωσης ενέργειας που βασίζονται σε ορυκτά καύσιμα, όπως το πετρέλαιο, το φυσικό αέριο και ο άνθρακας, σε εναλλακτικές πηγές ενέργειας όπως η ηλιακή ενέργεια, η αιολική ενέργεια, το υδρογόνο και οι μπαταρίες ιόντων λιθίου ([Markard, 2018](#)), μεταξύ άλλων.

Αξίζει να σημειωθεί πως το πρόβλημα της ενεργειακής μετάβασης περιλαμβάνει, αλλά δεν περιορίζεται στο στόχο της απανθρακοποίησης, καθώς έχει πολλαπλές κοινωνικές, τεχνολογικές και περιβαλλοντικές προεκτάσεις ([Carley and Konisky, 2020](#)). Πιο συγκεκριμένα, η επιτυχία, η ταχύτητα και η κοινωνική αποδοχή της ενεργειακής μετάβασης δεν είναι ένας εύκολος στόχος, αφού εξαρτάται σε μεγάλο βαθμό από τέσσερις συνιστώσες που είναι γνωστές ως τα 4 ‘D’s του ενεργειακού τομέα: την Απανθρακοποίηση (*Decarbonization*), την Ψηφιοποίηση (*Digitization*), την Αποκέντρωση (*Decentralization*) και τον Εκδημοκρατισμό (*Democratization*) της ενέργειας, τα οποία παρουσιάζονται στο Σχήμα 1.1. Συνεπώς, τα 4 ‘D’s μπορούν αναμφισβήτητα να αποτελέσουν την κινητήριο δύναμη για την πολυαναμενόμενη ενεργειακή μετάβαση, αλλά ταυτόχρονα επιφέρουν διαρκείς προκλήσεις και ρίσκα τα οποία θα μπορούσαν να θέσουν σε κίνδυνο το εγχείρημα της ενεργειακής μετάβασης σε ένα εύλογο χρονικό διάστημα.



Σχήμα 1.1: Τα 4 'D's μέσω των οποίων μπορεί να εκφραστεί η ενεργειακή μετάβαση.

Digitization: Η εποχή του ψηφιακού μετασχηματισμού

Τις τελευταίες δεκαετίες παρατηρούνται σημαντικές εξελίξεις στον τομέα των ψηφιακών τεχνολογιών, διαδραματίζοντας πολύ σημαντικό ρόλο στη διαμόρφωση συνηθειών και συμπεριφορικών προτύπων, στη ρύθμιση επιδόσεων και στρατηγικών, καθώς και στη λειτουργία οργανισμών, κοινοτήτων και γενικότερα της κοινωνίας. Μπορούμε χωρίς υπερβολή να ισχυριστούμε πως διανύουμε την εποχή της ψηφιοποίησης. Η ψηφιοποίηση είναι ένας από τους κομβικότερους παράγοντες της συνεχούς ανάπτυξης και στον τομέα της ενεργειακής καινοτομίας (Lyu and Liu, 2021), ο οποίος δε θα μπορούσε να παραμείνει ανεπηρέαστος από τις ριζικές αλλαγές.

Ο όρος ψηφιακές τεχνολογίες αναφέρεται σε οποιαδήποτε ηλεκτρονικά εργαλεία, συστήματα, συσκευές και πόρους που παράγουν, αποθηκεύουν ή επεξεργάζονται δεδομένα και πληροφορίες (Weigel and Fishedick, 2019). Οι ψηφιακές τεχνολογίες εμφανίστηκαν στο προσκήνιο πριν πολλές δεκαετίες, όμως η εξέλιξη τους τα τελευταία χρόνια είναι ραγδαία, μετατρέποντας τον ενεργειακό τομέα σταδιακά στην εποχή της Ενέργειας 4.0 (Mourtzis et al., 2021). Σύμφωνα με το Διεθνή Οργανισμό Ενέργειας (International Energy Agency - IEA), η ψηφιοποίηση στον τομέα της ενέργειας θεωρείται ως η αυξανόμενη εφαρμογή των τεχνολογιών πληροφοριών και επικοινωνιών (Information Communication Technologies - ICTs) έχοντας συμβάλει στη σύγκλιση μεταξύ του ψηφιακού και του φυσικού κόσμου (International Energy Agency and OECD, 2017).

Επιπλέον, η διαθεσιμότητα και η ποιότητα των δεδομένων έχουν βελτιωθεί σημαντικά, αφήνοντας περιθώριο για τη βελτιστοποίηση λειτουργιών και καθημερινών διεργασιών και ρουτινών σε επίπεδο κτιρίου, είτε σε οικιακό περιβάλλον, είτε σε περιβάλλον εργασίας), κοινότητας ή ακόμη και πόλης (Sarmas et al., 2022b). Τα διαθέσιμα δεδομένα χαρακτηρίζονται από υψηλό όγκο (Volume), αφού χιλιάδες terabytes δημιουργούνται αθροιστικά από έξυπνους αισθητήρες κάθε δευτερόλεπτο, μεγάλη ποικιλία (Variety) από δομημένα ή αδόμητα, σύγχρονα ή ασύγχρονα δεδομένα, ταχύτατο ρυθμό εμφάνισης νέων δεδομένων και ανανέωσης των υπαρχόντων (Velocity) και αυξημένη αξιοπιστία (Veracity). Αυτές οι τέσσερις ιδιότητες των μεγάλων δεδομένων δημιουργούν ευκαιρίες αξιοποίησης με ψηφιακές τεχνολογίες αιχμής που στο-

χεύουν να προσθέσουν αξία (*Value*) στα δεδομένα, σχηματίζοντας έτσι τα 5 'V's των μεγάλων δεδομένων (*Big Data*) όπως φαίνονται στο Σχήμα 1.2. Η αξία των δεδομένων μεταφράζεται στην επιρροή που έχει η ανάλυση και η αξιοποίηση τους για έναν οργανισμό προκειμένου να βελτιστοποιήσει τις λειτουργίες του και να υποστηρίξει τη διαδικασία λήψης αποφάσεων (Marinakis et al., 2020).



Σχήμα 1.2: Τα 5 κυριότερα χαρακτηριστικά που διέπουν τα Μεγάλα Δεδομένα.

Decarbonization: Η ανάγκη μεταστροφής σε ΑΠΕ

Οι πρόσφατες εξελίξεις που αφορούν στην επιδείνωση του φαινομένου της κλιματικής αλλαγής καθώς και οι αυξανόμενες εκπομπές διοξειδίου του άνθρακα (CO_2) επιβάλλουν δραστικές αλλαγές σε εθνικό και παγκόσμιο επίπεδο προκειμένου να αυξηθούν σημαντικά οι προσπάθειες για την απανθρακοποίηση του ενεργειακού τομέα (Papadis and Tsatsaronis, 2020). Ο όρος απανθρακοποίηση αναφέρεται στη μείωση της εξάρτησης από τον άνθρακα, μέσω της σταδιακής μετάβασης σε ένα νέο ενεργειακό σύστημα που περιορίζει τις εκπομπές διοξειδίου του άνθρακα. Αν αναλογιστεί κανείς ότι μέχρι το 2019 οι παγκόσμιες εκπομπές CO_2 ήταν πάνω από 60% πάνω από τις αντίστοιχες εκπομπές το 1990, όταν ξεκίνησαν οι διαπραγματεύσεις για το κλίμα, τότε μπορεί να γίνει αντιληπτό πως το φαινόμενο αυτό αποτελεί την κύρια αιτία υπερθέρμανσης του πλανήτη (Marinakis et al., 2021). Μάλιστα το 2019 ήταν έτος ρεκόρ για τις εκπομπές CO_2 και παρόλο που σημειώθηκε σημαντική μείωση το 2020 λόγω της πανδημίας, αυτό μπορεί να αποδοθεί στα κλιμακωτά lockdown που επιβλήθηκαν στην πλειονότητα των χωρών (Friedlingstein et al., 2020).

Ο μακροπρόθεσμος στόχος που έχει τεθεί είναι η δημιουργία μιας παγκόσμιας οικονομίας χωρίς CO_2 . Προς αυτό το στόχο ενισχύονται διάφορες δράσεις καινοτομίας και ευαισθητοποίησης της παγκόσμιας κοινότητας, όπως ο καθορισμός ευρέως αποδεκτών ορίων στους ρυθμούς αύξησης της παγκόσμιας θερμοκρασίας. Σύμφωνα με τη Συμφωνία του Παρισιού, η μέση παγκόσμια αύξηση της θερμοκρασίας θα πρέπει να περιοριστεί στους $1,5^\circ C$ τις επόμενες δεκαετίες, βέβαια η πραγματική εικόνα προς το παρόν απέχει αρκετά από τους στόχους που έχουν οριστεί (Doukas et al., 2018).

Είναι κοινώς αποδεκτό ότι ο προφανέστερος τρόπος για να επιτευχθεί η απανθρακοποίηση είναι η ευρεία μεταστροφή προς τις Ανανεώσιμες Πηγές Ενέργειας (ΑΠΕ). Στο πλαίσιο αυτό, μια ακόμη πρωτοβουλία με στόχο την απανθρακοποίηση πραγματοποιήθηκε από τον Διεθνή Οργανισμό Ανανεώσιμων Πηγών Ενέργειας (*International Renewable Energy Agency - IRENA*), ο οποίος πρότεινε πως απαιτείται ένα πλήρες σχέδιο για την απαλλαγή από τις ανθρακούχες εκπομπές έως το 2050 (IRENA, 2015). Ως εκ τούτου, πολλές χώρες χρησιμοποιούν ήδη ένα μεγάλο μερίδιο των ανανεώσιμων πόρων τους, όπως η αιολική και η ηλιακή ενέργεια για την ικανοποίηση

των ενεργειακών αναγκών τους (Kroposki et al., 2017). Παρ' όλα αυτά, η αλλαγή του ενεργειακού μείγματος δεν είναι ομοιογενής σε ολόκληρο τον κόσμο, το οποίο είναι ένα πρόβλημα που πηγάζει από το διαφορετικό επίπεδο ανάπτυξης και οικονομικής κατάστασης, τα διαφορετικά νομικά πλαίσια και τις κοινωνικές ανομοιογένειες που παρατηρούνται από χώρα σε χώρα.

Decentralization: Συστήματα κατανεμημένων ενεργειακών πόρων

Η ευρεία τεχνολογική πρόοδος σε όλα τα επίπεδα την τελευταία δεκαετία συνοδεύτηκε από την ενεργοποίηση των καταναλωτών με απώτερο σκοπό την αποκέντρωση του ενεργειακού συστήματος. Ένα αποκεντρωμένο ενεργειακό σύστημα δημιουργείται μέσω της τοποθέτησης εγκαταστάσεων παραγωγής ενέργειας πιο κοντά στις πηγές κατανάλωσης ενέργειας, σε αντίθεση με ένα κεντρικό σύστημα παροχής ενέργειας που χαρακτηρίζεται από παραγωγή ηλεκτρικής ενέργειας μεγάλης κλίμακας σε κεντρικές μονάδες παραγωγής ενέργειας (Hope et al., 2018). Η δημιουργία και η ανάπτυξη αποκεντρωμένων ενεργειακών συστημάτων βασίζεται στην υιοθέτηση και ευρεία χρήση των ΑΠΕ με στόχο τη μείωση της εξάρτησης από τα ορυκτά καύσιμα, όπως αναλύθηκε στην προηγούμενη παράγραφο.

Ωστόσο, η συνεχής ανάπτυξη των συστημάτων που βασίζονται σε ΑΠΕ, καθώς και η ύπαρξη ενεργών καταναλωτών με δυνατότητες διαχείρισης από την πλευρά της ζήτησης θέτουν σημαντικές προκλήσεις στη λειτουργία του ενεργειακού συστήματος και στην αγορά ηλεκτρικής ενέργειας. Γενικότερα, παρατηρείται η τάση για μετατροπή της δομής της αγοράς ηλεκτρικής ενέργειας από κεντροποιημένη με επίκεντρο τους προμηθευτές σε πιο αποκεντρωμένη με επίκεντρο τον καταναλωτή και με τα νοικοκυριά να διαδραματίζουν σημαντικό ρόλο με την παραγωγή και την αποθήκευση της ενέργειας που χρειάζονται (Baidya et al., 2021).

Είναι εμφανές, λοιπόν, πως ο στόχος της αποκέντρωσης είναι πιο επίκαιρος από ποτέ στις μέρες μας, οδηγώντας στη σταδιακή μετατροπή των ενεργειακών συστημάτων και παράλληλα αξιοποιώντας την τεχνική και τεχνολογική πρόοδο. Ως αποτέλεσμα, προωθούνται κατανεμημένες, *peer-to-peer* ενεργειακές συναλλαγές που βασίζονται στην κοινότητα με στόχο τη δημιουργία ενός μοντέλου με επίκεντρο τους καταναλωτές (Esmat et al., 2021) και απαιτούνται προβλεπτικά μοντέλα και αλγόριθμοι βελτιστοποίησης για την εξασφάλιση της επιτυχημένης λειτουργίας τέτοιων καινοτόμων μικροδικτύων (*microgrids*) και αποκεντρωμένων συστημάτων (Kuznetsova et al., 2015).

Democratization: Διάδοση της γνώσης στο πλαίσιο ενεργειακών κοινοτήτων

Το αποκεντρωμένο μοντέλο που περιεγράφηκε στις προηγούμενες παραγράφους βασίζεται σε μεγάλο βαθμό στην ικανότητα των ατόμων να παράγουν, να αποθηκεύουν και να διαχειρίζονται την ενέργεια που καταναλώνουν. Αυτό το μοντέλο μπορεί να υλοποιηθεί μέσω της μαζικής εγκατάστασης εξοπλισμού για παραγωγή ενέργειας, όπως φωτοβολταϊκά (Φ/Β) στέγης, συστημάτων αποθήκευσης ενέργειας -αν και το κόστος τους είναι ακόμη μεγάλο- και έξυπνων συστημάτων διαχείρισης και παρακολούθησης του μικροδικτύου που σχηματίζεται. Ο όρος που έχει καθιερωθεί για την περιγραφή των ατόμων που παράγουν την ενέργεια που καταναλώνουν είναι παραγωγός-καταναλωτής ή αυτοπαραγωγός (*prosumer*, από το συνδυασμό των λέξεων *producer* και *consumer*). Ο παραγωγός-καταναλωτής γενικά ορίζεται ως οποιοσδήποτε καταναλωτής ηλεκτρικής ενέργειας που έχει τη δυνατότητα να παράγει μέρος ανάγκης του για ηλεκτρική ενέργεια

με δικό του μέσο παραγωγής (Zafar et al., 2018). Ο παραγωγός-καταναλωτής έχει τη δυνατότητα να διοχετεύει την πλεονάζουσα παραγωγή στο δίκτυο εφόσον υπάρχει, και αντίστοιχα να καλύπτει την ανάγκη του για ενέργεια από το δίκτυο όταν η αυτοπαραγωγή δεν αρκεί.

Ο εκδημοκρατισμός της ενέργειας προϋποθέτει καθολική πρόσβαση σε οικονομικά προσιτή και καθαρή ενέργεια, ώστε ο καθένας να έχει τη δυνατότητα να χρησιμοποιεί τις ΑΠΕ σύμφωνα με τις ανάγκες του. Αυτή η συνθήκη οδηγεί στη δημιουργία τοπικής οικονομικής αξίας, αφού αυξάνονται οι ευκαιρίες ανάπτυξης για τους αυτοπαραγωγούς και τις μικρομεσαίες επιχειρήσεις λόγω της αξιόπιστης πρόσβασής τους στην ηλεκτρική ενέργεια. Συνεπώς, τα άτομα που χρησιμοποιούν την ενέργεια πρέπει να συμμετέχουν ενεργά στη διαδικασία λήψης αποφάσεων σχετικά με τον τρόπο προώθησης και διανομής της για να επωφεληθούν στο μέγιστο βαθμό από τις οικονομικές αποδόσεις της ενέργειας που παράγουν (Moura and Brito, 2019). Στο πλαίσιο αυτό, ο πλήρης εκδημοκρατισμός των ενεργειακών δεδομένων και υπηρεσιών φιλοδοξεί να δώσει τη δυνατότητα πρόσβασης σε δεδομένα, πληροφορίες κι έξυπνα συστήματα και υπηρεσίες στον μέσο τελικό χρήστη. Ο στόχος του εκδημοκρατισμού των δεδομένων και των εφαρμογών είναι να επιτρέψει στα άτομα της ενεργειακής κοινότητας να συλλέγουν και να αναλύουν τα δεδομένα των συστημάτων παραγωγής ενέργειας, της κατανάλωσης τους και των ευέλικτων φορτίων τους χωρίς να απαιτείται εξωτερική βοήθεια από ειδικούς.

Ο ρόλος της τεχνητής νοημοσύνης

Στις προηγούμενες παραγράφους πραγματοποιήθηκε μια συνοπτική περιγραφή του προβλήματος της ενεργειακής μετάβασης και της σχέσης του με την τεχνολογική πρόοδο η οποία έχει οδηγήσει στην ύπαρξη μεγάλου όγκου διαθέσιμων δεδομένων. Η κατάσταση αυτή δημιουργεί μεγάλες ευκαιρίες για το σχεδιασμό, την υλοποίηση και την ανάπτυξη ευφυών συστημάτων τα οποία μπορούν να επιτρέψουν τη βέλτιστη διαχείριση της ενέργειας και να υποστηρίξουν στη λήψη αποφάσεων σε πληθώρα προβλημάτων. Ωστόσο, βασικό ρόλο στην ανάπτυξη των συστημάτων αυτών διαδραματίζει η ΤΝ, η οποία μπορεί να χρησιμοποιηθεί για τη βελτιστοποίηση των ενεργειακών δικτύων με τη διαχείριση των ροών ενέργειας μεταξύ των σπιτιών, των επιχειρήσεων, των μπαταριών αποθήκευσης, των ΑΠΕ, των μικροδικτύων και του δικτύου ηλεκτρικής ενέργειας, μειώνοντας τη σπατάλη ενέργειας και παράλληλα αυξάνοντας τη συμμετοχή των καταναλωτών στη διαχείριση της ενέργειας.

Στο πλαίσιο αυτό, η ΤΝ χρησιμοποιείται ήδη σε ένα μεγάλο πλήθος από ενεργειακές εφαρμογές που αφορούν είτε στις ΑΠΕ, είτε στην ενεργειακή εξοικονόμηση κτιρίων, είτε στην ευφυή ενεργειακή διαχείριση σε επίπεδο μικροδικτύου που αποτελείται από καταναμημένους ενεργειακούς πόρους.

Όσον αφορά τις ΑΠΕ, η ΤΝ χρησιμοποιείται σχεδόν σε κάθε τύπο, όπως αιολική, ηλιακή, γεωθερμική και υδροηλεκτρική ενέργεια και άλλες, αλλά και σε υβριδικές μορφές μεταξύ αυτών για το σχεδιασμό, τη βελτιστοποίηση, την εκτίμηση, τη διαχείριση, τη διανομή και την χάραξη πολιτικής (Jha et al., 2017). Η επισκόπηση της υπάρχουσας βιβλιογραφίας υποδηλώνει πως οι περισσότερες επιστημονικές έρευνες επικεντρώνονται σε εφαρμογές της ΤΝ σε συστήματα που βασίζονται στην αιολική και ηλιακή ενέργεια, αν και υπάρχουν ακόμη μελέτες που εστιάζουν στην εφαρμογή μεθόδων ΤΝ σε υβριδικές πηγές. Οι κύριοι άξονες της έρευνας είναι η ανάπτυξη προβλεπτικών μοντέλων για την παραγωγή ηλεκτρικής ενέργειας από ΑΠΕ, ο εντοπισμός σφαλμάτων σε συστήματα ΑΠΕ και η διαστασιολόγηση και βέλτιστη γεωγραφικά τοποθέτηση ΑΠΕ.

Στον τομέα της ενεργειακής εξοικονόμησης σε επίπεδο κτιρίου, η ΤΝ χρησιμοποιεί-

ται σε όλα τα στάδια του κύκλου ζωής ενός κτιρίου. Πιο συγκεκριμένα, μέθοδοι TN έχουν χρησιμοποιηθεί για το σχεδιασμό του κτιρίου έχοντας αρχίσει να μετασχηματίζουν τον τρόπο με τον οποίο οι αρχιτέκτονες οραματίζονται και δημιουργούν ένα κτίριο (Tamke et al., 2018). Έπειτα στο στάδιο της κατασκευής η TN χρησιμοποιείται επιτυχώς στην ανάλυση κόστους, στη διαχείριση της κατασκευής, στην ανίχνευση ελαττωμάτων και στη μοντελοποίηση των πληροφοριών του κτιρίου (Hong et al., 2020). Σημαντικές εφαρμογές έχουν επίσης αναπτυχθεί στο στάδιο της λειτουργίας και συντήρησης του κτιρίου φιλοδοξώντας να μεγιστοποιήσουν το επίπεδο άνεσης των κατοίκων ή των εργαζομένων στο κτίριο και παράλληλα να αυξήσουν την ενεργειακή αποδοτικότητα του κτιρίου (Du et al., 2014).

Από την πλευρά της διαχείρισης ενέργειας, καθώς ο ενεργειακός τομέας γίνεται όλο και πιο περίπλοκος, υπάρχει ανάγκη για ευφυείς εφαρμογές και μηχανισμούς για την αποτελεσματική διαχείριση του συστήματος και τη λήψη έγκαιρων αποφάσεων (Ali and Choi, 2020). Νέοι τομείς όπως η Μηχανική Μάθηση (MM) και η Βαθιά Μάθηση (BM), τα νευρωνικά δίκτυα, οι γενετικοί αλγόριθμοι και η ενισχυτική μάθηση είναι κάποιες από τις δημοφιλέστερες τεχνικές TN που χρησιμοποιούνται για την ανάπτυξη ευφών εφαρμογών διαχείρισης ενέργειας και βελτιστοποίησης της χρήσης των διαθέσιμων καταναμημένων ενεργειακών πόρων (Ramos and Liu, 2011). Ωστόσο, το επίπεδο ανάπτυξης τέτοιων εφαρμογών δεν είναι αρκετά ώριμο, με συνέπεια πολλές λειτουργίες να εκτελούνται σε ένα πολύ βασικό επίπεδο αυτοματισμού σε επίπεδο μικροδικτύου και να μην αξιοποιούν με αποτελεσματικό τρόπο την παραγωγή ηλεκτρικής ενέργειας.

Παρόλο που η TN και η MM έχουν χρησιμοποιηθεί εκτενώς στους τρεις παραπάνω τομείς (ΑΠΕ, ενεργειακή αποδοτικότητα κτιρίων και ενεργειακή διαχείριση καταναμημένων πόρων σε μικροδίκτυα), έχουν εντοπιστεί αρκετοί περιορισμοί και κενά που αφήνουν περιθώρια περαιτέρω έρευνας στα συγκεκριμένα αντικείμενα. Πρώτον, οι περισσότερες μελέτες βρίσκονται ακόμη στη φάση έρευνας και ανάπτυξης και πολύ λίγες έχουν υιοθετηθεί από τη βιομηχανία. Υπάρχουν αρκετοί λόγοι που συμβαίνει αυτό με κυριότερο την έλλειψη ενός ομογενοποιημένου μεθοδολογικού πλαισίου για το κάθε πρόβλημα, έχοντας σαφή προαπαιτούμενα για τη μορφή των δεδομένων εισόδου και των χαρακτηριστικών που πρέπει να ικανοποιεί το κάθε μοντέλο που αναπτύσσεται. Δεύτερον, διαφορετικές μέθοδοι και μοντέλα TN εκπαιδεύονται και συγκρίνονται σε διαφορετικά σύνολα δεδομένων, γεγονός που καθιστά αδύνατη τη δίκαιη και αξιόπιστη σύγκριση των αποτελεσμάτων ή τη συγκριτική αξιολόγηση μεταξύ των διαφορετικών μοντέλων (Hong et al., 2020). Επομένως, είναι αναγκαία η διατύπωση ξεκάθαρων μετρικών αξιολόγησης για κάθε πρόβλημα με στόχο να μπορούν να συγκριθούν μοντέλα μάθησης σε διαφορετικά σύνολα δεδομένων. Τέλος, ένας σημαντικός περιορισμός της TN έγκειται στην ερμηνευσιμότητα των αποτελεσμάτων. Πιο συγκεκριμένα, τα περισσότερα πεδία της TN, όπως η MM και η BM υιοθετούν την data-driven προσεγγίσεις που λειτουργούν ως black-box, με συνέπεια τις περισσότερες φορές να είναι ασαφές πως προέκυψε το αποτέλεσμα ακόμη και σε κάποιον ειδικό (Carvalho et al., 2019).

Επομένως, ο σχεδιασμός και η ανάπτυξη δομημένων μοντέλων μάθησης και αλγορίθμων βελτιστοποίησης για προβλήματα ενεργειακής διαχείρισης, ΑΠΕ ή ενεργειακής αποδοτικότητας κτιρίων είναι ένα επιστημονικό πεδίο που απαιτεί διαρκή έρευνα και καινοτόμες ιδέες, με στόχο την υποστήριξη της ενεργειακής μετάβασης με δίκαιο, βιώσιμο και εκδημοκρατισμένο τρόπο στο πλαίσιο μιας κοινωνίας χωρίς αποκλεισμούς και με ίσα δικαιώματα στην ενέργεια.

1.2 Αντικείμενο & Στόχος Διατριβής

Το αντικείμενο και ο στόχος της Διδακτορικής Διατριβής παρουσιάζονται παρακάτω:

Αντικείμενο

Το αντικείμενο της Διδακτορικής Διατριβής είναι η ανάπτυξη μιας ολοκληρωμένης σειράς μοντέλων μάθησης και αλγορίθμων βελτιστοποίησης για την υποστήριξη αποφάσεων σε προβλήματα στον ενεργειακό και κτιριακό τομέα. Πιο συγκεκριμένα, η Διατριβή επιδιώκει να προσφέρει σύγχρονες λύσεις σε ιδιαιτέρως σημαντικά ενεργειακά προβλήματα που απασχολούν την επιστημονική κοινότητα, μέσω της ανάπτυξης καινοτόμων μοντέλων, αλγορίθμων μάθησης και βελτιστοποίησης και ολοκληρωμένων μεθοδολογιών για προβλήματα που ανήκουν σε τρεις άξονες: την κατανεμημένη παραγωγή, την ευελιξία σε επίπεδο μικροδικτύου και την ενεργειακή αποδοτικότητα κτιρίων. Το αντικείμενο της Διατριβής μπορεί να χαρακτηριστεί από τη μια πλευρά ως μια εξατομικευμένη και ολοκληρωμένη λύση σε κάθε πρόβλημα, αλλά από την άλλη πλευρά ως μια γενικευμένη μεθοδολογία αντιμετώπισης προβλημάτων κάθε φύσης η οποία μπορεί να επεκταθεί σε νέα ενεργειακά ζητήματα μέσα από κατάλληλες προσαρμογές.

Στόχος

Η Διδακτορική Διατριβή έχει ως στόχο να συμβάλει στην κάλυψη του επιστημονικού “κενού” που εντοπίστηκε σχετικά με την ανάπτυξη σύγχρονων μεθόδων μάθησης και αλγορίθμων μαθηματικής βελτιστοποίησης για την επίλυση μιας σειράς προβλημάτων στον ενεργειακό και κτιριακό τομέα. Το συγκεκριμένο επιστημονικό πεδίο αποτελεί ένα συνεχώς εξελισσόμενο πεδίο, αφού νέες μεθοδολογίες, αλγόριθμοι και μοντέλα αναδύονται με πολύ γρήγορους ρυθμούς, εντείνοντας την ανάγκη για τακτική παρακολούθηση των εξελίξεων και συνεισφορά στον τομέα. Πιο συγκεκριμένα, η Διδακτορική Διατριβή στοχεύει στην ανάπτυξη μοντέλων και αλγορίθμων για προβλήματα που εντάσσονται σε τρεις ευρύτερες κατηγορίες: (α) Κατανεμημένη Παραγωγή και Ανανεώσιμες Πηγές Ενέργειας, (β) Ευελιξία σε επίπεδο μικροδικτύου και (γ) Ενεργειακή Αποδοτικότητα Κτιρίων. Συνεπώς αναπτύσσονται και παρουσιάζονται μοντέλα ΤΝ και μαθηματικής βελτιστοποίησης για εφαρμογές που σχετίζονται με καθεμιά από τις παραπάνω κατηγορίες, μέσα από την εμπεριστατωμένη ανάλυση των βασικών παραμέτρων της κάθε εφαρμογής καθώς και των αλληλεπιδράσεων που υπάρχουν μεταξύ τους.

1.3 Συμβολή Διατριβής

Η συμβολή της Διδακτορικής Διατριβής συνίσταται στην ανάπτυξη μιας σειράς μοντέλων TN και αλγορίθμων βελτιστοποίησης με έμφαση σε επιμέρους προβλήματα στον τομέα της διαχείρισης ενέργειας, στις ΑΠΕ και στην ενεργειακή αποδοτικότητα κτιρίων.

Η συμβολή της Διδακτορικής Διατριβής διακρίνεται σε τέσσερα (4) επίπεδα, όπως απεικονίζεται στο Σχήμα 1.3, τα οποία αναλύονται στις επόμενες παραγράφους.



Σχήμα 1.3: Συμβολή

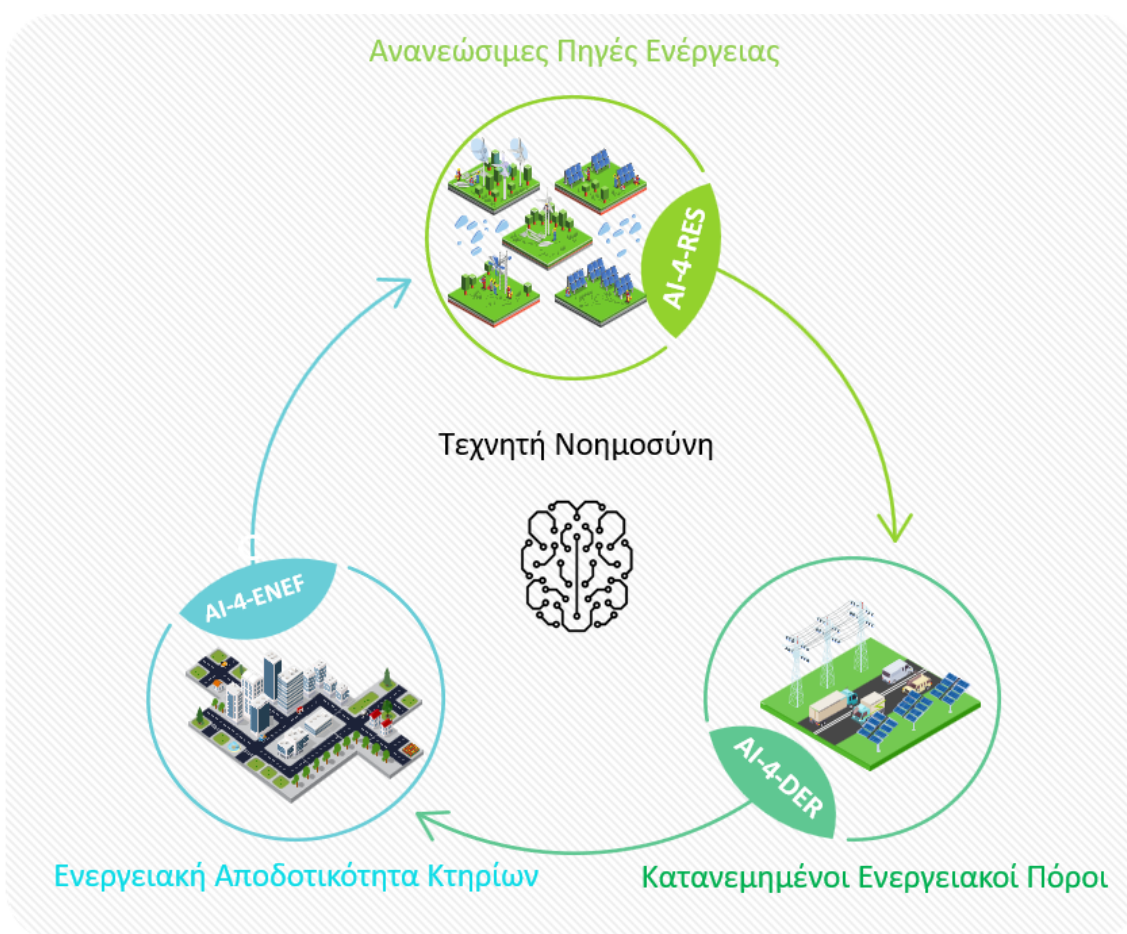
1ο Επίπεδο Συμβολής: Ανάπτυξη καινοτόμων μοντέλων TN και αλγορίθμων βελτιστοποίησης για μια σειρά εφαρμογών στον τομέα της ενέργειας.

Στο πλαίσιο της Διδακτορικής Διατριβής παρουσιάζεται μια σειρά μοντέλων TN, και πιο συγκεκριμένα μοντέλων MM και BM, καθώς και αλγορίθμων βελτιστοποίησης οι οποίοι έχουν αναπτυχθεί με βάση ένα ολοκληρωμένο μεθοδολογικό πλαίσιο (Κεφάλαιο 4). Η αφετηρία για την επιλογή των επιμέρους πεδίων έρευνας είναι ο εντοπισμός συγκεκριμένων προβλημάτων για τα οποία είτε υπάρχουν περιορισμένες διαθέσιμες λύσεις, είτε οι υπάρχουσες λύσεις χρήζουν περαιτέρω διερεύνησης.

Στην πρώτη κατηγορία εντάσσονται τα εξής προβλήματα: (α) το πρόβλημα της αξιολόγησης επενδύσεων που αφορούν σε κτιριακές ανακαινίσεις με στόχο τη βελτίωση της ενεργειακής αποδοτικότητας, (β) το πρόβλημα της εκτίμησης της ενεργειακής εξοικονόμησης δράσεων ανακαινίσης πριν την υλοποίησή τους (a priori) και (γ) το

πρόβλημα της εξομάλυνσης αιχμών φορτίου σε αποκεντρωμένα μικροδίκτυα μέσω της βελτιστοποίησης του προγραμματισμού ευέλικτων φορτίων όπως οι αντλίες ύδρευσης. Για τα συγκεκριμένα προβλήματα έχει εντοπιστεί πως υπάρχουν περιορισμένες αλγοριθμικές λύσεις οι οποίες εκμεταλλεύονται την πληθώρα δεδομένων που υπάρχουν πλέον διαθέσιμα.

Στη δεύτερη κατηγορία εντάσσονται τα εξής προβλήματα: (α) το πρόβλημα της πρόβλεψης παραγωγής Φ/Β συστημάτων, (β) το πρόβλημα της πρόβλεψης κατανάλωσης ενέργειας σε επίπεδο κτιρίου, (γ) το πρόβλημα της βελτιστοποίησης της λειτουργίας μικροδικτύου μέσω προγραμματισμού της λειτουργίας σταθμών ηλεκτρικής φόρτισης και συστημάτων αποθήκευσης ενέργειας. Σε αυτά τα προβλήματα υπάρχουν ήδη αρκετές διαθέσιμες λύσεις στη βιβλιογραφία, ωστόσο οι προτεινόμενες λύσεις είτε επιτυγχάνουν προβλέψεις καλύτερης ακρίβειας, είτε προσεγγίζουν τα προβλήματα από διαφορετική οπτική εκμεταλλευόμενες τα διαθέσιμα δεδομένα.



Σχήμα 1.4: Οι τρεις επιμέρους κατηγορίες των μοντέλων της Διδακτορικής Διατριβής

Οι λύσεις που προτείνονται στην παρούσα Διδακτορική Διατριβή απευθύνονται σε προβλήματα που μπορούν να κατηγοριοποιηθούν σε τρεις επιμέρους κατηγορίες όπως παρουσιάζεται στο Σχήμα 1.4. Οι κατηγορίες αυτές είναι η καταναμημένη παραγωγή, η ενεργειακή αποδοτικότητα κτιρίων και η ευελιξία μικροδικτύων και παρουσιάζονται αναλυτικότερα ακολουθώντας:

- **Καταναμημένη Παραγωγή και ΑΠΕ (AI-4-RES):** Σε αυτή την κατηγορία η έμφαση δίνεται στην ανάπτυξη προβλεπτικών μοντέλων για την παραγωγή ηλεκτρικής ενέργειας. Πιο συγκεκριμένα, η Διδακτορική Διατριβή εστιάζει

στο πρόβλημα της πρόβλεψης παραγωγής ενέργειας από Φ/Β συστήματα (Κεφάλαια 5 και 6). Εξετάζονται διαφορετικά μοντέλα MM και BM, διαφορετικοί χρονικοί ορίζοντες πρόβλεψης (μοντέλα για βραχυπρόθεσμες και μεσοπρόθεσμες προβλέψεις) καθώς και τα καταλληλότερα χαρακτηριστικά που πρέπει να ενσωματωθούν στα μοντέλα. Επίσης, εξετάζεται η ειδική περίπτωση πρόβλεψης παραγωγής Φ/Β συστημάτων υπό καθεστώς έλλειψης δεδομένων με τη χρήση μεταφοράς μάθησης.

- **Ενεργειακή Αποδοτικότητα Κτιρίων (AI-4-ENEF)**: Η κατηγορία αυτή αφορά στην ανάπτυξη μοντέλων που στοχεύουν στην αξιολόγηση δράσεων ενεργειακής αποδοτικότητας σε κτίρια. Τα μοντέλα αυτά διακλαδίζονται σε μοντέλα που προβλέπουν την ενεργειακή εξοικονόμηση πριν την πραγματοποίηση της δράσης (a-priori) βασισμένα σε ιστορικά δεδομένα και σε μοντέλα που εκτιμούν την πραγματική εξοικονόμηση μιας δράσης ανακαίνισης αφού πραγματοποιηθεί (ex-ante). Στο πλαίσιο της ex-ante ανάλυσης αναπτύσσονται προβλεπτικά μοντέλα για την ενεργειακή κατανάλωση σε επίπεδο κτιρίου. Επιπλέον, παρουσιάζεται ένα μοντέλο αξιολόγησης επενδύσεων ανακαίνισης σε κτίρια το οποίο λαμβάνει υπόψιν τόσο την ενεργειακή εξοικονόμηση που επιτυγχάνεται, όσο και την οικονομική συνιστώσα του προβλήματος (Κεφάλαια 7 και 8).
- **Ευελιξία Μικροδικτύων (AI-4-FLEX)**: Η κατηγορία αυτή επικεντρώνεται στην κατασκευή αλγορίθμων βελτιστοποίησης για την βέλτιστη χρήση και αξιοποίηση κατανεμημένων ενεργειακών πόρων, όπως σταθμών ηλεκτρικής φόρτισης, συστημάτων αποθήκευσης ενέργειας, αντλιών άρδευσης και συστημάτων θέρμανσης και εξαερισμού κτιρίων μεταξύ άλλων. Ο σκοπός αυτών των αλγορίθμων είναι να προτείνουν το βέλτιστο προγραμματισμό της λειτουργίας αυτών των πόρων για να επιτευχθεί έξυπνη ενεργειακή διαχείριση σε επίπεδο μικροδικτύου. Μάλιστα, αξιοποιούν το αποτέλεσμα των άλλων δύο συνιστωσών όπως τις προβλέψεις για Φ/Β συστημάτων παραγωγής και τις προβλέψεις για την κατανάλωση κτιρίων (Κεφάλαια 9 και 10).

2ο Επίπεδο Συμβολής: Ενιαίο πλαίσιο ανάπτυξης μοντέλων και αλγορίθμων για ενεργειακά προβλήματα επιμέρους κατηγοριών: κατάταξη, παλινδρόμηση, πρόβλεψη και βελτιστοποίηση.

Στο πλαίσιο της Διδακτορικής Διατριβής ακολουθείται ένα ολοκληρωμένο πλαίσιο αντιμετώπισης προβλημάτων μάθησης και βελτιστοποίησης με συγκεκριμένες προεκτάσεις σε κάθε κατηγορία προβλημάτων. Είναι δεδομένο πως κάθε κατηγορία προβλημάτων έχει ιδιαιτερότητες που καθιστούν αναγκαία την ύπαρξη ενός συγκεκριμένου πλαισίου αντιμετώπισης της. Για παράδειγμα, ένα πρόβλημα πρόβλεψης απαιτεί διαφορετικό χειρισμό και έχει ξεχωριστά επιμέρους βήματα από ένα πρόβλημα ταξινόμησης ή βελτιστοποίησης.

Επομένως, στην παρούσα Διδακτορική Διατριβή προτείνεται ένα πλαίσιο αντιμετώπισης προβλημάτων μάθησης και βελτιστοποίησης που αποτελείται από 4 συνιστώσες οι οποίες παρουσιάζονται παρακάτω:

- **Συνιστώσα 1 “Problem Setting”**: Αφορά στην επιλογή του προβλήματος προς επίλυση, η οποία είναι καθοριστική για τα βήματα που θα ακολουθηθούν. Ένα πρόβλημα μπορεί να ανήκει στην κατηγορία της παλινδρόμησης, της κατάταξης, της πρόβλεψης ή της βελτιστοποίησης. Κάθε μια από αυτές τις κατηγορίες

απαιτεί διαφορετικό χειρισμό όσον αφορά τις ενέργειες που ακολουθούν έως ότου παραχθεί το αποτέλεσμα. Η συνιστώσα αυτή επίσης περιλαμβάνει την εισαγωγή των δεδομένων στα οποία βασίζεται το πρόβλημα προς επίλυση.

- **Συνιστώσα 2 “Feature Engineering”**: Περιλαμβάνει την επιλογή των καταλληλότερων χαρακτηριστικών εισόδου για το πρόβλημα προς επίλυση. Σύμφωνα με την προτεινόμενη μεθοδολογία, η επιλογή των χαρακτηριστικών ή μεταβλητών εισόδου βασίζεται σε επιμέρους βήματα που περιλαμβάνουν την οπτικοποίηση των δεδομένων, τη στατιστική ανάλυση πάνω στα δεδομένα και τη μελέτη συσχετίσεων μεταξύ των διαφορετικών μεταβλητών. Όλα αυτά τελικά οδηγούν στην επιλογή των καταλληλότερων χαρακτηριστικών με στόχο την αύξηση της επίδοσης των μοντέλων μάθησης και των αλγορίθμων βελτιστοποίησης.
- **Συνιστώσα 3 “Pre-processing and Fine-tuning”**: Αφορά στα βήματα που πρέπει να πραγματοποιηθούν πριν την εκπαίδευση των μοντέλων. Αυτά τα βήματα περιλαμβάνουν την προ-επεξεργασία των δεδομένων προκειμένου να βρεθούν στην κατάλληλη μορφή για να δοθούν ως είσοδος στο μοντέλο μάθησης ή στον αλγόριθμο βελτιστοποίησης, όπως επίσης και τη διαδικασία εύρεσης των κατάλληλων υπερπαραμέτρων των μοντέλων. Αυτό είναι ένα πολύ σημαντικό βήμα για την εξασφάλιση της βέλτιστης λειτουργίας των μοντέλων και κατά συνέπεια της επίτευξης καλής ακρίβειας στα αποτελέσματα. Επιπλέον, η συνιστώσα αυτή περιλαμβάνει την εύρεση των κατάλληλων μετρικών για την αξιολόγηση των μοντέλων, τα οποία επίσης διαφέρουν ανάλογα με την κατηγορία του προβλήματος.
- **Συνιστώσα 4 “Model Training and Predictions”**: Περιλαμβάνει τη διαδικασία της εκπαίδευσης του μοντέλου μάθησης ή αντίστοιχα την εκτέλεση του αλγορίθμου βελτιστοποίησης. Αφού επιλεγθούν τα μοντέλα, οι μεταβλητές εισόδου, οι υπερπαραμέτροι των μοντέλων και οι μετρικές αξιολόγησης, σύμφωνα με το προτεινόμενο πλαίσιο τα μοντέλα εκπαιδεύονται, συγκρίνονται και αξιοποιούνται για προβλέψεις σε άγνωστα δεδομένα.

3ο Επίπεδο Συμβολής: Εφαρμογή των προτεινόμενων μεθοδολογιών σε προβλήματα με πραγματικά δεδομένα για την επαλήθευση της επιστημονικής ορθότητας τους.

Η διαδικασία της ανάπτυξης μοντέλων μάθησης και αλγορίθμων βελτιστοποίησης είναι άρρηκτα συνδεδεμένη με την επικύρωση και επαλήθευση των παραγόμενων αποτελεσμάτων από τα μοντέλα σε εφαρμογές που περιλαμβάνουν πραγματικά δεδομένα. Στην πραγματικότητα, όπως αναφέρθηκε και στις προηγούμενες παραγράφους, η ύπαρξη όλων αυτών των δεδομένων έχει οδηγήσει στην ανάγκη σχεδίασης καινοτόμων εφαρμογών. Επομένως, όλα τα μοντέλα που αναπτύσσονται στο πλαίσιο της Διδακτορικής Διατριβής εκπαιδεύονται και αξιολογούνται σε πραγματικά δεδομένα.

Πιο συγκεκριμένα, σε καθένα από τα έξι κεφάλαια που παρουσιάζονται οι εφαρμογές ενσωματώνεται μια εκτεταμένη ανάλυση για τα δεδομένα που χρησιμοποιήθηκαν κατά τη διαδικασία της πειραματικής επαλήθευσης. Στο πλαίσιο αυτό, παρουσιάζονται διαφορετικές οπτικοποιήσεις των δεδομένων, πληροφορίες για τη στατιστική τους κατανομή, λεπτομέρειες για την προ-επεξεργασία τους και ενδιαφέροντα ευρήματα που πιθανώς προέκυψαν στη διάρκεια της ανάλυσης τους. Επιπλέον, παρόλο που τα μοντέλα έχουν αρχικά αναπτυχθεί με κριτήριο κάποιο συγκεκριμένο σύνολο δεδομένων, η

τελική μορφή των ανεπτυγμένων εφαρμογών έχει σχεδιαστεί με τέτοιο τρόπο ώστε να επιτρέπει τη γενίκευση με δεδομένα παρόμοιας μορφής.

Τα δεδομένα που έχουν χρησιμοποιηθεί καλύπτουν μια μεγάλη περιοχή των διαθέσιμων δεδομένων στο χώρο της ενέργειας, όντας ετερογενή μεταξύ τους και καλύπτοντας περιπτώσεις τόσο στατικών όσο και δυναμικών δεδομένων, ικανοποιώντας έτσι όλες τις συνιστώσες των 5 Vs που παρουσιάστηκαν στην προηγούμενη παράγραφο. Έχουν αξιοποιηθεί δεδομένα σε μορφή χρονοσειράς, στατικά δεδομένα, σύνολα δεδομένων με μεγαλύτερο ή μικρότερο όγκο, περιπτώσεις με ελλιπή δεδομένα κ.ο.κ. Επίσης, αξίζει να σημειωθεί πως τα δεδομένα που αξιοποιήθηκαν στην παρούσα Διατριβή προέρχονται από πέντε διαφορετικές χώρες (Ελλάδα, Ιταλία, Πορτογαλία, Λετονία, Ισπανία), ενώ έχουν αξιοποιηθεί επίσης βάσεις δεδομένων της Ευρωπαϊκής Ένωσης.

Τα διαθέσιμα δεδομένα ανήκουν στις εξής κατηγορίες: χρονοσειρές παραγωγής από μεγάλα Φ/Β συστήματα, χρονοσειρές παραγωγής από Φ/Β στέγης, χρονοσειρές ηλεκτρικής και θερμικής κατανάλωσης κτιρίων, κατάλογοι επενδύσεων ενεργειακής αποδοτικότητας, δεδομένα συστημάτων άρδευσης, χρονοσειρές κατανάλωσης σε επίπεδο δικτύου, δεδομένα ηλεκτρικών οχημάτων και δεδομένα συστημάτων αποθήκευσης ενέργειας. Κάθε κατηγορία περιλαμβάνει ξεχωριστές ιδιαιτερότητες και απαιτεί διαφορετικό τρόπο επεξεργασίας, όπως θα παρουσιαστεί στα επόμενα κεφάλαια της Διατριβής. Όμως, όλα αυτά τα δεδομένα συνδυασμένα δίνουν τη δυνατότητα παροχής ευφών λύσεων και εφαρμογών για τη βελτιστοποίηση στον τομέα της ενεργειακής διαχείρισης και αποδοτικότητας.

4ο Επίπεδο Συμβολής: Ανάπτυξη και προσαρμογή καινοτόμων μεθόδων μάθησης σε προβλήματα στον τομέα της ενέργειας και των κτιρίων: Meta-Learning, Online Learning, Transfer Learning.

Η ΤΝ αντιμετωπίζει το πρόβλημα της δημιουργίας υπολογιστικών μοντέλων που βελτιώνονται αυτόματα μέσω της εμπειρίας, όντας ένας από τους πιο ταχέως αναπτυσσόμενους τεχνικούς τομείς στην εποχή μας, αποτελώντας σημείο τομής της επιστήμης των υπολογιστών, της στατιστικής και της επιστήμης δεδομένων ([Jordan and Mitchell, 2015](#)). Την τελευταία δεκαετία έχει επιτευχθεί μεγάλη πρόοδος σε όλους τους τομείς της ΤΝ, λόγω της ανάπτυξης νέων αλγορίθμων και νέων θεωριών μάθησης. Η πρόσφατη πρόοδος στη ΜΜ οφείλεται τόσο στην ανάπτυξη νέων αλγορίθμων και θεωριών εκμάθησης όσο και στη συνεχιζόμενη έκρηξη στη διαθεσιμότητα δεδομένων και στη μείωση του κόστους και του χρόνου υπολογισμού ([Sze et al., 2017](#)).

Σε αυτό το πλαίσιο, το τελευταίο επίπεδο συμβολής της Διδακτορικής Διατριβής αποτελείται από την διερεύνηση, την ανάπτυξη και την προσαρμογή καινοτόμων μεθόδων μάθησης σε απαιτητικά ενεργειακά προβλήματα. Πιο συγκεκριμένα, εφαρμόζονται και αξιολογούνται διεξοδικά οι τεχνικές της μετα-μάθησης (*meta-learning*), της online μάθησης (*online/incremental learning*) και της μεταφοράς μάθησης (*transfer learning*).

Η τεχνική του **meta-learning** αφορά τη χρήση αλγορίθμων ΜΜ οι οποίοι μαθαίνουν πώς να συνδυάζουν με βέλτιστο τρόπο τις προβλέψεις από άλλους αλγόριθμους ΜΜ. Αυτό σημαίνει πως τα μοντέλα meta-learning απαιτούν την ανάπτυξη άλλων μοντέλων μάθησης που έχουν ήδη εκπαιδευτεί σε δεδομένα. Το meta-learning χρησιμοποιείται με στόχο την αύξηση της προβλεπτικής ακρίβειας των μοντέλων και έχει αξιοποιηθεί με επιτυχία σε πολλούς τομείς. Στην παρούσα Διδακτορική Διατριβή η τεχνική του meta-learning χρησιμοποιείται στο πρόβλημα της πρόβλεψης παραγωγής από Φ/Β συστήματα (**Κεφάλαιο 5**), στο πρόβλημα της πρόβλεψης της ηλεκ-

τρικής κατανάλωσης (**Κεφάλαιο 7**) και στο πρόβλημα της αξιολόγησης επενδύσεων ανακαίνισης στον κτιριακό τομέα (**Κεφάλαιο 8**).

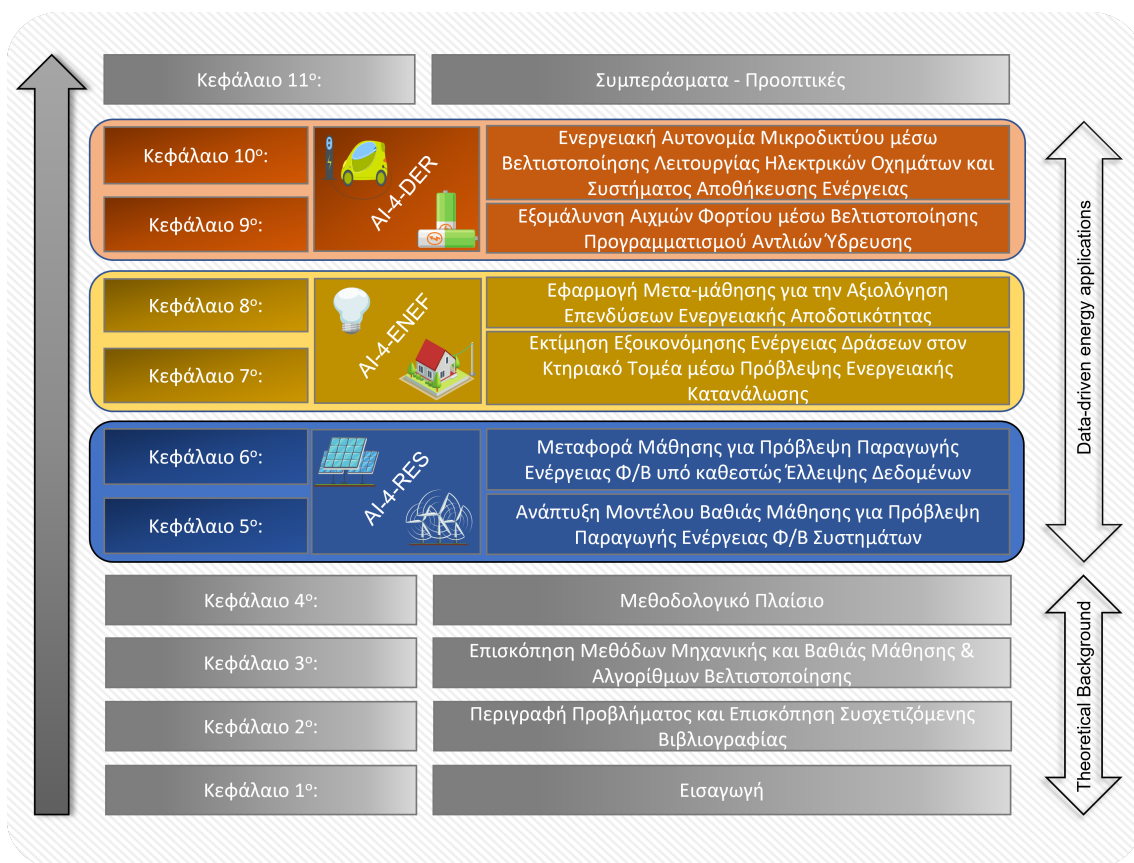
Το **online/incremental learning** είναι ένας κλάδος της MM που περιλαμβάνει την επεξεργασία συνόλων δεδομένων που εισέρχονται ως ροές δεδομένων (data streams) σε πραγματικό χρόνο έχοντας ελάχιστη έως καθόλου γνώση της κατανομής των δεδομένων. Στο online learning τα δεδομένα εισόδου χρησιμοποιούνται συνεχώς για την επέκταση των γνώσεων του υπάρχοντος μοντέλου, βοηθώντας στην περαιτέρω εκπαίδευση του μοντέλου επαυξητικά. Στην παρούσα Διατριβή αξιολογείται η τεχνική του online learning για την πρόβλεψη της παραγωγής Φ/Β συστημάτων και της κατανάλωσης κτιρίων (**Κεφάλαιο 10**) και συγκρίνεται η επίδοση των επαυξητικά εκπαιδευμένων μοντέλων με τα μοντέλα που έχουν εκπαιδευτεί μια φορά και χρησιμοποιούνται offline ([Sarmas et al., 2022c](#)).

Η τεχνική του **transfer learning** εφαρμόζεται σε περιπτώσεις όπου για ένα πρόβλημα δεν υπάρχουν επαρκή δεδομένα εκπαίδευσης. Ως συνέπεια, εξετάζονται δεδομένα παρόμοιων προβλημάτων, αναπτύσσονται μοντέλα για αυτά τα προβλήματα και τα μοντέλα μεταφέρονται στο πρόβλημα με τα ανεπαρκή δεδομένα. Η μεταφορά μάθησης έχει γενικά αξιοποιηθεί για προβλήματα σε πολλούς τομείς. Στο πλαίσιο της Διατριβής, εξετάζεται η τεχνική της μεταφοράς μάθησης σε προβλήματα πρόβλεψης Φ/Β συστημάτων υπό καθεστώς έλλειψης δεδομένων (**Κεφάλαιο 6**). Τα αποτελέσματα αυτής της έρευνας ήταν πολύ ενθαρρυντικά, αναδεικνύοντας τη μεταφορά μάθησης ως μια πολύ αξιόπιστη τεχνική για το συγκεκριμένο πρόβλημα ([Sarmas et al., 2022a](#)).

Τέλος, όλα τα μοντέλα αναπτύχθηκαν με χρήση της γλώσσας προγραμματισμού Python και με τη βοήθεια βιβλιοθηκών MM και BM, ενδεικτικά των *Scikit-Learn*, *Tensorflow Keras* και *PyTorch*. Αντίστοιχα τα μοντέλα βελτιστοποίησης αναπτύχθηκαν με τη βοήθεια αντίστοιχων βιβλιοθηκών όπως το πακέτο *MIP* της *Python*.

1.4 Δομή Διδακτορικής Διατριβής

Η Διδακτορική Διατριβή αποτελείται από έντεκα (11) Κεφάλαια, όπως απεικονίζεται στο Σχήμα 1.5. Το παρόν Κεφάλαιο αποτελεί την Εισαγωγή της Διατριβής, τα Κεφάλαια 3 έως 4 παρουσιάζουν το θεωρητικό υπόβαθρο, τις μεθόδους και την προτεινόμενη μεθοδολογική προσέγγιση, τα Κεφάλαια 5 έως 10 περιλαμβάνουν τις πειραματικές εφαρμογές σε 6 διαφορετικά προβλήματα, ενώ τέλος το Κεφάλαιο 11 παρουσιάζει τα συμπεράσματα της Διατριβής και τις μελλοντικές προεκτάσεις.



Σχήμα 1.5: Δομή της Διδακτορικής Διατριβής

Πιο αναλυτικά το περιεχόμενο καθενός από τα Κεφάλαια της Διατριβής περιγράφεται παρακάτω:

Κεφάλαιο 1ο: Εισαγωγή

Αποτελεί το παρόν Κεφάλαιο της Διδακτορικής Διατριβής, στο οποίο παρουσιάζεται συνοπτικά το πρόβλημα και στηρίζεται η ανάγκη ανάπτυξης μεθόδων ΤΝ και αλγορίθμων βελτιστοποίησης για την υποστήριξη αποφάσεων σε προβλήματα διαχείρισης ενέργειας και ενεργειακής αποδοτικότητας. Επιπλέον, στο Κεφάλαιο αυτό παρουσιάζεται το αντικείμενο, ο στόχος και η συμβολή της Διατριβής.

Κεφάλαιο 2ο: Επισκόπηση Μεθόδων Τεχνητής Νοημοσύνης & Αλγορίθμων Βελτιστοποίησης

Λαμβάνοντας υπόψη την ανάλυση του Κεφαλαίου 3 της Διατριβής και της ανάγκης που απορρέει για την ανάπτυξη κατάλληλων μοντέλων και ολοκληρωμένων λύσεων για το κάθε πρόβλημα, στο Κεφάλαιο 2 περιγράφονται οι επιστημονικές περιοχές, στις

οποίες έγκειται η προτεινόμενη μεθοδολογία. Πιο συγκεκριμένα, στο Κεφάλαιο 2 παρουσιάζεται μια εκτενής περιγραφή του επιστημονικού κλάδου της TN, με έμφαση σε αλγορίθμους MM και BM. Επίσης, πραγματοποιείται αναφορά στους αλγορίθμους βελτιστοποίησης, οι οποίοι αποτελούν βασικό τμήμα της λύσης για ορισμένα προβλήματα διαχείρισης ενέργειας. Το Κεφάλαιο αυτό αποτελεί το θεωρητικό υπόβαθρο των αλγορίθμων που χρησιμοποιούνται στις επιμέρους πρακτικές εφαρμογές των Κεφαλαίων 5 έως 10. Αξίζει όμως να σημειωθεί πως αναλυτικότερη περιγραφή των εξειδικευμένων χρησιμοποιούμενων μοντέλων πραγματοποιείται σε κάθε επιμέρους Κεφάλαιο πριν την παρουσίαση των αποτελεσμάτων.

Κεφάλαιο 3ο: Διατύπωση Προβλήματος και Επισκόπηση Συσχετιζόμενης Βιβλιογραφίας

Σε συνέχεια της σύντομης παρουσίασης του προβλήματος στο Κεφάλαιο της Εισαγωγής, το Κεφάλαιο 3 αναλύει διεξοδικά το υπόβαθρο των προβλημάτων διαχείρισης ενέργειας που μπορούν να επιλυθούν με τη χρήση μεθόδων TN. Το Κεφάλαιο 3 παρουσιάζει τα κυριότερα ενεργειακά προβλήματα που αντιμετωπίζονται με τη βοήθεια της TN και τα κατατάσσει στους τρεις πυλώνες που παρουσιάστηκαν στην παραπάνω ενότητα. Επιπλέον, για κάθε πρόβλημα παρουσιάζεται η συσχετιζόμενη βιβλιογραφία, ακολουθούμενες πρακτικές, αλλά και ο τρόπος με τον οποίο η TN έχει συμβάλλει στην αποτελεσματικότερη αντιμετώπιση του εκάστοτε προβλήματος.

Κεφάλαιο 4ο: Περιγραφή Επιμέρους Προβλημάτων, Στάδια Ανάπτυξης Μοντέλων & Προτεινόμενη Αρχιτεκτονική

Στο Κεφάλαιο 4 παρουσιάζεται το μεθοδολογικό πλαίσιο για την ανάπτυξη των αλγορίθμων και μοντέλων TN για προβλήματα που σχετίζονται με την κατανομημένη παραγωγή ενέργειας, τη διαχείριση ενέργειας και την ευελιξία μικροδικτύων και την ενεργειακή αποδοτικότητα κτιρίων. Το προτεινόμενο πλαίσιο έχει σχεδιαστεί με σκοπό να υποστηρίξει διαφορετικά ενδιαφερόμενα μέρη στον ενεργειακό τομέα κατά τη διαδικασία ανάπτυξης αποτελεσματικών αλγορίθμων και μοντέλων. Το προτεινόμενο πλαίσιο καλύπτει τα στάδια ανάπτυξης μοντέλων και αλγορίθμων μάθησης καθώς και την αρχιτεκτονική των μοντέλων TN, η οποία περιλαμβάνει όλα τα απαιτούμενα επίπεδα όπως η διαχείριση των δεδομένων, των μοντέλων και των αποτελεσμάτων.

Κεφάλαιο 5ο: Μοντέλο Βαθιάς Μάθησης για την Πρόβλεψη Παραγωγής Φ/Β Συστημάτων

Στο Κεφάλαιο 5 παρουσιάζεται μια μεθοδολογία μετα-μάθησης που συνδυάζει δυναμικά τις βασικές προβλέψεις πολλαπλών μοντέλων BM με στόχο την εκμάθηση των συνθηκών υπό τις οποίες κάθε μοντέλο αναμένεται να αποδώσει καλύτερα και, με βάση αυτή τη διαδικασία μάθησης, τη βελτίωση της συνολικής ακρίβειας πρόβλεψης. Πιο συγκεκριμένα, αναπτύσσονται τέσσερα baseline μοντέλα Long Short-Term Memory (LSTM) διαφορετικών αρχιτεκτονικών και παράγονται προβλέψεις παραγωγής ενέργειας Φ/Β συστημάτων σε βραχυπρόθεσμο ορίζοντα, χωρίς να χρησιμοποιούμε αρνητικές προβλέψεις καιρού, με στόχο την επιτάχυνση της διαδικασίας εκπαίδευσης και την ενίσχυση της αξιοπιστίας της προτεινόμενης λύσης. Επιπλέον, αξιολογείται η ακρίβεια του μοντέλου μετα-μάθησης χρησιμοποιώντας τρία Φ/Β συστήματα που βρίσκονται στη Λισαβόνα της Πορτογαλίας. Τα αποτελέσματά μας επιβεβαιώνουν ότι διαφορετικά baseline μοντέλα αποδίδουν καλύτερα σε διαφορετικά Φ/Β συστή-

ματα, γεγονός που υποδηλώνει ότι η μετα-μάθηση μπορεί να βελτιώσει σημαντικά την ακρίβεια, ειδικά κατά τις ώρες αιχμής της Φ/Β παραγωγής.

Κεφάλαιο 6ο: Τεχνικές Μεταφοράς Μάθησης για την Πρόβλεψη Παραγωγής Φ/Β υπό καθεστώς Έλλειψης Δεδομένων

Στο Κεφάλαιο 6 εξετάζεται η τεχνική της μεταφοράς μάθησης. Αναλυτικότερα, χρησιμοποιείται το μοντέλο LSTM με τρεις στρατηγικές μεταφοράς μάθησης για να παρέχει ακριβείς προβλέψεις παραγωγής Φ/Β συστημάτων. Η μεταφορά μάθησης χρησιμοποιείται τόσο για την αρχικοποίηση των βαρών του μοντέλου LSTM, όσο και για την εξαγωγή χαρακτηριστικών, χρησιμοποιώντας διαφορετικές προσεγγίσεις μεταφοράς μάθησης σε κάθε περίπτωση. Οι προαναφερθείσες στρατηγικές μεταφοράς μάθησης συγκρίνονται με ένα συμβατικό μοντέλο μάθησης χωρίς μεταφορά, καθώς και με το μοντέλο smart persistence που αποτελεί το πιο ευρέως αποδεκτό μοντέλο σύγκρισης. Η εφαρμογή αξιολογείται στο πρόβλημα της πρόβλεψης της ωριαίας παραγωγής έξι Φ/Β συστημάτων, ενώ τα αποτελέσματα αποδεικνύουν ότι τα μοντέλα μεταφοράς μάθησης υπερτερούν σημαντικά των συμβατικών, επιτυγχάνοντας βελτίωση ακρίβειας 12,6% όσον αφορά το μέσο τετραγωνικό σφάλμα και 16,3% ως προς τον δείκτη ακρίβειας πρόβλεψης με δεδομένα εκπαίδευσης 1 έτους. Το χάσμα μεταξύ των δύο προσεγγίσεων γίνεται ακόμη μεγαλύτερο όταν υπάρχουν λιγότερα διαθέσιμα δεδομένα εκπαίδευσης (ειδικά στην περίπτωση δεδομένων εκπαίδευσης διάρκειας τριών μηνών), ανοίγοντας νέους δρόμους στην πρόβλεψη παραγωγής ενέργειας των νεοεγκατασταθέντων Φ/Β εγκαταστάσεων και καθιστώντας τη μεταφορά μάθησης ένα αξιόπιστο εργαλείο στα χέρια των αυτοπαραγωγών προς τον απώτερο στόχο της ενεργειακής εξισορρόπησης και της διαχείρισης της απόκρισης ζήτησης.

Κεφάλαιο 7ο: Μοντέλο Πρόβλεψης Ενεργειακής Κατανάλωσης Κτιρίων για την Εκτίμηση της Εξοικονόμησης Ενέργειας

Στο Κεφάλαιο 7 εξετάζεται η χρήση μοντέλων TN για την πρόβλεψη της κατανάλωσης ενέργειας σε κτίρια, με στόχο την εκτίμηση της εξοικονόμησης ενέργειας από δράσεις ανακαίνισης. Η ακριβής εκτίμηση της εξοικονόμησης ενέργειας είναι ζωτικής σημασίας για την αποτελεσματική εφαρμογή των μέτρων εξοικονόμησης ενέργειας. Συνεπώς, προτείνουμε ένα μοντέλο ensemble για την ακριβή εκτίμηση της baseline κατανάλωσης ενέργειας, το οποίο βασίζεται σε δένδρικούς αλγορίθμους, και πιο συγκεκριμένα στους Random Forest, XGBoost και LightGBM. Αξίζει να σημειωθεί ότι το μοντέλο μας δίνει έμφαση στην παροχή επεξηγηματικότητας, παρέχοντας διαφάνεια και πληροφορίες σχετικά με τους βασικούς παράγοντες που επηρεάζουν τη βασική ενεργειακή κατανάλωση. Για την επικύρωση της ακρίβειας του, διεξάγουμε πειραματικές αξιολογήσεις σε ένα σύμπλεγμα κτιρίων στη Λετονία. Τα αποτελέσματα καταδεικνύουν την υπεροχή του προτεινόμενου ensemble μοντέλου έναντι των επιμέρους μοντέλων και ακόμη και ενός δικτύου BM προσαρμοσμένου για την εκτίμηση της κατανάλωσης ενέργειας, προσφέροντας μια ισχυρή και ερμηνεύσιμη λύση για την εκτίμηση της εξοικονόμησης ενέργειας στον κτιριακό τομέα.

Κεφάλαιο 8ο: Μοντέλο Μετα-μάθησης για την Αξιολόγηση Επενδύσεων Ενεργειακής Αποδοτικότητας

Στο Κεφάλαιο 8 παρουσιάζεται μια μεθοδολογία η οποία φιλοδοξεί να γεφυρώσει το χάσμα στη χρηματοδότηση έργων ενεργειακής αποδοτικότητας. Η ενεργειακή

αποδοτικότητα των κτιρίων είναι κρίσιμη για την επίτευξη των παγκόσμιων ενεργειακών και κλιματικών στόχων, απαιτώντας ωστόσο σημαντικές επενδύσεις. Λόγω της έλλειψης ώριμων συστημάτων υποστήριξης αποφάσεων και της χρήσης παραδοσιακών επενδυτικών μηχανισμών που εστιάζουν στις οικονομικές πτυχές των έργων ενεργειακής αποδοτικότητας και παραμελούν τις περιβαλλοντικές τους επιπτώσεις, τέτοια έργα ενδέχεται να αντιμετωπίσουν δυσκολίες στη χρηματοδότηση. Στο Κεφάλαιο αυτό, λοιπόν, αξιολογούνται διαφορετικές μέθοδοι ταξινόμησης, οι οποίες έπειτα συνδυάζονται μέσω ενός μοντέλου μετα-μάθησης με στόχο τη βελτίωση της συνολικής απόδοσης ταξινόμησης και τον προσδιορισμό της χρηματοδότησης που πρέπει να λάβει κάθε επένδυση σύμφωνα με τα ιδιαίτερα χαρακτηριστικά της. Η προτεινόμενη μεθοδολογία αξιολογείται χρησιμοποιώντας ένα σύνολο περισσότερων από 300 έργων ανακαίνισης που έχουν ολοκληρωθεί σε κτίρια στη Λετονία. Τα αποτελέσματά υποδεικνύουν ότι το μοντέλο μετα-μάθησης παρουσιάζει καλύτερη ακρίβεια από όλα τα baseline μοντέλα MM, εντοπίζοντας έργα υψηλής και μέσης δυναμικής και διακρίνοντας παράλληλα με επιτυχία έργα χαμηλής δυναμικής.

Κεφάλαιο 9ο: Μοντέλο Βελτιστοποίησης Προγραμματισμού Αντλιών Ύδρευσης για την Εξομάλυνση Αιχμών Φορτίου

Στο Κεφάλαιο 9 παρουσιάζεται μια μέθοδος διαχείρισης ενέργειας που βελτιστοποιεί την κατανάλωση ηλεκτρικής ενέργειας εξομαλύνοντας τις αιχμές κατανάλωσης, μέσω του προγραμματισμού των βέλτιστων ωρών λειτουργίας του αντλητικού συστήματος ύδρευσης ενός μη διασυνδεδεμένου νησιού. Ένα σύνολο μοντέλων MM χρησιμοποιούνται αρχικά για την ακριβή πρόβλεψη της ηλεκτρικής ενέργειας που καταναλώνεται σε επίπεδο νησιού, καθώς και της ενέργειας που παράγεται από ΑΠΕ σε ωριαίο επίπεδο. Στη συνέχεια, οι προβλέψεις αξιοποιούνται από έναν ευριστικό αλγόριθμο βελτιστοποίησης που κατανέμει βέλτιστα τις ώρες λειτουργίας των αντλιών με στόχο την ελαχιστοποίηση των αιχμών κατανάλωσης, ενώ εξετάζονται επίσης περιορισμοί που σχετίζονται με τη λειτουργία των αντλιών. Η απόδοση της προτεινόμενης μεθόδου αξιολογείται λαμβάνοντας υπόψη την περίπτωση ενός απομακρυσμένου ελληνικού νησιού, της Τήλου. Το νησί αυτό περιλαμβάνει ένα σύστημα διαχείρισης ενέργειας που διευκολύνει την παρακολούθηση και τον έλεγχο των τοπικών σταθμών άντλησης νερού που υποστηρίζουν την παροχή νερού και την άρδευση κατοικιών. Τα αποτελέσματα δείχνουν ότι ο έξυπνος προγραμματισμός των αντλιών νερού σε νησιωτικό περιβάλλον μικρής κλίμακας μπορεί να μειώσει την ημερήσια και εβδομαδιαία απόκλιση της κατανάλωσης ηλεκτρικής ενέργειας κατά περισσότερο από 15% χωρίς κανένα χρηματικό κόστος. Συμπεραίνεται, επίσης, ότι τα πιθανά οφέλη της προτεινόμενης προσέγγισης συνδέονται άμεσα με την ποσότητα φορτίου που μπορεί να μετατοπίζεται κάθε μέρα, την ακρίβεια των προβλέψεων που χρησιμοποιούνται και την ποσότητα ηλεκτρικής ενέργειας που παράγεται από τα Φ/Β συστήματα.

Κεφάλαιο 10ο: Μοντέλο Βελτιστοποίησης Λειτουργίας Ηλεκτρικών Οχημάτων και Συστήματος Αποθήκευσης Ενέργειας για την Ενεργειακή Αυτονομία Μικροδικτύου

Στο Κεφάλαιο 10 προτείνεται μια ολοκληρωμένη μεθοδολογία για την υποστήριξη και ενίσχυση της ενεργειακής αυτονομίας σε επίπεδο μικροδικτύου και την αντιμετώπιση του φαινομένου της αντίστροφης ροής ισχύος. Η αντίστροφη ροή ισχύος, η οποία ορίζεται ως η συνεχής ροή ηλεκτρικής ενέργειας σε κατεύθυνση αντίθετη από την κανονική κατεύθυνση της ροής ισχύος σε ένα δίκτυο, εμφανίζεται συνήθως στα μικροδίκτυα

όταν η ενέργεια που παράγεται από τους κατανεμημένους σταθμούς παραγωγής ηλεκτρικής ενέργειας υπερβαίνει την τοπική ζήτηση φορτίου. Το φαινόμενο αυτό ενέχει διάφορους κινδύνους που σχετίζονται με τη μη αποδοτική λειτουργία ή τη βλάβη του εξοπλισμού, την αστάθεια του δικτύου και τις απώλειες ενέργειας. Προκειμένου να μειωθεί η αντίστροφη ροή ισχύος στα μικροδίκτυα και να υποστηριχθεί η ενεργειακή αυτονομία, εισάγουμε έναν αλγόριθμο βασισμένο σε προβλεπτικά μοντέλα. Το πλαίσιο βασίζεται σε μοντέλα βαθιάς μάθησης που προβλέπουν την ηλεκτρική ενέργεια που παράγεται από Φ/Β συστήματα και καταναλώνεται από το μικροδίκτυο και σε έναν αλγόριθμο βελτιστοποίησης που προγραμματίζει τα ευέλικτα φορτία του (ηλεκτρικά οχήματα) με βάση τις εν λόγω προβλέψεις. Πραγματοποιούμε μια μελέτη απόσβεσης για να αξιολογήσουμε την επίδραση που έχει ο βελτιστοποιημένος προγραμματισμός και η αποθήκευση ενέργειας στην αυτονομία του μικροδικτύου, διερευνώντας επίσης την επίδραση διαφορετικών χωρητικοτήτων μπαταριών και μεγεθών στόλου ηλεκτρικών οχημάτων. Τα αποτελέσματά μας υποδεικνύουν ότι η μετατόπιση φορτίου βάσει προβλέψεων μπορεί να μειώσει σημαντικά την αντίστροφη ροή ισχύος, ιδίως για σχετικά μεγαλύτερα ποσά ευέλικτων φορτίων. Επιπλέον, διαπιστώνουμε ότι η αποθήκευση ηλεκτρικής ενέργειας μπορεί να συμπληρώσει τη μετατόπιση φορτίου. Παρ' όλα αυτά, οι βελτιώσεις αυτές υπόκεινται στην ακρίβεια των προβλέψεων και στις δυνατότητες αποθήκευσης.

Κεφάλαιο 11ο: Συμπεράσματα - Προοπτικές

Το Κεφάλαιο 11 της Διατριβής παρουσιάζει τα επιτεύγματα της προτεινόμενης προσέγγισης, που απορρέουν τόσο από την ανάλυση των αρχικών Κεφαλαίων όσο και από τα εμπειρικά αποτελέσματα των πρακτικών εφαρμογών. Τέλος, το Κεφάλαιο αυτό καταλήγει σε μια σειρά από προτάσεις και ιδέες για περαιτέρω ερευνητικές δραστηριότητες που αφορούν στην εφαρμογή της TN σε προβλήματα διαχείρισης ενέργειας και ενεργειακής αποδοτικότητας κτιρίων.

Βιβλιογραφία

- Agreement, P. (2015). Paris agreement. In *Report of the Conference of the Parties to the United Nations Framework Convention on Climate Change (21st Session, 2015: Paris)*. Retrieved December, volume 4, page 2017. HeinOnline.
- Ali, S. S. and Choi, B. J. (2020). State-of-the-art artificial intelligence techniques for distributed smart grids: A review. *Electronics*, 9(6):1030.
- Baidya, S., Potdar, V., Ray, P. P., and Nandi, C. (2021). Reviewing the opportunities, challenges, and future directions for the digitalization of energy. *Energy Research & Social Science*, 81:102243.
- Carley, S. and Konisky, D. M. (2020). The justice and equity implications of the clean energy transition. *Nature Energy*, 5(8):569–577.
- Carvalho, D. V., Pereira, E. M., and Cardoso, J. S. (2019). Machine learning interpretability: A survey on methods and metrics. *Electronics*, 8(8):832.
- Doukas, H. (2022). Energy transitions, intelligence and big data: Towards a prosumer concept with energy autonomy. In *2022 13th International Conference on Information, Intelligence, Systems & Applications (IISA)*, pages 1–5. IEEE.
- Doukas, H., Nikas, A., González-Eguino, M., Arto, I., and Anger-Kraavi, A. (2018). From integrated to integrative: Delivering on the paris agreement. *Sustainability*, 10(7):2299.
- Du, Z., Fan, B., Jin, X., and Chi, J. (2014). Fault detection and diagnosis for buildings and hvac systems using combined neural networks and subtractive clustering analysis. *Building and Environment*, 73:1–11.
- Esmat, A., de Vos, M., Ghiassi-Farrokhfal, Y., Palensky, P., and Epema, D. (2021). A novel decentralized platform for peer-to-peer energy trading market with blockchain technology. *Applied Energy*, 282:116123.
- Friedlingstein, P., O’sullivan, M., Jones, M. W., Andrew, R. M., Hauck, J., Olsen, A., Peters, G. P., Peters, W., Pongratz, J., Sitch, S., et al. (2020). Global carbon budget 2020. *Earth System Science Data*, 12(4):3269–3340.
- Hong, T., Wang, Z., Luo, X., and Zhang, W. (2020). State-of-the-art on research and applications of machine learning in the building life cycle. *Energy and Buildings*, 212:109831.
- Hope, A., Roberts, T., and Walker, I. (2018). Consumer engagement in low-carbon home energy in the united kingdom: Implications for future energy system decentralization. *Energy research & social science*, 44:362–370.
- International Energy Agency and OECD (2017). Digitalization & Energy. Paris, France, <https://www.iea.org/reports/digitalisation-and-energy>.
- IRENA (2015). Renewable Energy Statistics. <https://www.irena.org/publications/2015/Jun/Renewable-Energy-Target-Setting>.
- Jha, S. K., Bilalovic, J., Jha, A., Patel, N., and Zhang, H. (2017). Renewable energy: Present research and future scope of artificial intelligence. *Renewable and Sustainable Energy Reviews*, 77:297–317.
- Jordan, M. I. and Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245):255–260.

- Kroposki, B., Johnson, B., Zhang, Y., Gevorgian, V., Denholm, P., Hodge, B.-M., and Hannegan, B. (2017). Achieving a 100% renewable grid: Operating electric power systems with extremely high levels of variable renewable energy. *IEEE Power and energy magazine*, 15(2):61–73.
- Kuznetsova, E., Ruiz, C., Li, Y.-F., and Zio, E. (2015). Analysis of robust optimization for decentralized microgrid energy management under uncertainty. *International Journal of Electrical Power & Energy Systems*, 64:815–832.
- Lyu, W. and Liu, J. (2021). Artificial intelligence and emerging digital technologies in the energy sector. *Applied Energy*, 303:117615.
- Marinakis, V., Doukas, H., Tsapelas, J., Mouzakitis, S., Sicilia, Á., Madrazo, L., and Sgouridis, S. (2020). From big data to smart energy services: An application for intelligent energy management. *Future Generation Computer Systems*, 110:572–586.
- Marinakis, V., Koutsellis, T., Nikas, A., and Doukas, H. (2021). Ai and data democratisation for intelligent energy management. *Energies*, 14(14):4341.
- Markard, J. (2018). The next phase of the energy transition and its implications for research and policy. *Nature Energy*, 3(8):628–633.
- Moura, R. and Brito, M. C. (2019). Prosumer aggregation policies, country experience and business models. *Energy Policy*, 132:820–830.
- Mourtzis, D., Angelopoulos, J., and Panopoulos, N. (2021). A collaborative approach on energy-based offered services: Energy 4.0 ecosystems. *Procedia CIRP*, 104:1638–1643.
- Papadis, E. and Tsatsaronis, G. (2020). Challenges in the decarbonization of the energy sector. *Energy*, 205:118025.
- Ramos, C. and Liu, C.-C. (2011). Ai in power systems and energy markets. *IEEE Intelligent Systems*, 26(2):5–8.
- Sarmas, E., Dimitropoulos, N., Marinakis, V., Mylona, Z., and Doukas, H. (2022a). Transfer learning strategies for solar power forecasting under data scarcity. *Scientific Reports*, 12(1):1–13.
- Sarmas, E., Dimitropoulos, N., Stropolas, S., Mylona, Z., Marinakis, V., Giannadakis, A., Romaios, A., and Doukas, H. (2022b). A web-based building automation and control service. In *2022 13th International Conference on Information, Intelligence, Systems & Applications (IISA)*, pages 1–6. IEEE.
- Sarmas, E., Stropolas, S., Marinakis, V., Santori, F., Bucarelli, M. A., and Doukas, H. (2022c). An incremental learning framework for photovoltaic production and load forecasting in energy microgrids. *Electronics*, 11(23):3962.
- Sze, V., Chen, Y.-H., Emer, J., Suleiman, A., and Zhang, Z. (2017). Hardware for machine learning: Challenges and opportunities. In *2017 IEEE Custom Integrated Circuits Conference (CICC)*, pages 1–8. IEEE.
- Tamke, M., Nicholas, P., and Zwierzycki, M. (2018). Machine learning for architectural design: Practices and infrastructure. *International Journal of Architectural Computing*, 16(2):123–143.
- Tollefson, J. and Weiss, K. R. (2015). Nations adopt historic global climate accord: agreement commits world to holding warming well below 2 [degrees] c. *Nature*, 582(7582):315–317.

Weigel, P. and Fishedick, M. (2019). Review and categorization of digital applications in the energy sector. *Applied Sciences*, 9(24):5350.

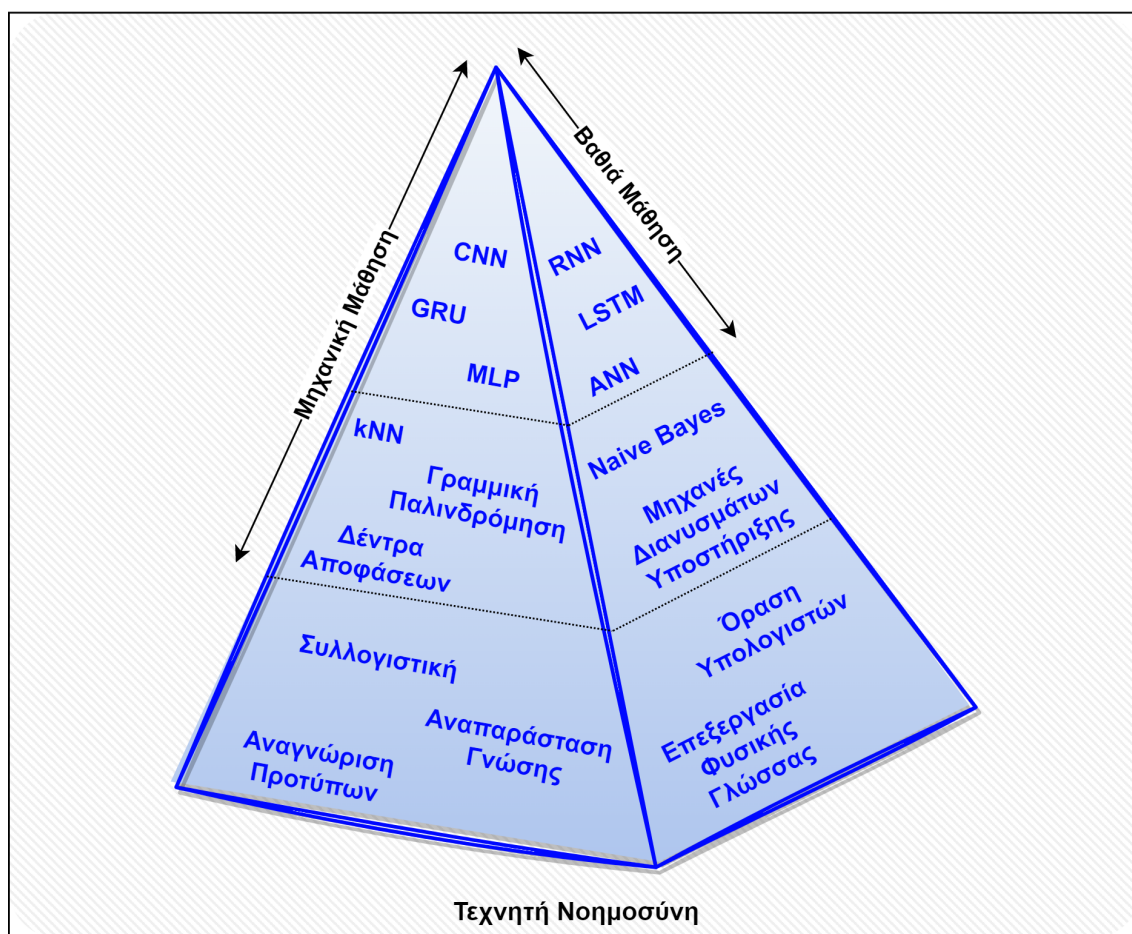
Zafar, R., Mahmood, A., Razzaq, S., Ali, W., Naeem, U., and Shehzad, K. (2018). Prosumer based energy management and sharing in smart grid. *Renewable and Sustainable Energy Reviews*, 82:1675–1684.

Κεφάλαιο 2

Επισκόπηση Μεθόδων Τεχνητής Νοημοσύνης & Αλγορίθμων Βελτιστοποίησης

2.1 Εισαγωγή

Η ΤΝ αναφέρεται σε συστήματα που μιμούνται την ανθρώπινη νοημοσύνη με στόχο την εκτέλεση εργασιών και έχουν την ικανότητα να βελτιώνονται με βάση τις πληροφορίες που συλλέγουν μέσα από περίπλοκες διαδικασίες μάθησης.



Σχήμα 2.1: Επισκόπηση του επιστημονικού πεδίου της ΤΝ.

Στο Κεφάλαιο αυτό πραγματοποιείται μια αναλυτική ανασκόπηση των δημοφιλέστερων αλ-

γορίθμων στον τομέα της ΤΝ και της μαθηματικής βελτιστοποίησης. Αρχικά, στην ενότητα 7.3.2 γίνεται μια επισκόπηση της μηχανικής μάθησης, επεξηγούνται οι διαφορές ανάμεσα στις διαφορετικές κατηγορίες μεθόδων Μηχανικής Μάθησης και παρουσιάζονται οι σημαντικότεροι αλγόριθμοι. Έπειτα, στην ενότητα 2.3 πραγματοποιείται μια εισαγωγή στη Βαθιά Μάθηση και αναλύονται οι σημαντικότερες κατηγορίες νευρωνικών δικτύων: τα δίκτυα πρόσθιας τροφοδότησης, τα συνελικτικά και τα αναδρομικά δίκτυα. Στη συνέχεια, η ενότητα 2.4 περιλαμβάνει μια επισκόπηση των μεθόδων βελτιστοποίησης, μελετώντας τόσο τους αιτιοκρατικούς αλγόριθμους, όσο και τους στοχαστικούς αλγόριθμους βελτιστοποίησης. Τέλος, τα συμπεράσματα και οι προοπτικές του κεφαλαίου συνοψίζονται στην ενότητα 7.5.

2.2 Μηχανική Μάθηση

Η Μηχανική Μάθηση - ΜΜ (*Machine Learning - ML*) είναι μια υποκατηγορία της ΤΝ που επιτρέπει στις υπολογιστικές μηχανές να γίνονται ακριβέστερες στην πρόβλεψη αποτελεσμάτων περίπλοκων προβλημάτων χωρίς να είναι ρητά προγραμματισμένες (Mitchell, 1997). Οι αλγόριθμοι ΜΜ λαμβάνουν και αναλύουν ιστορικά δεδομένα ως είσοδο για να προβλέψουν νέες τιμές εξόδου. Καθώς τροφοδοτούνται νέα δεδομένα σε αυτούς τους αλγόριθμους, μαθαίνουν και βελτιστοποιούν τις λειτουργίες τους για να βελτιώσουν την απόδοση, αναπτύσσοντας ΤΝ με την πάροδο του χρόνου (Jordan and Mitchell, 2015).

Ένας βασικός στόχος ενός αλγόριθμου ΜΜ είναι να γενικεύει από την εμπειρία που αποκτά. Η γενίκευση σε αυτό το πλαίσιο είναι η ικανότητα ενός τέτοιου αλγόριθμου να αποδίδει με ακρίβεια σε νέα, άγνωστα παραδείγματα αφού έχει εκπαιδευτεί σε ένα σύνολο δεδομένων μάθησης. Τα παραδείγματα εκπαίδευσης προέρχονται από κάποια γενικά άγνωστη κατανομή πιθανοτήτων, η οποία θεωρείται αντιπροσωπευτική του χώρου των παραδειγμάτων, και πρέπει να οικοδομηθεί ένα γενικό μοντέλο για αυτόν τον χώρο που να επιτρέπει να παραχθούν ακριβείς προβλέψεις σε νέες περιπτώσεις (Wang et al., 2016).

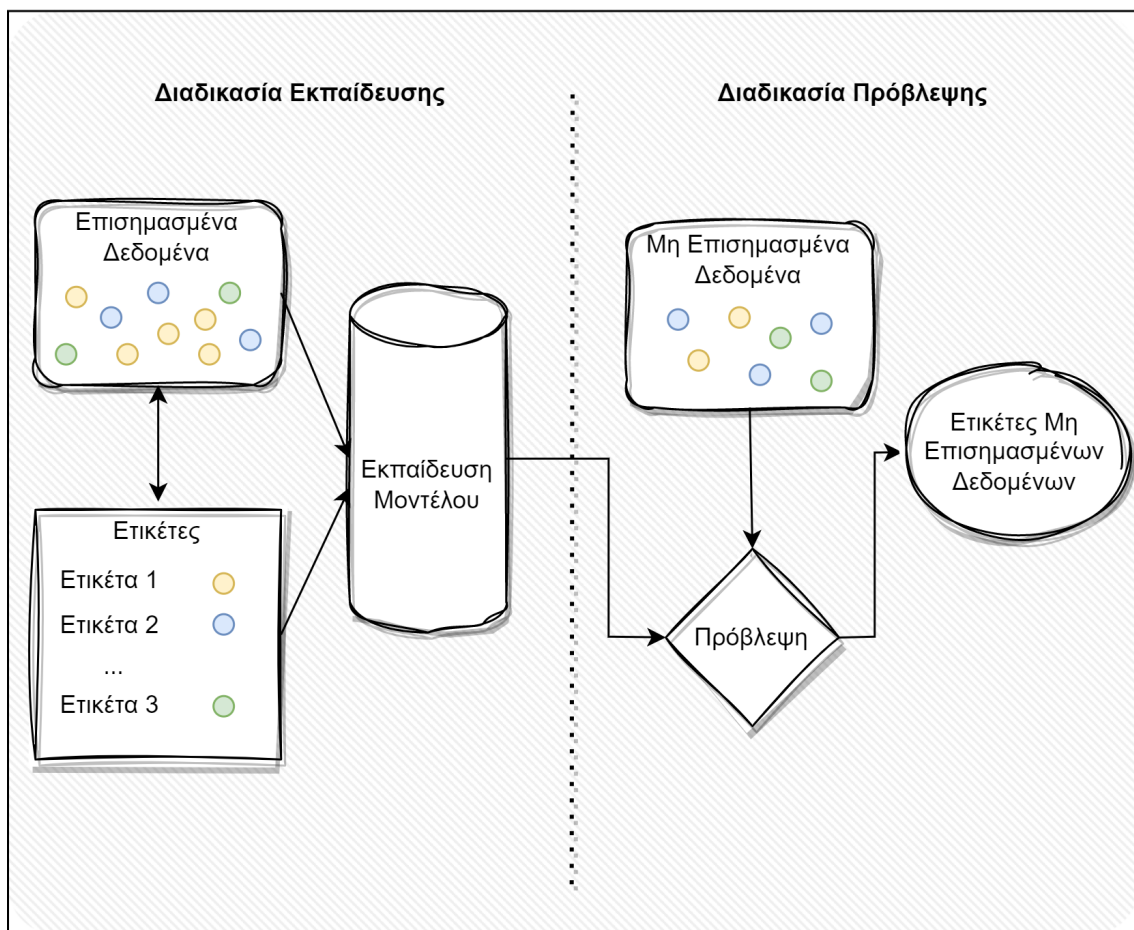
Ιστορικά, ο όρος μηχανική μάθηση πρωτοεμφανίστηκε το 1959 από τον πρωτοπόρο στον τομέα της ΤΝ Arthur Samuel (Samuel, 1959). Ωστόσο, το πρώτο μοντέλο ΜΜ γράφτηκε από τον ίδιο 7 χρόνια νωρίτερα, το 1952, και αφορούσε την ανάλυση της στρατηγικής για τις επόμενες κινήσεις του υπολογιστή στο παιχνίδι ντάμα. Το πρώτο Τεχνητό Νευρωνικό Δίκτυο - ΤΝΔ (*Artificial Neural Network - ANN*) αναπτύχθηκε το 1957 από τον Frank Rosenblatt, με σκοπό να προσομοιώνει τις διαδικασίες σκέψης του ανθρώπινου εγκεφάλου (Rosenblatt, 1957). Το ΤΝΔ αυτό είναι γνωστό με το όνομα perceptron και θα παρουσιαστεί πιο αναλυτικά στο επόμενο κεφάλαιο της Βαθιάς Μάθησης - ΒΜ (*Deep Learning - DL*). Μια ακόμη ριζοσπαστική εξέλιξη στον τομέα της μηχανικής μάθησης πραγματοποιήθηκε το 1967 με τη δημιουργία του αλγόριθμου των πλησιέστερων γειτόνων, που σηματοδότησε την απαρχή της αναγνώρισης προτύπων με χρήση υπολογιστών (Cover and Hart, 1967). Ωστόσο, η έλλειψη προόδου στον τομέα του υλικού και η περιορισμένη υπολογιστική ισχύς οδήγησαν σε μια μεγάλη περίοδο στασιμότητας κατά τη δεκαετία του 1980. Η περίοδος αυτή ονομάστηκε “χειμώνας της ΜΜ” (Schuchmann, 2019). Από τη δεκαετία του 1990 κι έπειτα υπήρξε μια στροφή στον τομέα της ΜΜ, η οποία από βασισμένη στη γνώση (*knowledge-driven*) μεταστράφηκε σε βασισμένη στα δεδομένα (*data-driven*) (Negnevitsky, 2005). Οι επιστήμονες ξεκίνησαν να δημιουργούν προγράμματα για να αναλύουν μεγάλες ποσότητες δεδομένων και να εξάγουν συμπεράσματα μαθαίνοντας από τα δεδομένα. Εκείνη την περίοδο έγιναν πολύ δημοφιλείς οι μηχανές διανυσμάτων υποστήριξης και τα ΤΝΔ. Φτάνοντας στην τελευταία δεκαετία και με την πρόοδο στην διαθέσιμη υπολογιστική ισχύ να είναι εξαιρετικά γρήγορη, αναπτύχθηκε ευρέως η ΒΜ με τη δημιουργία πολυ-επίπεδων ΤΝΔ, τα οποία θα παρουσιαστούν στο υποκεφάλαιο της ΒΜ.

Υπάρχουν τρεις βασικές κατηγορίες αλγορίθμων ΜΜ: αλγόριθμοι επιβλεπόμενης μάθησης, αλγόριθμοι μη επιβλεπόμενης μάθησης και αλγόριθμοι ενισχυτικής μάθησης. Επίσης, υπάρχει η κατηγορία της ημι-επιβλεπόμενης μάθησης, για την οποία δε θα γίνει περαιτέρω ανάλυση καθώς συναντάται αρκετά σπάνια (Zhu, 2005). Οι τρεις βασικές κατηγορίες αναλύονται λεπτομερώς στις παρακάτω παραγράφους.

2.2.1 Μέθοδοι Επιβλεπόμενης Μάθησης

Η Επιβλεπόμενη Μάθηση (*Supervised Learning*) είναι μια κατηγορία ΜΜ κατά την οποία ένα μοντέλο εκπαιδεύεται χρησιμοποιώντας επισημασμένα (*labeled*) δεδομένα εκπαίδευσης και βάσει αυτών των δεδομένων προβλέπει την έξοδο (Cunningham et al., 2008). Η ύπαρξη επισημασμένων δεδομένων προϋποθέτει πως για τα δεδομένα αυτά υπάρχει διαθέσιμη η σωστή έξοδος. Στην επιβλεπόμενη μάθηση τα δεδομένα εκπαίδευσης που δίδονται στο μοντέλο έχουν το ρόλο του επιβλέποντα που δίνει την ευκαιρία στο μοντέλο να μάθει να προβλέπει σωστά την έξοδο μιας άγνωστης εισόδου (Hastie et al., 2009a). Ο στόχος των μοντέλων επιβλεπόμενης μάθησης είναι να σχηματίσουν μια συνάρτηση η οποία χαρτογραφεί τη μεταβλητή εισόδου (x) με τη μεταβλητή εξόδου (y).

Όπως παρουσιάζεται στο Σχήμα 2.2, τα μοντέλα επιβλεπόμενης μάθησης εκπαιδεύονται με χρήση επισημασμένων δεδομένων με ετικέτα, ώστε το μοντέλο να μάθει τα χαρακτηριστικά για κάθε τύπο δεδομένων. Μετά την ολοκλήρωση της διαδικασίας εκπαίδευσης, το μοντέλο αξιολογείται σε ένα σύνολο άγνωστων δεδομένων (*test data*) για τα οποία προσπαθεί να προβλέψει την πραγματική τους τιμή. Θεωρητικά το μοντέλο πρέπει να έχει εκπαιδευτεί σε ένα σύνολο από διαφορετικά μοτίβα δεδομένων εισόδου ώστε να μπορεί να προβλέψει με υψηλή ακρίβεια την έξοδο των άγνωστων δεδομένων (Suthaharan, 2016a).



Σχήμα 2.2: Η διαδικασία της Επιβλεπόμενης Μάθησης.

Σύμφωνα με τους Caruana and Niculescu-Mizil (2006) τα μοντέλα επιβλεπόμενης μάθησης χωρίζονται σε μοντέλα ταξινόμησης (*classification*) και μοντέλα παλινδρόμησης (*regression*), ενώ επίσης μπορούμε να διακρίνουμε και την κατηγορία των μοντέλων πρόβλεψης (*forecasting*). Τα τρία αυτά προβλήματα παρουσιάζονται παρακάτω:

- Ταξινόμηση: Στα προβλήματα ταξινόμησης, το μοντέλο ΜΜ πρέπει να εξάγει και να καθορίσει σε ποια κατηγορία ανήκουν οι νέες παρατηρήσεις ως συμπέρασμα από τις

παρατηρούμενες παρατηρήσεις (Kotsiantis et al., 2006). Ένα τέτοιο παράδειγμα είναι το φίλτράρισμα μηνυμάτων ηλεκτρονικού ταχυδρομείου ως «ανεπιθύμητα» ή «μη ανεπιθύμητα», όπου το μοντέλο πρέπει να εξετάζει τα υπάρχοντα δεδομένα παρατήρησης και να φιλτράρει ανάλογα τα μηνύματα ηλεκτρονικού ταχυδρομείου.

- Παλινδρόμηση: Στα προβλήματα παλινδρόμησης, το μοντέλο MM πρέπει να εκτιμήσει και να κατανοήσει τις σχέσεις μεταξύ των μεταβλητών (Maulud and Abdulazeez, 2020). Η ανάλυση παλινδρόμησης εστιάζει σε μια εξαρτημένη μεταβλητή και σε μια σειρά από άλλες μεταβαλλόμενες μεταβλητές καθιστώντας την ιδιαίτερα χρήσιμη για την πρόβλεψη και την πρόβλεψη.
- Πρόβλεψη: Η πρόβλεψη είναι η διαδικασία της εκτίμησης μελλοντικών τιμών με βάση τα δεδομένα του παρελθόντος και του παρόντος και χρησιμοποιείται συνήθως για την ανάλυση των τάσεων, της εποχικότητας και της κυκλικότητας σε προβλήματα χρονοσειρών (Petropoulos et al., 2022).

Αξίζει να σημειωθεί ότι υπάρχουν επίσης μοντέλα ημι-επιβλεπόμενης μάθησης (*semi-supervised learning*), τα οποία λειτουργούν παρόμοια με τα μοντέλα επιβλεπόμενης μάθησης, αλλά χρησιμοποιούν δεδομένα με ετικέτα και χωρίς ετικέτα. Τα δεδομένα με ετικέτα είναι ουσιαστικά πληροφορίες που βοηθούν τον αλγόριθμο να κατανοήσει τα δεδομένα, ενώ τα δεδομένα χωρίς ετικέτα δεν διαθέτουν αυτές τις πληροφορίες. Χρησιμοποιώντας αυτό το συνδυασμό, οι αλγόριθμοι ημι-επιβλεπόμενης μάθησης μπορούν να μάθουν να προβλέπουν δεδομένα χωρίς ετικέτα.

Γραμμική Παλινδρόμηση

Η Γραμμική Παλινδρόμηση (*Linear Regression*) είναι ο βασικότερος τύπος παλινδρόμησης και ανήκει στην κατηγορία της επιβλεπόμενης μάθησης. Η γραμμική παλινδρόμηση επιτρέπει να κατανοήσουμε τις σχέσεις μεταξύ δύο συνεχών μεταβλητών. Με πιο απλά λόγια, η γραμμική παλινδρόμηση βρίσκει την καλύτερη γραμμική σχέση μεταξύ της ανεξάρτητης και της εξαρτημένης μεταβλητής έτσι ώστε το σφάλμα να ελαχιστοποιείται (Montgomery et al., 2021). Το σφάλμα, όπως παρουσιάζεται παρακάτω, ορίζεται ως η διαφορά μεταξύ της πραγματικής τιμής και της προβλεπόμενης τιμής και ο στόχος είναι να μειωθεί αυτή η διαφορά.

Η γραμμική παλινδρόμηση μπορεί να είναι δύο τύπων, απλή γραμμική παλινδρόμηση (*simple linear regression*) και πολλαπλή γραμμική παλινδρόμηση (*multiple linear regression*). Όπως αναφέρθηκε και παραπάνω, στην απλή γραμμική παλινδρόμηση υπάρχει μόνο μία ανεξάρτητη μεταβλητή και το μοντέλο εντοπίζει τη γραμμική σχέση της με την εξαρτημένη μεταβλητή, ενώ στην πολλαπλή γραμμική παλινδρόμηση υπάρχουν περισσότερες από μία ανεξάρτητες μεταβλητές και το μοντέλο βρίσκει τη σχέση τους με την εξαρτημένη μεταβλητή (Hidalgo and Goodman, 2013).

Η εξίσωση της απλής γραμμικής παλινδρόμησης παρατίθεται παρακάτω:

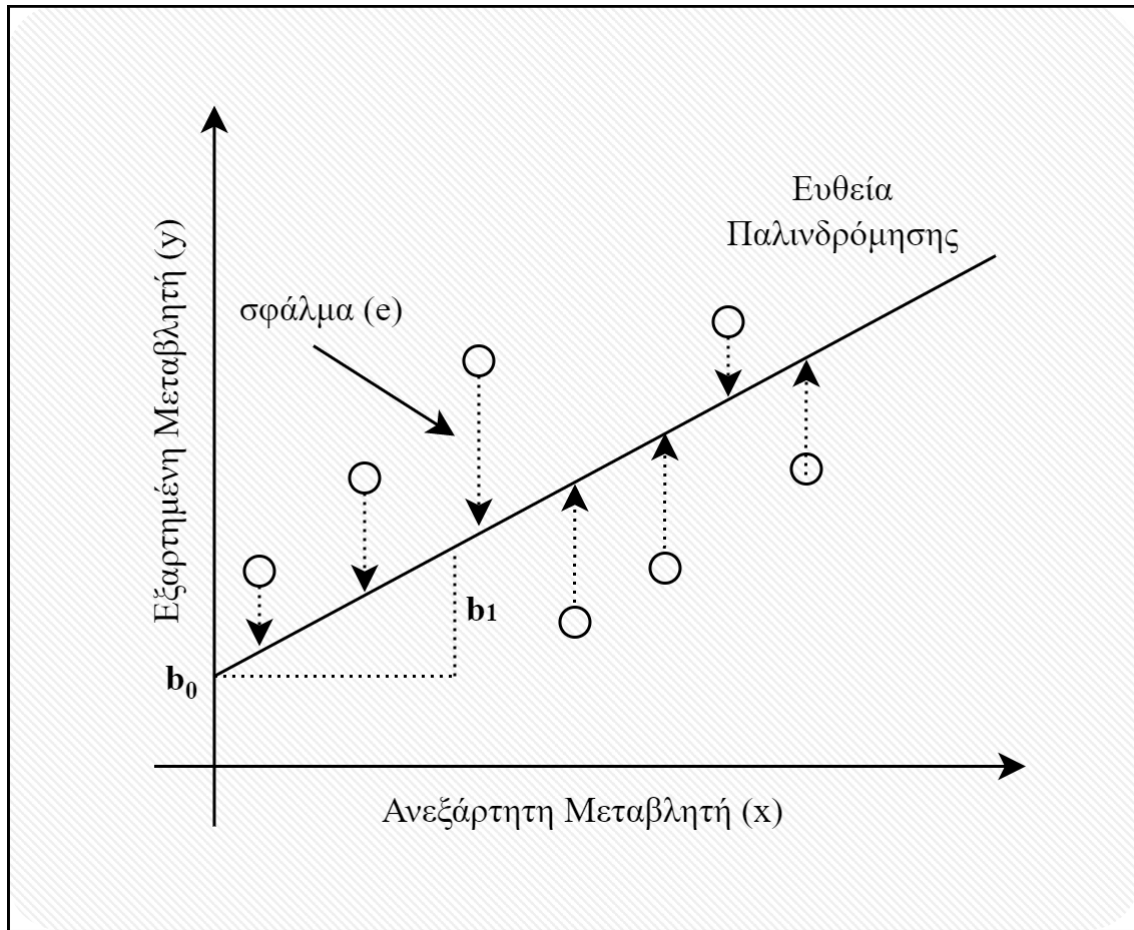
$$y = b_0 + b_1x \quad (2.1)$$

όπου b_0 είναι η τέμνουσα (*intercept*), b_1 είναι η κλίση (*coefficient* ή *slope*), x είναι η ανεξάρτητη μεταβλητή και y η εξαρτημένη μεταβλητή.

Στη γραμμική παλινδρόμηση ο αλγόριθμος εκτιμά τους συντελεστές της γραμμικής εξίσωσης που περιλαμβάνει μία ή περισσότερες ανεξάρτητες μεταβλητές ώστε να προβλέπουν την τιμή της εξαρτημένης μεταβλητής. Η γραμμική παλινδρόμηση εντοπίζει την ευθεία γραμμή ή επιφάνεια που ελαχιστοποιεί τις αποκλίσεις μεταξύ των προβλεπόμενων και των πραγματικών τιμών εξόδου σύμφωνα με τη μέθοδο των ελαχίστων τετραγώνων (*ordinary least squares*) (Dismuke and Lindrooth, 2006; Craven and Islam, 2011). Το σφάλμα (*residual error*) είναι ένα μέτρο του πόσο μακριά είναι ένα σημείο κατακόρυφα από τη γραμμή παλινδρόμησης, δηλαδή μεταξύ μιας προβλεπόμενης τιμής και της παρατηρούμενης πραγματικής τιμής.

$$\sum e_i^2 = \sum (y_i - \hat{y}_i)^2 \quad (2.2)$$

Στο Σχήμα 2.3 απεικονίζεται στον οριζόντιο άξονα η ανεξάρτητη μεταβλητή x ενώ στον κατακόρυφο άξονα η εξαρτημένη μεταβλητή y . Οι μαύρες κουκίδες είναι οι πραγματικές τιμές ενώ η κατακόρυφη απόσταση τους από την ευθεία παλινδρόμησης ορίζεται ως το σφάλμα του μοντέλου. Ο στόχος της γραμμικής παλινδρόμησης είναι να ελαχιστοποιήσει το άθροισμα των τετραγώνων αυτών των σφαλμάτων (Alevizos, 2020).



Σχήμα 2.3: Σχηματική απεικόνιση του μοντέλου Linear Regression.

Οι βασικές παραδοχές της Γραμμικής Παλινδρόμησης είναι οι εξής:

- Γραμμικότητα (*Linearity*): Δηλώνει ότι η εξαρτημένη μεταβλητή Y πρέπει να σχετίζεται γραμμικά με ανεξάρτητες μεταβλητές. Αυτή η υπόθεση μπορεί να ελεγχθεί σχεδιάζοντας ένα διάγραμμα διασποράς μεταξύ των δύο μεταβλητών.
- Κανονικότητα (*Normality*): Οι μεταβλητές X και Y θα πρέπει να κατανομούνται κανονικά. Ιστογράμματα, διαγράμματα KDE, διαγράμματα Q-Q μπορούν να χρησιμοποιηθούν για τον έλεγχο της υπόθεσης της κανονικότητας (Peng et al., 2004).
- Ομοσκεδαστικότητα (*Homoscedasticity*): Η διακύμανση των όρων σφάλματος θα πρέπει να είναι σταθερή, δηλαδή η διασπορά των υπολειμμάτων θα πρέπει να είναι σταθερή για όλες τις τιμές του X . Αυτή η υπόθεση μπορεί να ελεγχθεί σχεδιάζοντας ένα *residual plot*. Εάν παραβιαστεί η υπόθεση, τότε τα σημεία θα σχηματίσουν *funnel shape* διαφορετικά θα είναι σταθερά (Schützenmeister et al., 2012).

Αντίστοιχα, η εξίσωση της πολλαπλής γραμμικής παλινδρόμησης παρουσιάζεται παρακάτω:

$$y = b_0 + b_1x_1 + b_2x_2 + b_3x_3 + \dots + b_nx_n \quad (2.3)$$

όπου b_0 είναι η τέμνουσα, $b_1, b_2, b_3, \dots, b_n$ είναι οι κλίσεις των ανεξάρτητων μεταβλητών $x_1, x_2, x_3, \dots, x_n$ και y είναι η εξαρτημένη μεταβλητή.

Λογιστική Παλινδρόμηση

Η λογιστική παλινδρόμηση (*Logistic Regression*) είναι ένας αλγόριθμος επιβλεπόμενης μάθησης για προβλήματα κατάταξης ο οποίος εστιάζει στην εκτίμηση της πιθανότητας να συμβεί ένα συμβάν με βάση δεδομένα (Kleinbaum et al., 2002). Χρησιμοποιείται για την κάλυψη μιας δυαδικής εξαρτημένης μεταβλητής, όπου μόνο δύο τιμές, το 0 και το 1, αντιπροσωπεύουν αποτελέσματα. Η βασική φιλοσοφία της λογιστικής παλινδρόμησης είναι η εξής: Δίνεται ως είσοδος ένα σύνολο δεδομένων που περιέχει N σημεία εκ των οποίων κάθε σημείο i αποτελείται από ένα σύνολο m μεταβλητών εισόδου $x_{1i}, x_{2i}, \dots, x_{mi}$, (ονομάζονται επίσης ανεξάρτητες μεταβλητές) και μια μεταβλητή δυαδικού αποτελέσματος y_i (επίσης γνωστή ως εξαρτημένη μεταβλητή ή κλάση) (Walker and Duncan, 1967). Η εξαρτημένη μεταβλητή μπορεί να λάβει μόνο δύο πιθανές τιμές 0 (ερμηνεύεται ως “όχι” ή αποτυχία) ή 1 (ερμηνεύεται ως “ναι” ή επιτυχία). Ο στόχος της λογιστικής παλινδρόμησης είναι να χρησιμοποιηθεί το σύνολο δεδομένων για τη δημιουργία ενός προγνωστικού μοντέλου της εξαρτημένης μεταβλητής. Η παραπάνω περιγραφή αντιστοιχεί στο απλούστερο μοντέλο λογιστικής παλινδρόμησης που ονομάζεται δυαδική λογιστική παλινδρόμηση (King, 2008).

Η λογιστική συνάρτηση περιγράφεται με την παρακάτω εξίσωση:

$$p(x) = \frac{1}{1 + e^{-(x-\mu)/s}} \quad (2.4)$$

όπου το μ δηλώνει που επικεντρώνεται η κατανομή στον οριζόντιο άξονα και το s δηλώνει την κλίμακα της κατανομής. Συνήθως η λογιστική συνάρτηση εκφράζεται με την ακόλουθη εξίσωση.

$$p(x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x)}} \quad (2.5)$$

όπου η μεταβλητή $\beta_0 = -\mu/s$ είναι η τέμνουσα (πιο συγκεκριμένα η κάθετη τέμνουσα της γραμμής $y = \beta_0 + \beta_1 x$) και η μεταβλητή $\beta_1 = 1/s$ είναι η κλίση (inverse scale parameter or rate parameter).

Η λογιστική παλινδρόμηση ανήκει στην οικογένεια των επιβλεπόμενων μοντέλων MM (Schein and Ungar, 2007). Θεωρείται επίσης διακριτικό μοντέλο, που σημαίνει ότι επιχειρεί να διακρίνει μεταξύ κλάσεων. Η λογιστική παλινδρόμηση μπορεί επίσης να είναι επιρρεπής σε υπερπροσαρμογή (*overfitting*), ιδιαίτερα όταν υπάρχει μεγάλος αριθμός μεταβλητών πρόβλεψης στο μοντέλο (Demšar and Zupan, 2021). Για αυτό το λόγο ενδείκνυται η χρήση κάποιας μορφής κανονικοποίησης (*regularization*) για να τιμωρήσει παραμέτρους με μεγάλους συντελεστές σε περιπτώσεις που το μοντέλο εμπεριέχει υψηλή διαστατικότητα.

Υπάρχουν τρεις υποκατηγορίες λογιστικής παλινδρόμησης, οι οποίες περιγράφονται παρακάτω:

1. Δυαδική Λογιστική Παλινδρόμηση (*Binary Logistic Regression*): Όπως αναφέρθηκε και παραπάνω, η δυαδική λογιστική παλινδρόμηση χρησιμοποιείται στην περίπτωση ταξινόμησης ενός αντικειμένου ανάμεσα σε δύο πιθανές κλάσεις, όταν δηλαδή υπάρχουν μόνο δύο πιθανές περιπτώσεις ως αποτέλεσμα οι οποίες τυπικά αντιπροσωπεύονται ως 0 ή 1 στην κωδικοποίηση.
2. Πολυωνυμική Λογιστική Παλινδρόμηση (*Multinomial Logistic Regression*): Σε αυτόν τον τύπο μοντέλου λογιστικής παλινδρόμησης, η εξαρτημένη μεταβλητή έχει τρία ή περισσότερα πιθανά αποτελέσματα. Ωστόσο, αυτές οι διακριτές κλάσεις δεν έχουν καθορισμένη σειρά.
3. Λογιστική Παλινδρόμηση Τάξεως (*Ordinal Logistic Regression*): Αυτός ο τύπος μοντέλου λογιστικής παλινδρόμησης αξιοποιείται όταν η μεταβλητή απόκρισης έχει τρία ή περισσότερα πιθανά αποτελέσματα, αλλά στην περίπτωση αυτή, αυτές οι τιμές έχουν μια καθορισμένη σειρά (Harrell, 2015). Τυπικό παράδειγμα αποτελεί η κατάταξη μιας επένδυσης σε τρεις διακριτές κλάσεις ή η πρόβλεψη για την ενεργειακή αποδοτικότητα

μιας συσκευής ανάμεσα σε πέντε διακριτές κλίμακες βαθμολόγησης από το A έως το F.

Μηχανές Διανυσμάτων Υποστήριξης

Οι Μηχανές Διανυσμάτων Υποστήριξης (*Support Vector Machines*) είναι ένα σύνολο μεθόδων επιβλεπόμενης μάθησης που χρησιμοποιούνται για προβλήματα ταξινόμησης, παλινδρόμησης και ανίχνευσης ακραίων τιμών (Suthaharan, 2016b). Για προβλήματα παλινδρόμησης το μοντέλο ονομάζεται *support vector regressor*, ενώ για προβλήματα ταξινόμησης ονομάζεται *support vector classifier*. Τα βασικότερα πλεονεκτήματα των μηχανών διανυσμάτων υποστήριξης είναι πως έχουν αποδειχθεί αποτελεσματικά σε χώρους υψηλών διαστάσεων, παρουσιάζουν καλή προβλεπτική ικανότητα σε περιπτώσεις όπου ο αριθμός των διαστάσεων είναι μεγαλύτερος από τον αριθμό των δειγμάτων και παρουσιάζουν μεγάλη ευελιξία καθώς μπορούν να καθοριστούν διαφορετικές συναρτήσεις πυρήνα ως συνάρτηση απόφασης (Anguita et al., 2010). Το μειονέκτημα των μηχανών διανυσμάτων υποστήριξης είναι πως δεν υπολογίζουν άμεσα πιθανότητες, αλλά αντίθετα οι πιθανότητες προκύπτουν μέσω της διαδικασίας *cross-validation* (Platt et al., 1999).

Ο στόχος του αλγόριθμου της μηχανής διανυσμάτων υποστήριξης είναι να βρει ένα υπερεπίπεδο (*hyperplane*) το οποίο να ταξινομεί ευδιάκριτα τα σημειακά δεδομένα (*data points*) σε ένα χώρο N -διαστάσεων (ο αριθμός N ορίζεται από το πλήθος των χαρακτηριστικών). Προκειμένου να διαχωριστούν δύο κατηγορίες σημειακών δεδομένων, υπάρχουν πολλά πιθανά υπερεπίπεδα που θα μπορούσαν να επιλεγούν. Ο αλγόριθμος επιδιώκει να εντοπίσει το επίπεδο που έχει το μέγιστο περιθώριο (*maximum margin*), δηλαδή τη μέγιστη απόσταση μεταξύ των σημειακών δεδομένων των δύο κατηγοριών, όπως φαίνεται στο Σχήμα 2.4. Η μεγιστοποίηση της απόστασης αυτής ενισχύει το μοντέλο έτσι ώστε μελλοντικά σημειακά δεδομένων να μπορούν να ταξινομηθούν με μεγαλύτερη ακρίβεια.


Τα υπερεπίπεδα είναι σύνορα απόφασης που βοηθούν στην ταξινόμηση των σημειακών δεδομένων, επομένως σημειακά δεδομένα που εμπίπτουν σε κάποια πλευρά του υπερεπιπέδου αποδίδονται στην αντίστοιχη κλάση. Όσον αφορά στη διάσταση του υπερεπιπέδου, αυτή εξαρτάται από τον αριθμό των χαρακτηριστικών εισόδου. Πιο συγκεκριμένα, αν ο αριθμός των χαρακτηριστικών εισόδου είναι 2, τότε το υπερεπίπεδο είναι απλώς μια γραμμή (όπως φαίνεται στο Σχήμα 2.4. Αν ο αριθμός των χαρακτηριστικών εισόδου είναι 3, τότε το υπερεπίπεδο γίνεται διδιάστατο επίπεδο. Για περισσότερα από 3 χαρακτηριστικά εισόδου είναι δύσκολο να οπτικοποιηθεί το υπερεπίπεδο αφού θα υπάρχει χώρος 4 ή περισσότερων διαστάσεων.

Η ορολογία μηχανές διανυσμάτων υποστήριξης βασίζεται στα διανύσματα υποστήριξης. Τα διανύσματα υποστήριξης είναι σημειακά δεδομένα τα οποία βρίσκονται πιο κοντά στο υπερεπίπεδο και συνεπώς επηρεάζουν τη θέση και τον προσανατολισμό του υπερεπιπέδου (Noble, 2006). Χρησιμοποιώντας αυτά τα διανύσματα υποστήριξης, μεγιστοποιείται το περιθώριο του ταξινομητή καθώς η διαγραφή των διανυσμάτων υποστήριξης αλλάζει τη θέση του υπερεπιπέδου.

Η μαθηματική προτυποποίηση του προβλήματος έχει ως εξής: Δοθέντος ενός συνόλου n σημείων στη μορφή $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)$, όπου το y_i είναι είτε 1 είτε -1 ανάλογα με την κλάση που ανήκει το \mathbf{x}_i , αναζητείται το υπερεπίπεδο μέγιστου περιθωρίου που διαχωρίζει το σύνολο σημείων \mathbf{x}_i με $y_i = 1$ από το σύνολο σημείων με $y_i = -1$, έτσι ώστε η απόσταση μεταξύ του υπερεπιπέδου και του πλησιέστερου σημείου \mathbf{x}_i από οποιαδήποτε ομάδα να μεγιστοποιείται. Οποιοδήποτε υπερεπίπεδο μπορεί να εκφραστεί ως το σύνολο των σημείων \mathbf{x} που ικανοποιούν την παρακάτω εξίσωση:

$$\mathbf{w}^T \mathbf{x} - b = 0, \quad (2.6)$$

όπου το διάνυσμα \mathbf{w} είναι το κανονικό διάνυσμα στο υπερεπίπεδο. Η παράμετρος $\frac{b}{\|\mathbf{w}\|}$ καθορίζει τη μετατόπιση του υπερεπιπέδου από κατά μήκος του κανονικού διανύσματος \mathbf{w} . Αν τα δεδομένα είναι γραμμικά διαχωρισμένα, ο αλγόριθμος επιλέγει δύο παράλληλα υπερεπίπεδα που



Σχήμα 2.4: Σχηματική απεικόνιση του μοντέλου Support Vector Machine.

χωρίζουν τις δύο κατηγορίες δεδομένων, έτσι ώστε η απόσταση μεταξύ τους να είναι όσο το δυνατόν μεγαλύτερη. Αυτό μπορεί να εκφραστεί με το παρακάτω πρόβλημα βελτιστοποίησης.

$$\text{Minimize: } y_i(\mathbf{w}^T \mathbf{x}_i - b) \geq 1, \quad \text{for all } 1 \leq i \leq n \quad (2.7)$$

Αντίθετα, αν τα δεδομένα δεν είναι γραμμικά διαχωρίσιμα τότε ο αλγόριθμος της μηχανής διανυσμάτων υποστήριξης χρησιμοποιεί τη συνάρτηση *hinge loss*, η οποία είναι μηδέν αν το \mathbf{x}_i βρίσκεται στη σωστή πλευρά του περιθωρίου, ενώ είναι ανάλογη με την απόσταση από το περιθώριο αν \mathbf{x}_i βρίσκεται στην λάθος πλευρά του περιθωρίου (Wu and Liu, 2007). Η περιγραφή αυτή εκφράζεται με την παρακάτω εξίσωση:

$$\text{Minimize: } \lambda \|\mathbf{w}\|^2 + \left[\frac{1}{n} \sum_{i=1}^n \max(0, 1 - y_i(\mathbf{w}^T \mathbf{x}_i - b)) \right], \quad (2.8)$$

όπου η τιμή της παραμέτρου λ καθορίζει πόσο αυστηρά θα τιμωρείται η ύπαρξη δεδομένων στη λάθος πλευρά του περιθωρίου. Επομένως αντισταθμίζει την αύξηση του μεγέθους του περιθωρίου και τη διασφάλιση ότι το \mathbf{x}_i βρίσκεται στη σωστή πλευρά του περιθωρίου.

Ταξινομητής Naive Bayes

Οι ταξινομητές *Naive Bayes* είναι μια οικογένεια πιθανοτικών ταξινομητών που βασίζονται στο θεώρημα του Bayes και λειτουργούν ταξινομώντας κάθε νέα τιμή ως ανεξάρτητη από οποιαδήποτε άλλη τιμή (Rish et al., 2001). Ο ταξινομητής Naive Bayes ανήκει στις κατηγορίες επιβλεπόμενης μάθησης και εξυπηρετεί αποκλειστικά στην επίλυση προβλημάτων ταξινόμησης. Τα μοντέλα που ανήκουν σε αυτή την κατηγορία είναι επεκτάσιμα σε μεγάλο βαθμό, αφού απαιτούν ένα πλήθος παραμέτρων γραμμικών ως προς το πλήθος των μεταβλητών.

Σε αντίθεση με άλλους ταξινομητές που ακολουθούν την επαναληπτική προσέγγιση κατά τη διαδικασία της μάθησης, οι ταξινομητές Naive Bayes διεξάγουν την εκπαίδευση μέγιστης πιθανοφάνειας (*maximum likelihood*) μέσω μαθηματικών εκφράσεων που απαιτούν γραμμικό χρόνο (Dumais et al., 1998).

Ο αλγόριθμος Naive Bayes είναι μια τεχνική που βασίζεται στην υπόθεση ότι η τιμή ενός συγκεκριμένου χαρακτηριστικού είναι ανεξάρτητη από την τιμή οποιουδήποτε άλλου χαρακτηριστικού, δεδομένης της μεταβλητής κλάσης. Σε πολλές πρακτικές εφαρμογές, η εκτίμηση των παραμέτρων για απλά μοντέλα Bayes πραγματοποιείται με τη μέθοδο της μέγιστης πιθανοφάνειας. Παρά τον αφελή σχεδιασμό τους και τις φαινομενικά υπεραπλουστευμένες υποθέσεις, οι ταξινομητές Naive Bayes έχουν λειτουργήσει αρκετά καλά σε πολλά περίπλοκα προβλήματα σε διαφορετικούς τομείς (Ashari et al., 2013; Bayindir et al., 2017). Ένα πλεονέκτημα του Naive Bayes είναι ότι απαιτεί μόνο μικρό αριθμό δεδομένων εκπαίδευσης για την εκτίμηση των παραμέτρων που είναι απαραίτητες για την ταξινόμηση (Singh et al., 2017).

Η μαθηματική προτυποποίηση του αλγορίθμου Naive Bayes είναι η εξής: Δοθέντος ενός δείγματος προς ταξινόμηση, το οποίο εκφράζεται με ένα διάνυσμα $\mathbf{x} = (x_1, \dots, x_n)$ που αντιπροσωπεύει n χαρακτηριστικά εισόδου, ο αλγόριθμος εκχωρεί στο δείγμα πιθανότητες $p(C_k | x_1, \dots, x_n)$ για κάθε ένα από τα K πιθανά αποτελέσματα κλάσεων C_k . Το πρόβλημα με την παραπάνω διατύπωση είναι ότι αν ο αριθμός των χαρακτηριστικών n είναι μεγάλος, τότε δεν είναι εφικτό να βασιστεί ένα τέτοιο μοντέλο στη θεωρία των πιθανοτήτων. Επομένως, χρησιμοποιώντας το θεώρημα του Bayes, η υπό όρους πιθανότητα μπορεί να αποσυντεθεί ως εξής:

$$p(C_k | \mathbf{x}) = \frac{p(C_k) p(\mathbf{x} | C_k)}{p(\mathbf{x})} \quad (2.9)$$

Οι δημοφιλέστεροι ταξινομητές Naive Bayes είναι ο *Gaussian Naive Bayes*, ο *Multinomial Naive Bayes* και ο *Bernoulli Naive Bayes*, οι οποίοι περιγράφονται στις επόμενες παραγράφους.

Ο Gaussian Naive Bayes χρησιμοποιείται για προβλήματα με συνεχή δεδομένα και στηρίζεται στην υπόθεση πως οι συνεχείς τιμές που σχετίζονται με κάθε κλάση κατανομούνται σύμφωνα με την κανονική κατανομή (Jahromi and Taheri, 2017). Επομένως, αν υπάρχει ένα πρόβλημα κατάταξης όπου τα δεδομένα εκπαίδευσης περιέχουν ένα συνεχές χαρακτηριστικό X , τότε τα δεδομένα τμηματοποιούνται ανά κλάση και υπολογίζεται ο μέσος όρος και η διακύμανση του x για κάθε κλάση. Αν μ_k είναι η μέση τιμή και σ_k^2 είναι η διακύμανση των τιμών για την κλάση C_k τότε η συνάρτηση πυκνότητας πιθανότητας δίνεται από την παρακάτω μαθηματική έκφραση:

$$p(x = v | C_k) = \frac{1}{\sqrt{2\pi\sigma_k^2}} e^{-\frac{(v-\mu_k)^2}{2\sigma_k^2}} \quad (2.10)$$

Στον Multinomial Naive Bayes τα χαρακτηριστικά εισόδου αντιπροσωπεύουν τη συχνότητα με την οποία ορισμένα συμβάντα έχουν δημιουργηθεί από ένα πολυώνυμο (p_1, \dots, p_n) όπου p_i είναι η πιθανότητα να συμβεί το συμβάν i . Ο αλγόριθμος αυτός χρησιμοποιείται κυρίως στην επεξεργασία φυσικής γλώσσας (*natural language processing*) καθώς προβλέπει την πιθανότητα για την ετικέτα ενός κειμένου (Kibriya et al., 2004).

Τέλος, ο ταξινομητής Bernoulli Naive Bayes χρησιμοποιείται σε προβλήματα όπου τα χαρακτηριστικά εισόδου είναι ανεξάρτητες δυαδικές μεταβλητές που περιγράφουν εισόδους σε ένα πείραμα Bernoulli. Αν το x_i είναι μια δυαδική μεταβλητή που εκφράζει την εμφάνιση ή μη εμφάνιση του i -οστού όρου από ένα λεξιλόγιο, τότε η πιθανότητα να ανήκει στην κλάση C_k δίνεται από την παρακάτω εξίσωση:

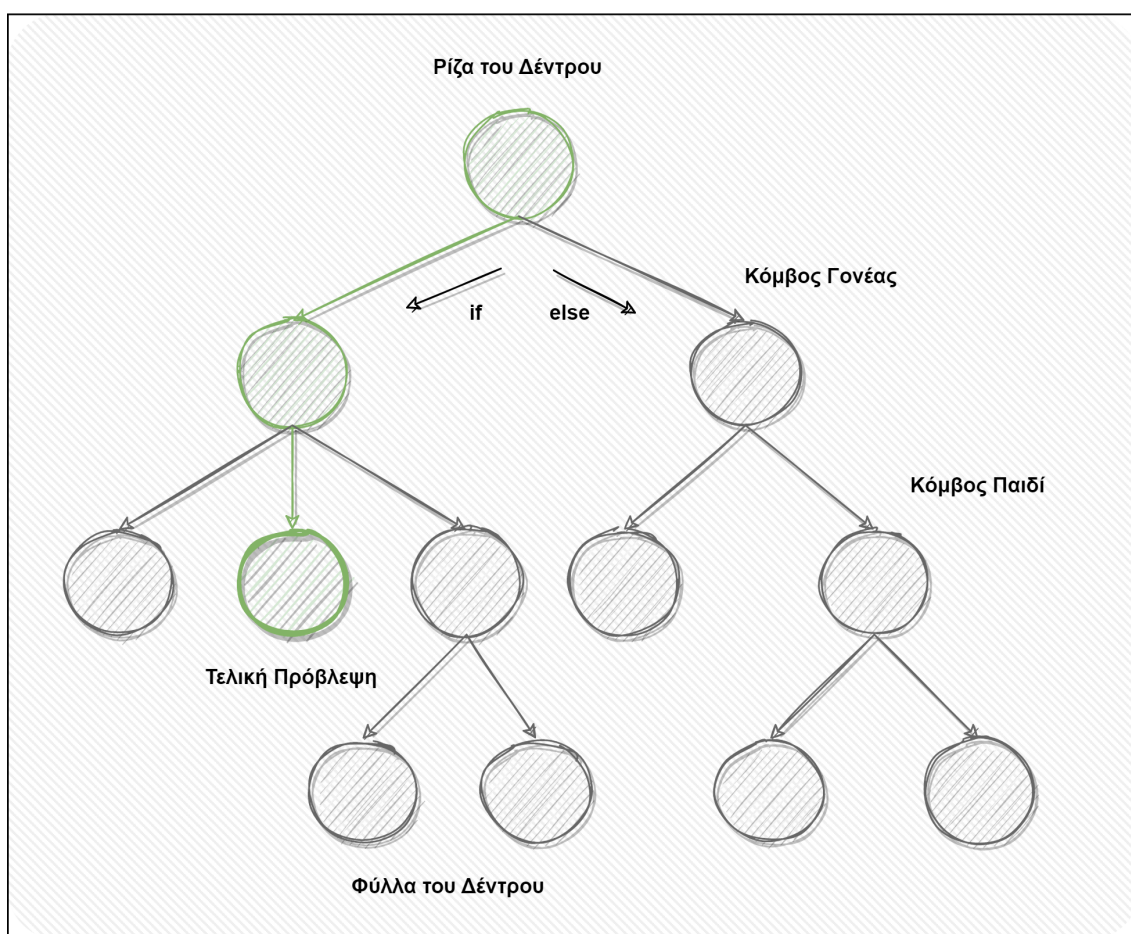
$$p(\mathbf{x} | C_k) = \prod_{i=1}^n p_{ki}^{x_i} (1 - p_{ki})^{(1-x_i)} \quad (2.11)$$

όπου p_{ki} είναι η πιθανότητα της κλάσης C_k να περιέχει τον όρο x_i .

Δέντρα Αποφάσεων

Τα δέντρα αποφάσεων (*Decision Trees*) ανήκουν στην οικογένεια των μοντέλων επιβλεπόμενης ΜΜ και χρησιμοποιείται για την πραγματοποίηση προβλέψεων με κριτήριο τον τρόπο με τον οποίο απαντήθηκε ένα προηγούμενο σύνολο ερωτήσεων (Myles et al., 2004). Ως μοντέλο επιβλεπόμενης μάθησης, ένα δέντρο αποφάσεων πρέπει να εκπαιδευτεί σε ένα σύνολο δεδομένων που περιέχει την επιθυμητή κατηγοριοποίηση. Τα δέντρα αποφάσεων μιμούνται την ανθρώπινη σκέψη, επομένως έχουν το πλεονέκτημα πως είναι γενικά εύκολο για τους επιστήμονες δεδομένων να κατανοήσουν και να ερμηνεύσουν τα αποτελέσματα.

Ένα δέντρο αποφάσεων έχει δομή δέντρου και μοιάζει με διάγραμμα ροής που χρησιμοποιεί μια μέθοδο διακλάδωσης για να απεικονίσει κάθε πιθανό αποτέλεσμα μιας απόφασης. Κάθε κόμβος μέσα στο δέντρο αντιπροσωπεύει μια δοκιμή σε μια συγκεκριμένη μεταβλητή, ενώ κάθε κλάδος είναι το αποτέλεσμα αυτής της δοκιμής. Η γραφική αναπαράσταση ενός δέντρου αποφάσεων παρουσιάζεται στο Σχήμα 2.5 και τα δομικά του μέρη επεξηγούνται παρακάτω:



Σχήμα 2.5: Σχηματική απεικόνιση του μοντέλου Decision Tree.

- Κόμβος γονέας και παιδί: Ένας κόμβος που χωρίζεται σε υποκόμβους είναι γνωστός ως κόμβος γονέας, ενώ αυτοί οι υποκόμβοι είναι γνωστοί ως κόμβοι παιδιά. Δεδομένου ότι ένας κόμβος μπορεί να διαχωριστεί σε πολλαπλούς άλλους κόμβους, προκύπτει ότι ένας κόμβος μπορεί να λειτουργήσει ως γονέας περισσότερων από δύο κόμβων παιδιών.
- Ρίζα του δέντρου: Ο κόμβος από τον οποίο εκκινεί το δέντρο αποφάσεων και συνεπώς δεν έχει γονικό κόμβο. Ο κόμβος αυτός αντιπροσωπεύει ολόκληρο το δείγμα των δεδομένων.

- Φύλλα του δέντρου: Οι κόμβοι που δεν έχουν κόμβο παιδί και συνεπώς είναι τερματικοί κόμβοι του δέντρου.

Για να δημιουργηθεί το μοντέλο του δέντρου αποφάσεων η διαδικασία μοντελοποίησης μπορεί να χωριστεί σε τρία στάδια, την ανάπτυξη των δέντρων (*tree growing*), το κλάδεμα των δέντρων (*tree pruning*) και την επιλογή μονοπατιού στο δέντρο (*tree selection*).

Το πρώτο στάδιο της δημιουργίας ενός μοντέλου δέντρου αποφάσεων είναι η ανάπτυξη δέντρων, η οποία τη συγχώνευση των δέντρων και το διαχωρισμό των δέντρων. Οι μη σημαντικές κατηγορίες πρόβλεψης και οι σημαντικές κατηγορίες σε ένα σύνολο δεδομένων ομαδοποιούνται μαζί. Καθώς το δέντρο μεγαλώνει, οι ακαθαρσίες (*impurities*) του μοντέλου αυξάνονται. Αυτό έχει ως αποτέλεσμα τη μείωση της ακρίβειας του μοντέλου, και συνεπώς δημιουργείται η ανάγκη καθαρισμού του δέντρου. Ο συνηθέστερος τρόπος για τον καθαρισμό του δέντρου είναι η αφαίρεση τους σε διαφορετικά φύλλα και διακλαδώσεις.

Κατά τη διαδικασία του κλαδέματος των δέντρων είναι η αφαίρεση των άσχετων κόμβων διαχωρισμού (Esposito et al., 1997; Kirkos et al., 2007). Η αφαίρεση των άσχετων κόμβων επιδρά μειώνοντας την πιθανότητα να δημιουργηθεί ένα δέντρο επιρρεπές σε υπερπροσαρμογή. Επομένως αυτή η διαδικασία είναι ιδιαίτερα χρήσιμη καθώς ένα μοντέλο δέντρου που έχει υποστεί υπερπροσαρμογή κατά τη διαδικασία εκπαίδευσης μπορεί να οδηγήσει σε εσφαλμένη ταξινόμηση δεδομένων στο σύνολο ελέγχου (Quinlan, 1987).

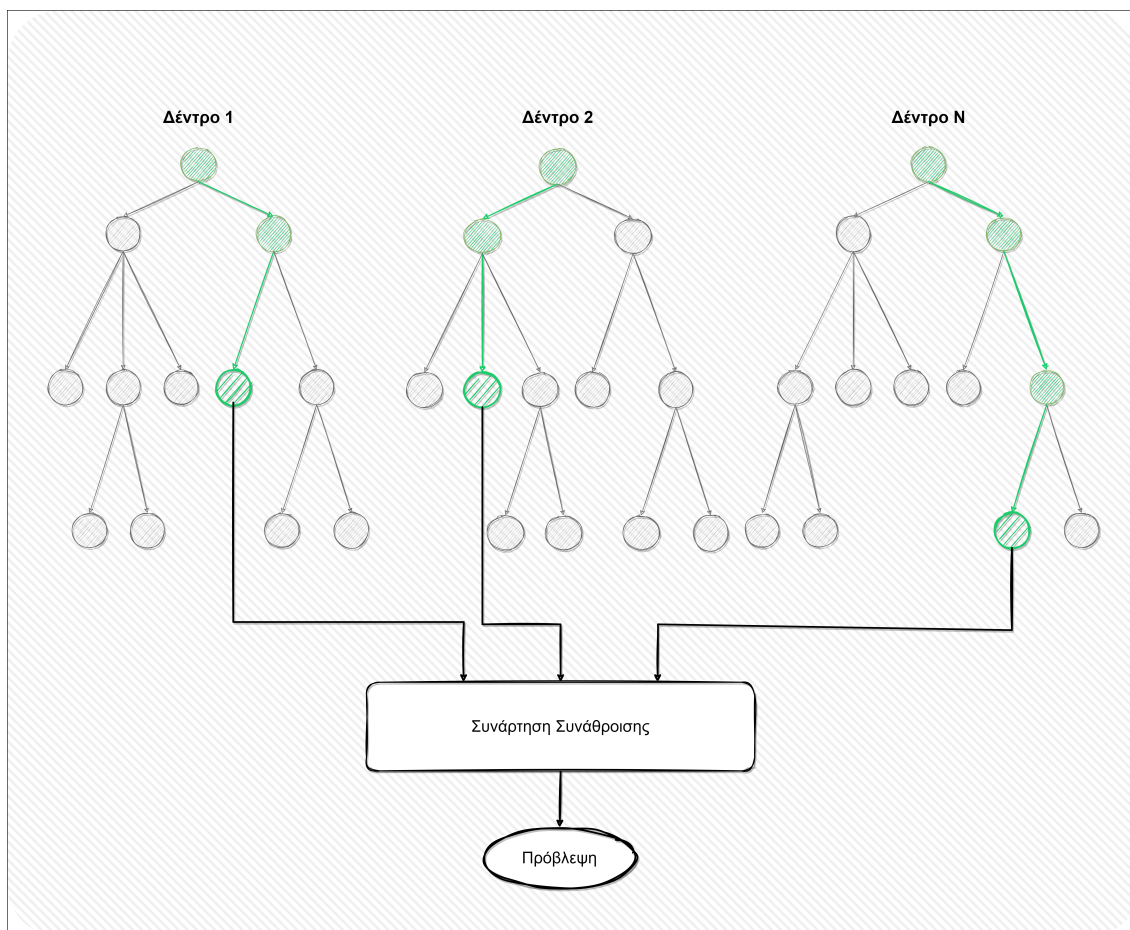
Το τελευταίο στάδιο στην ανάπτυξη ενός μοντέλου δέντρου αποφάσεων είναι η επιλογή δέντρου, όπου το μοντέλο δέντρου αποφάσεων που δημιουργήθηκε αξιολογείται συνήθως χρησιμοποιώντας διασταυρούμενη επικύρωση (Li et al., 1984). Αυτό το στάδιο είναι απαραίτητο, καθώς μπορεί να μειώσει τις πιθανότητες εσφαλμένης ταξινόμησης δεδομένων.

Συμπερασματικά, τα δέντρα αποφάσεων έχουν πολλαπλά πλεονεκτήματα. Τα βασικότερα είναι πως λειτουργούν και για αριθμητικά και για κατηγορικά δεδομένα. Επίσης, μπορούν να μοντελοποιήσουν προβλήματα με πολλαπλές εξόδους, απαιτούν λιγότερη προ-επεξεργασία δεδομένων από άλλες τεχνικές μοντελοποίησης δεδομένων και είναι εύκολα εξηγήσιμο. Αντιθέτως, στα μειονεκτήματα μπορεί να σημειωθεί πως επηρεάζονται από το θόρυβο στα δεδομένα, δεν είναι ιδανικά για μεγάλα σύνολα δεδομένων και επίσης τα δέντρα μπορεί να γίνουν πολύ περίπλοκα όταν αντιμετωπίζουν αβεβαιότητα και πολυάριθμα συνδεδεμένα αποτελέσματα.

Random Forests

Ο αλγόριθμος *Random Forest* (Breiman, 2001) είναι μια μέθοδος που ανήκει στην κατηγορία των μεθόδων επιβλεπόμενης μάθησης και χρησιμοποιείται για ταξινόμηση, παλινδρόμηση και άλλα προβλήματα. Τα random forests βασίζονται τη λειτουργία τους στην κατασκευή πολλών δέντρων αποφάσεων κατά την εκπαίδευση του μοντέλου. Σε προβλήματα ταξινόμησης, η έξοδος του τυχαίου δάσους είναι η κλάση που έχει επιλεγεί από τα περισσότερα δέντρα αποφάσεων, ενώ σε προβλήματα παλινδρόμησης τα random forests επιστρέφουν ως πρόβλεψη το μέσο όρο των προβλέψεων των μεμονωμένων δέντρων. Τα random forests δεν είναι τόσο επιρρεπή σε υπερπροσαρμογή σε σχέση με τα δέντρα αποφάσεων (Biau, 2012).

Ο αλγόριθμος των τυχαίων δασών έχει τρεις βασικές υπερπαραμέτρους, οι οποίες πρέπει να βελτιστοποιηθούν πριν από την διαδικασία εκπαίδευσης (Bernard et al., 2009). Αυτές οι υπερπαραμέτροι είναι το μέγεθος του κόμβου (node size), τον αριθμό των δέντρων (*number of trees*) και τον αριθμό των χαρακτηριστικών (*number of features*). Ο αλγόριθμος των τυχαίων δασών αποτελείται από ένα σύνολο δέντρων αποφάσεων. Κάθε δέντρο αποφάσεων αποτελείται από ένα δείγμα δεδομένων που προέρχεται από ένα σετ εκπαίδευσης με αντικατάσταση το οποίο ονομάζεται δείγμα εκκίνησης (*bootstrap sample*). Ένα μέρος αυτού του δείγματος εκπαίδευσης χρησιμοποιούνται ως δεδομένα ελέγχου, γνωστά επίσης ως *out-of-bag* δείγμα (Hastie et al., 2009b). Η συσχέτιση μεταξύ των δέντρων αποφάσεων από τα οποία αποτελείται το τυχαίο δάσος ενισχύεται μέσω της τεχνικής *feature bagging* με την οποία εισάγεται ένας επιπλέον παράγοντας τυχαιότητας στο μοντέλο (Strobl et al., 2009). Η δομή ενός μοντέλου τυχαίου δάσους παρουσιάζεται στο Σχήμα 2.6.



Σχήμα 2.6: Σχηματική απεικόνιση του μοντέλου Random Forest.

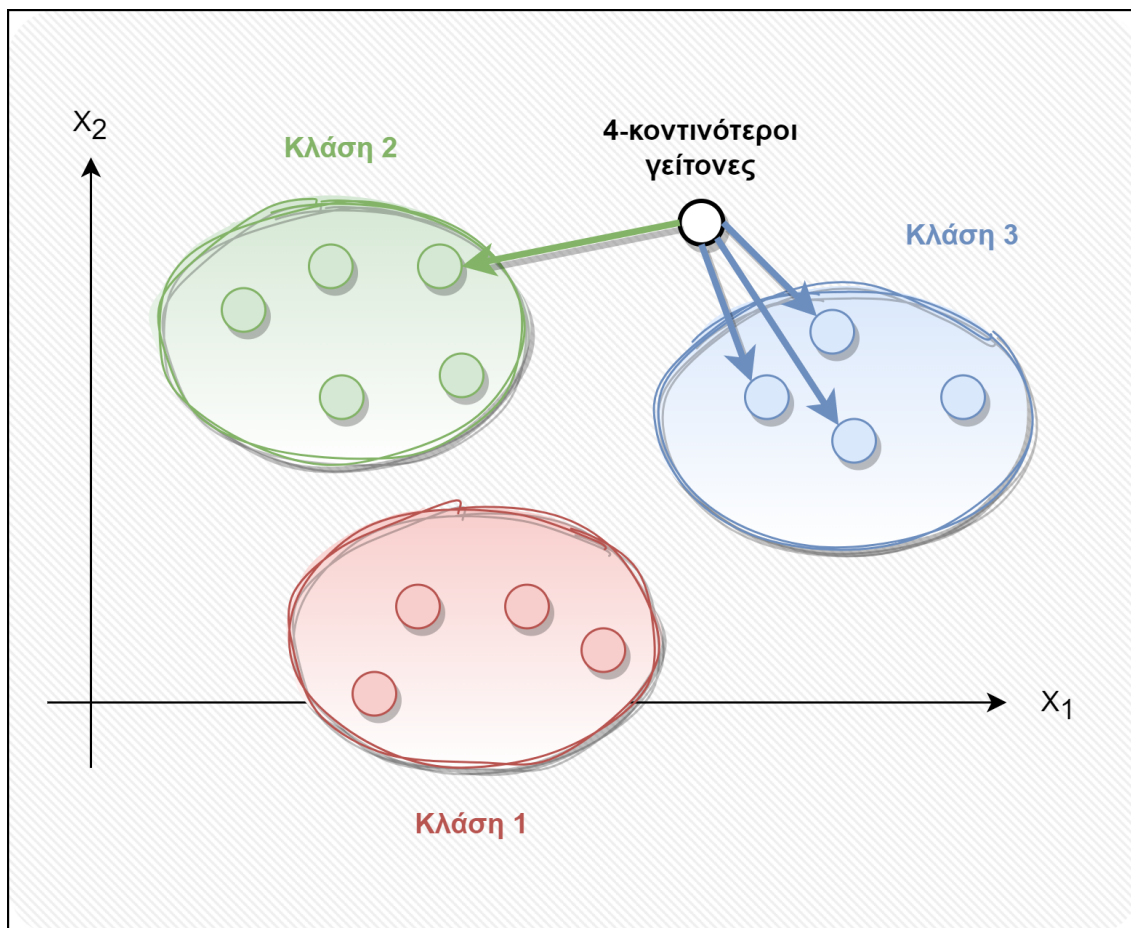
Η φιλοσοφία της λειτουργίας των τυχαίων δέντρων είναι συγκριτικά παρόμοια με αυτή των δέντρων αποφάσεων δεδομένου ότι ένα τυχαίο δέντρο παράγει την πρόβλεψη του με βάση τις προβλέψεις ενός συνόλου δέντρων αποφάσεων. Ωστόσο, τα δύο αυτά μοντέλα έχουν αρκετές διαφορές επί της ουσιαστικής λειτουργίας τους. Αρχικά, τα δέντρα αποφάσεων συνήθως πάσχουν από το πρόβλημα της υπερπροσαρμογής εάν τους επιτρέπεται να αναπτυχθούν χωρίς ελέγχους κατά τη διαδικασία μάθησης, σε αντίθεση με τα random forests που δημιουργούνται από υποσύνολα δεδομένων και η τελική έξοδος τους βασίζεται στη μέση πρόβλεψη ή στην πλειοψηφική πρόβλεψη των επιμέρους δέντρων αποφάσεων αντιμετωπίζοντας ως εκ τούτου το πρόβλημα της υπερπροσαρμογής. Επιπλέον, ένα απλό δέντρο αποφάσεων είναι συγκριτικά υπολογιστικά ταχύτερο σε σύγκριση με ένα τυχαίο δάσος. Τέλος, ένα δέντρο αποφάσεων διατυπώνει ένα σύνολο κανόνων για να κάνει πρόβλεψη, σε αντίθεση με τα random forests τα οποία επιλέγουν τυχαία παρατηρήσεις, δημιουργούν δέντρα αποφάσεων και λαμβάνουν τη μέση πρόβλεψη, χωρίς να χρησιμοποιούν κάποιο μαθηματικό τύπο ή σύνολο κανόνων.

k-Πλησιέστεροι Γείτονες

Ο αλγόριθμος k-πλησιέστερων γειτόνων (*k-Nearest Neighbors - kNN*) είναι ένα μοντέλο ταξινόμησης δεδομένων που χρησιμοποιείται για να εκτιμήσει την πιθανότητα ένα σημειακό δεδομένο να γίνει μέλος μιας ομάδας με βάση την ομάδα στην οποία ανήκουν τα σημειακά δεδομένα που βρίσκονται πλησιέστερα σε αυτό (Zhang, 2016). Ο αλγόριθμος αυτός ανήκει στην οικογένεια των μοντέλων επιβλεπόμενης μάθησης και χρησιμοποιείται κατά κύριο λόγο για προβλήματα ταξινόμησης, ωστόσο έχει χρησιμοποιηθεί και σε προβλήματα παλινδρόμησης. Ο αλγόριθμος kNN είναι ένας lazy, μη παραμετρικός αλγόριθμος (Spyromitros et al., 2008).

Ονομάζεται lazy αλγόριθμος ή *lazy learner* επειδή δεν εκτελεί κάποια μορφή εκπαίδευσης όταν λαμβάνει ως είσοδο το σύνολο των δεδομένων εκπαίδευσης. Αντίθετα, αποθηκεύει τα

δεδομένα κατά τη διαδικασία της εκπαίδευσης χωρίς να εκτελεί κάποιον υπολογισμό και δε δημιουργεί κάποιο μοντέλο μάθησης μέχρις ότου να εκτελεστεί ένα ερώτημα στο σύνολο δεδομένων (Maron and Moore, 1997). Αυτή η ιδιότητα του kNN τον καθιστά ιδανικό για εφαρμογές εξόρυξης δεδομένων. Επιπλέον, θεωρείται μη παραμετρικός αλγόριθμος επειδή δεν κάνει υποθέσεις σχετικά με την κατανομή των δεδομένων, αλλά προσπαθεί να προσδιορίσει σε ποια κλάση ανήκει ένα νέο δείγμα με βάση την κλάση των δεδομένων γύρω από αυτό το δείγμα. Η παραπάνω διαδικασία απεικονίζεται στο Σχήμα 2.7.



Σχήμα 2.7: Σχηματική απεικόνιση του μοντέλου k-nearest neighbors.

Η παράμετρος "k" στον αλγόριθμο kNN καθορίζει τον αριθμό των πλησιέστερων γειτόνων που θα συμπεριληφθούν κατά τη διαδικασία ψηφοφορίας (*voting process*). Η βέλτιστη τιμή της παραμέτρου k εξαρτάται αμιγώς από τα δεδομένα. Εν γένει, μεγαλύτερες τιμές της παραμέτρου k μειώνουν την επίδραση του θορύβου στο πρόβλημα ταξινόμησης, όμως κάνουν τα όρια μεταξύ των κλάσεων λιγότερο διακριτά (Zhang et al., 2017). Υπάρχει μεγάλο πλήθος τεχνικών βελτιστοποίησης για την βέλτιστη επιλογή της υπερπαραμέτρου k, όμως ο εμπειρικός κανόνας είναι πως η βέλτιστη τιμή K που συνήθως είναι η τετραγωνική ρίζα του N, όπου N είναι ο συνολικός αριθμός δειγμάτων. Επίσης στην ειδική περίπτωση που η παράμετρος k είναι ίση με 1, τότε κάθε νέο δείγμα ταξινομείται με βάση τον κοντινότερο γείτονα του (Hassanat et al., 2014).

Η προβλεπτική ικανότητα του αλγορίθμου kNN μπορεί να επηρεαστεί σε μεγάλο βαθμό από την παρουσία θορυβωδών χαρακτηριστικών με χαμηλή συσχέτιση ή στην περίπτωση που η κλίμακα των χαρακτηριστικών (*feature scale*) δεν είναι συνεπής με τη σημασία τους, επομένως απαιτείται κατάλληλη προεπεξεργασία των δεδομένων. Αξίζει να σημειωθεί πως σε προβλήματα δυαδικής ταξινόμησης είναι χρήσιμο να επιλέγεται περιττός αριθμός για την υπερπαραμέτρο k ώστε να αποφεύγονται οι ισοψηφίες.

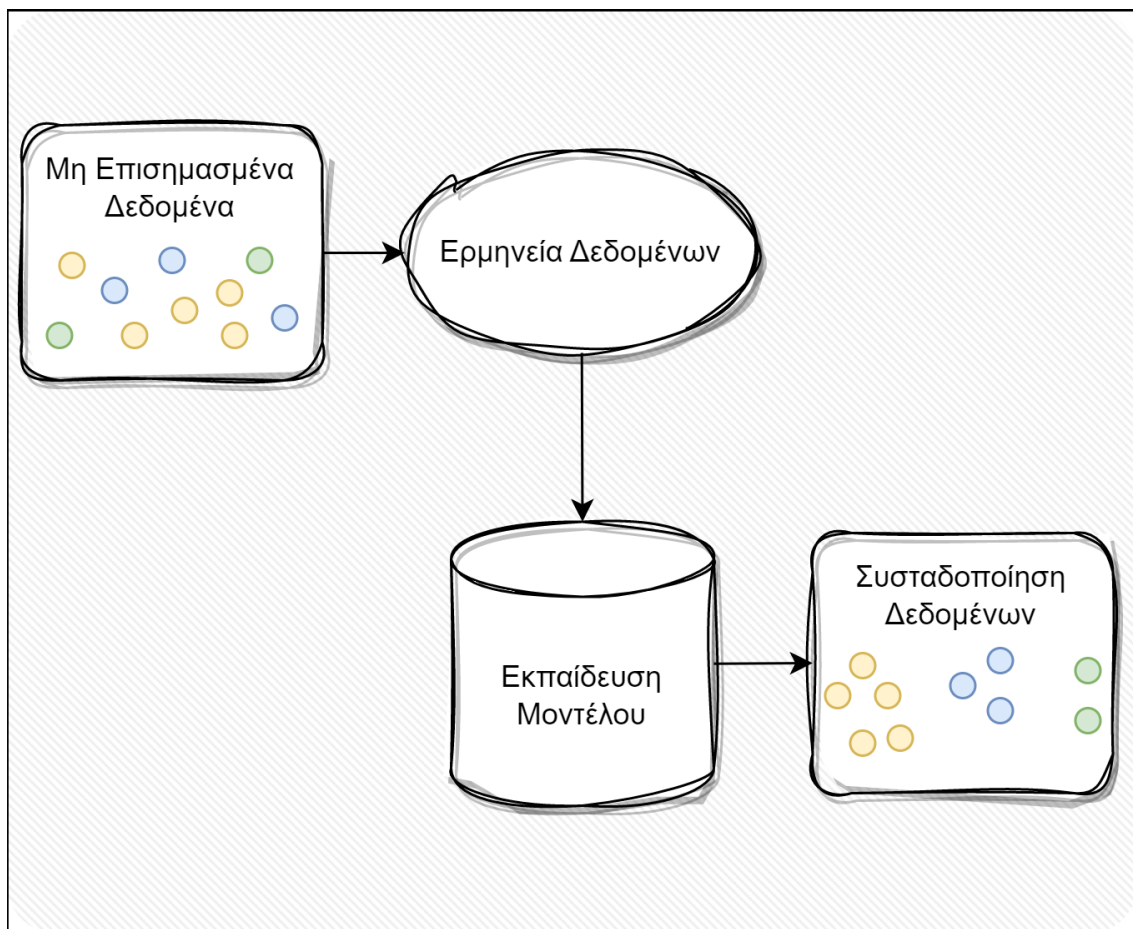
Οι βασικότερες μετρικές για τον υπολογισμό της μέτρησης της απόστασης μεταξύ του

νέου δείγματος και των πλησιέστερων γειτόνων του είναι τέσσερις: η ευκλείδεια απόσταση, η απόσταση Μανχάταν, η απόσταση *Hamming* και η απόσταση *Minkowski*. Από τις παραπάνω μεθόδους, η ευκλείδεια απόσταση είναι η πιο δημοφιλής μετρική (Isa et al., 2017).

2.2.2 Μέθοδοι Μη Επιβλεπόμενης Μάθησης

Η μη επιβλεπόμενη μάθηση (*unsupervised learning*) (Hastie et al., 2009c) είναι μια υποκατηγορία της ΜΜ που περιλαμβάνει αλγόριθμους για την ανάλυση και την ομαδοποίηση συνόλων δεδομένων χωρίς ετικέτα (*unlabeled data*). Αυτοί οι αλγόριθμοι έχουν ως στόχο να εντοπίζουν μοτίβα ή ομαδοποιήσεις δεδομένων χωρίς την ύπαρξη κάποιας πληροφορίας για την έξοδο στο σύνολο δεδομένων εκπαίδευσης και συνεπώς χωρίς την ανάγκη ανθρώπινης παρέμβασης (Barlow, 1989). Τέτοιοι αλγόριθμοι προσπαθούν να οργανώσουν τα δεδομένα με κάποιο τρόπο ώστε να περιγράψουν τη δομή τους. Καθώς ο αλγόριθμος εκπαιδεύεται σε περισσότερα δεδομένα, η ικανότητά του να λαμβάνει αποφάσεις για αυτά τα δεδομένα σταδιακά βελτιώνεται.

Στο Σχήμα 2.8 παρουσιάζεται η βασική φιλοσοφία των αλγορίθμων μη επιβλεπόμενης μάθησης. Ας θεωρήσουμε το παράδειγμα κατά το οποίο ένας αλγόριθμος μη επιβλεπόμενης μάθησης δέχεται ως είσοδο ένα σύνολο από εικόνες διαφορετικών αντικειμένων και καλείται να ομαδοποιήσει αυτές τις εικόνες. Στη μη επιβλεπόμενη μάθηση ο αλγόριθμος δεν εκπαιδεύεται πάνω στο σύνολο των δεδομένων εισόδου με την έννοια ότι δεν έχει τη γνώση για την ετικέτα της κάθε εικόνας. Επομένως, ο αλγόριθμος πρέπει να ερμηνεύσει τα χαρακτηριστικά των δεδομένων και να ομαδοποιήσει τα δεδομένα σε ομάδες με κριτήριο ομοιότητες ανάμεσα στα χαρακτηριστικά τους.



Σχήμα 2.8: Η διαδικασία της Μη Επιβλεπόμενης Μάθησης.

Αν και η μη επιβλεπόμενη μάθηση μπορεί να αποδειχθεί πολύ χρήσιμη για διάφορους τύπους προβλημάτων, συχνά προκύπτουν ορισμένες προκλήσεις και δυσκολίες λόγω της

έλλειψης ετικέτας στα δεδομένα εκπαίδευσης (Dike et al., 2018). Οι κυριότερες προκλήσεις είναι η αυξημένη υπολογιστική πολυπλοκότητα και συνεπώς η ανάγκη για μεγαλύτερο χρόνο εκπαίδευσης, ο εγγενής κίνδυνος για ανακριβή και μη ερμηνεύσιμα αποτελέσματα καθώς και η έλλειψη διαφάνειας πάνω στον τρόπο με τον οποίο ομαδοποιήθηκαν τα δεδομένα.

Τα μοντέλα μη επιβλεπόμενης μάθησης χρησιμοποιούνται κυρίως για τρεις τύπους προβλημάτων, τη συσταδοποίηση ή ομαδοποίηση, την εκμάθηση κανόνων συσχέτισης και τη μείωση διαστατικότητας των δεδομένων. Αυτοί οι τρεις τύποι προβλημάτων περιγράφονται συνοπτικά παρακάτω:

- Ομαδοποίηση ή Συσταδοποίηση (*Clustering*): Η ομαδοποίηση έχει ως κύριο αντικείμενο την δημιουργία συστάδων που περιέχουν συνόλων παρόμοιων δεδομένων με βάση καθορισμένα κριτήρια (Omran et al., 2007). Οι αλγόριθμοι συσταδοποίησης είναι χρήσιμοι για να διαχωρίζουν δεδομένα σε πολλές ομάδες προκειμένου να αναλυθεί κάθε ομάδα δεδομένων μεμονωμένα για τον εντοπισμό σχέσεων και μοτίβων μεταξύ τους.
- Εκμάθηση κανόνων συσχέτισης (*Association Rule Learning*): Η κατηγορία της εκμάθησης κανόνων συσχέτισης εμπεριέχει μεθόδους που προσπαθούν να εντοπίσουν κανόνες για την εύρεση σχέσεων μεταξύ των μεταβλητών σε ένα σύνολο δεδομένων (Kumbhare and Chobe, 2014). Τέτοιοι αλγόριθμοι έχουν ως στόχο στον εντοπισμό ισχυρών κανόνων που καθορίζουν πως και γιατί συνδέονται ορισμένα δεδομένα
- Μείωση διαστατικότητας (*Dimensionality Reduction*): Η μείωση διαστατικότητας στοχεύει στη μείωση τον αριθμό των μεταβλητών που εξετάζονται από το μοντέλο MM και συνεπώς μπορεί να θεωρηθεί ως τεχνική προ-επεξεργασίας δεδομένων (Van Der Maaten et al., 2009). Με αυτό το μετασχηματισμό δεδομένων από ένα χώρο υψηλής διάστασης σε ένα χώρο χαμηλής διάστασης επιτυγχάνεται η τελική αναπαράσταση των δεδομένων να διατηρεί τις κυριότερες ιδιότητες των αρχικών δεδομένων, απαλλάσσοντας παράλληλα το σύνολο δεδομένο από πολλαπλά αχρείαστα χαρακτηριστικά που προκαλούν το πρόβλημα της κατάρτας της διαστατικότητας (*curse of dimensionality*).

Στις επόμενες παραγράφους περιγράφονται εν συντομία δύο από τους δημοφιλέστερους αλγορίθμους μη επιβλεπόμενης μάθησης, ο αλγόριθμος k-μέσων για συσταδοποίηση και ο αλγόριθμος ανάλυσης κυρίων συνιστωσών για μείωση διαστατικότητας. Εκτός αυτών των δύο μεθόδων υπάρχουν πολλοί αλγόριθμοι μη επιβλεπόμενης μάθησης που βρίσκουν εφαρμογές σε προβλήματα διαφόρων τομέων, όπως η ιεραρχική συσταδοποίηση (*hierarchical clustering*) (Murtagh and Contreras, 2012), αλλά το παρόν κεφάλαιο επικεντρώνεται σε αυτούς τους δύο αλγορίθμους καθώς περιγράφουν ιδανικά τη φιλοσοφία της μη επιβλεπόμενης μάθησης.

Αλγόριθμος k-μέσων

Ο αλγόριθμος *k-means* ανήκει στην κατηγορία αλγορίθμων μη επιβλεπόμενης μάθησης, χρησιμοποιείται για προβλήματα συσταδοποίησης και ο στόχος του είναι η εύρεση συστάδων (clusters) πάνω σε μη επισημασμένα δεδομένα (Likas et al., 2003). Η βασική λειτουργία του αλγορίθμου είναι ο υπολογισμός των κέντρων (*centroids*) επαναληπτικά μέχρις ότου να εντοπιστεί η βέλτιστη θέση τους. Ο αριθμός των κέντρων, και συνεπώς ο αριθμός των συστάδων, που εντοπίζονται από τον αλγόριθμο συμβολίζεται με το γράμμα k του *k-means*. Τα δεδομένα ομαδοποιούνται με τέτοιο τρόπο ώστε το άθροισμα των αποστάσεων μεταξύ των σημείων και του κέντρου της αντίστοιχης κλάσης τους να ελαχιστοποιείται (Garcia-Escudero and Gordaliza, 1999). Αξίζει να σημειωθεί πως αν η κατανομή των δεδομένων είναι τέτοια ώστε να μην υπάρχει μεγάλη ποικιλομορφία μέσα σε κάθε συστάδα, τότε υπάρχουν περισσότερα ίδια ή παρόμοια σημειακά δεδομένα σε κάθε συστάδα (Mohamad and Usman, 2013).

Πιο αναλυτικά, ο αλγόριθμος *k-means* λειτουργεί ως εξής: αρχικά δίνεται ως είσοδος ο ακριβής αριθμός των συστάδων (δηλαδή ο αριθμός k) που θα δημιουργηθούν από τον αλγόριθμο. Αυτή η επιλογή είναι εξαιρετικά σημαντική καθώς κρίνει σε μεγάλο βαθμό το αποτέλεσμα

της συσταδοποίησης (Hamerly and Elkan, 2003). Έπειτα, επιλέγονται k σημεία από το σύνολο των δεδομένων με τυχαίο τρόπο και εκχωρείται ένα σημείο σε κάθε συστάδα. Αυτή η διαδικασία ακολουθείται από τον υπολογισμό των κέντρων κάθε συστάδας. Αφού πραγματοποιηθεί η αρχικοποίηση του αλγορίθμου, στη συνέχεια ακολουθείται η εξής επαναληπτική διαδικασία έως ότου βρεθούν τα βέλτιστα κέντρα των συστάδων. Η επαναληπτική διαδικασία περιλαμβάνει τον υπολογισμό του αθροίσματος των τετραγωνικών αποστάσεων μεταξύ των σημείων και των κέντρων της αντίστοιχης συστάδας, έπειτα την εκχώρηση κάθε σημείου στην κοντινότερη συστάδα και τέλος τον επανυπολογισμό των νέων κέντρων των συστάδων. Η μέθοδος που εφαρμόζει ο k -means βασίζεται στην στρατηγική *expectation-optimization* για το εντοπισμό της μέγιστης πιθανοφάνειας σε μη επισημασμένα δεδομένα. Αυτή η επαναληπτική στρατηγική εφαρμόζει διαδοχικά την ανάθεση σημείων στην κοντινότερη συστάδα και τον επανυπολογισμό των κέντρων των συστάδων.

Κατά τη χρήση του αλγορίθμου k -means υπάρχουν δύο βασικά ζητήματα που αφορούν τη χρήση του και πρέπει να λαμβάνονται υπόψιν. Το πρώτο ζήτημα αφορά την κανονικοποίηση των δεδομένων η οποία θεωρείται απαραίτητη για το συγκεκριμένο αλγόριθμο διότι λειτουργεί με βάση την γεωμετρική απόσταση των σημείων για να πραγματοποιήσει τη διαδικασία της συσταδοποίησης. Το δεύτερο ζήτημα αφορά θέματα σύγκλισης, καθώς ο k -means ενδέχεται να αποτύχει να συγκλίνει στη βέλτιστη λύση, λόγω της χρήσης επαναληπτικής μεθόδου και της τυχαίας αρχικοποίησης των κέντρων.

Για την εύρεση της βέλτιστης τιμής για την υπερπαράμετρο k υπάρχουν δύο πολύ δημοφιλείς μέθοδοι, η μέθοδος του αγκώνα (*elbow method*) και το *silhouette score* (Naghizadeh and Metaxas, 2020). Η μέθοδος του αγκώνα απαιτεί να εκτελεστεί ο αλγόριθμος διαδοχικά για όλες τις διαφορετικές τιμές της παραμέτρου k . Για κάθε τιμή του k εντοπίζονται οι μέσες αποστάσεις των δεδομένων από τα κέντρα των συστάδων και εντοπίζεται το σημείο που παρατηρείται απότομη μείωση στη μέση απόσταση των κέντρων σχηματίζοντας έναν αγκώνα στην γραφική παράσταση. Όσον αφορά το *silhouette score*, είναι ένας δείκτης που υπολογίζει πόσο παρόμοιο είναι ένα σημειακό δεδομένο με τη δική του συστάδα (ο όρος αυτός είναι γνωστός ως *cohesion*) σε σύγκριση με άλλες συστάδες (ο όρος αυτός είναι γνωστός ως *separation*). Το *silhouette score* κυμαίνεται από -1 έως $+1$. Υψηλές τιμές υποδηλώνουν ότι ένα δεδομένο ταιριάζει ικανοποιητικά στη συστάδα του και δεν ταιριάζει στις άλλες συστάδες. Η μαθηματική έκφραση του *silhouette score* για ένα σημείο i που ανήκει στη συστάδα C_I δίνεται από την παρακάτω εξίσωση:

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}}, \text{ if } |C_I| > 1 \quad (2.12)$$

όπου το μέγεθος a_i εκφράζει την μέση απόσταση μέσα στην ίδια συστάδα, ενώ το μέγεθος b_i εκφράζει την μέση απόσταση με την κοντινότερη συστάδα στην οποία το σημείο δε συμμετέχει.

Ανάλυση Κυρίων Συνιστωσών

Η ανάλυση κυρίων συνιστωσών (*Principal Component Analysis*) είναι μια μέθοδος η οποία έχει ως κύριο στόχο τη μείωση της διάστασης μεγάλων συνόλων δεδομένων, που απαρτίζονται από πολλά χαρακτηριστικά (*features*) και συνεπώς είναι δυσκολότερο να αναλυθούν και να οδηγήσουν στην εξαγωγή συμπερασμάτων (Abdi and Williams, 2010). Συνυπολογίζοντας πως τέτοια σύνολα δεδομένων είναι όλο και πιο συχνά στην εποχή μας, η ανάλυση κυρίων συνιστωσών έχει πολλές εφαρμογές σε προβλήματα διαφόρων τομέων. Ωστόσο, πέρα από τη μείωση της διάστασης μεγάλων συνόλων δεδομένων, η τεχνική αυτή αυξάνει τη δυνατότητα ερμηνείας των δεδομένων και ελαχιστοποιεί την απώλεια πληροφορίας.

Ο τρόπος λειτουργίας της ανάλυσης κυρίων συνιστωσών περιλαμβάνει τη δημιουργία νέων μη συσχετισμένων μεταβλητών που μεγιστοποιούν τη διακύμανση μεταξύ των χαρακτηριστικών του συνόλου δεδομένων. Η εύρεση τέτοιων νέων μεταβλητών, που ονομάζονται κύριες συνιστώσες, μπορεί να θεωρηθεί ως ένα πρόβλημα εύρεσης ιδιοτιμής ή ιδιοδιανύσματος και οι νέες μεταβλητές καθορίζονται απευθείας από το σύνολο δεδομένων καθιστώντας έτσι την

ανάλυση κυρίων συνιστωσών μια προσαρμοστική (*adaptive*) τεχνική ανάλυσης δεδομένων (Shlens, 2014). Επιπλέον, η μέθοδος αυτή μπορεί να χρησιμοποιήσει διάφορες άλλες τεχνικές υποβοηθητικά ανάλογα με τον τύπο και τη δομή των δεδομένων, αυξάνοντας την προσαρμοστικότητά της.

Πιο συγκεκριμένα, η λειτουργία της ανάλυσης κυρίων συνιστωσών μπορεί να γίνει ευκολότερα αντιληπτή αν θεωρήσουμε έναν πίνακα με N σειρές που αντιπροσωπεύουν τις παρατηρήσεις του συνόλου δεδομένων και K στήλες που εκφράζουν τα χαρακτηριστικά. Έπειτα μπορούμε να φανταστούμε ένα K -διάστατο χώρο, δηλαδή ένα χώρο που έχει τόσες διαστάσεις όσα είναι και τα χαρακτηριστικά του προβλήματος, όπου κάθε χαρακτηριστικό εκφράζεται από έναν άξονα συντεταγμένων και το μήκος έχει τυποποιηθεί αφού τα δεδομένα κανονικοποιηθούν. Κάθε παρατήρηση του συνόλου δεδομένων τοποθετείται στον K -διάστατο χώρο, δημιουργώντας έτσι ένα σύνολο N σημείων διάσπαρτα σε αυτό το χώρο. Στη συνέχεια, υπολογίζονται οι μέσες τιμές των χαρακτηριστικών για κάθε μεταβλητή και δημιουργείται ένα νέο μέσο σημείο-διάνυσμα που αντιστοιχεί στο κέντρο των παρατηρήσεων. Αφαιρώντας το μέσο σημείο από τα δεδομένα πραγματοποιείται η διαδικασία της μετατόπισης του συστήματος συντεταγμένων έτσι ώστε το κέντρο των αξόνων να συμπίπτει με το μέσο σημείο. Τέλος, μπορεί να πραγματοποιηθεί διαδοχικά η διαδικασία υπολογισμού των κυρίων συνιστωσών.

Η πρώτη κύρια συνιστώσα είναι η γραμμή που προσεγγίζει καλύτερα τα δεδομένα στον χώρο μεταβλητών K διαστάσεων αν θεωρήσουμε ως κριτήριο τη μέθοδο ελαχίστων τετραγώνων. Συνεπώς, κάθε παρατήρηση προβάλλεται πάνω στη γραμμή αυτή και υπολογίζεται το νέο της σκωρ. Αντίστοιχα, η δεύτερη κύρια συνιστώσα εκφράζεται επίσης από μια ευθεία στο χώρο μεταβλητών, η οποία είναι ορθογώνια στην ευθεία της πρώτης συνιστώσας.

Γενικότερα, η ανάλυση κυρίων συνιστωσών αποτελεί μια μέθοδο μείωσης διαστάσεων που στηρίζεται στη φιλοσοφία του να εξάγει χαρακτηριστικά από ένα σύνολο δεδομένων. Δύο είναι οι κυριότερες κατηγορίες μεθόδων που χρησιμοποιούνται για τη μείωση διαστατικότητας, η εξαγωγή χαρακτηριστικών και η εξάλειψη χαρακτηριστικών. Αυτές οι κατηγορίες αναλύονται παρακάτω:

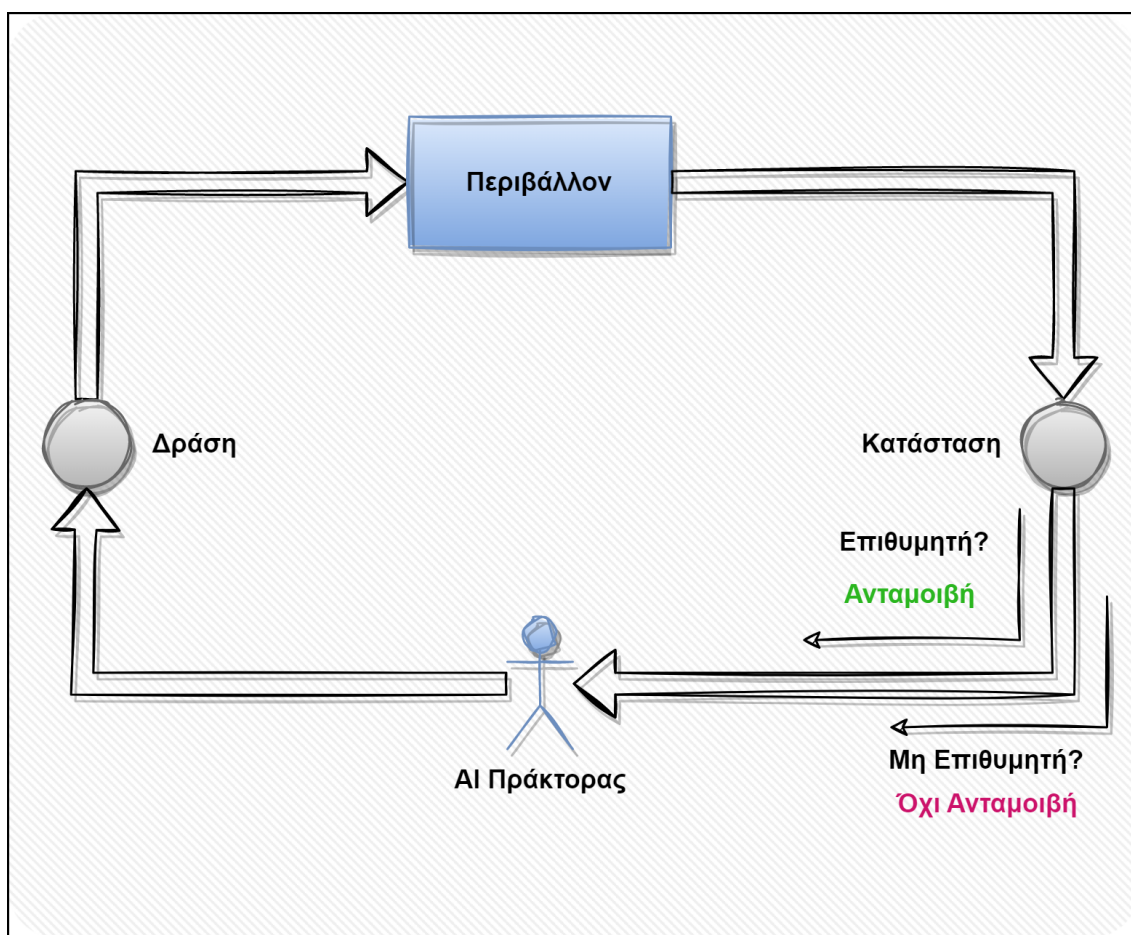
- **Εξαγωγή χαρακτηριστικών (*feature extraction*):** Στην εξαγωγή χαρακτηριστικών, δημιουργούμε νέες ανεξάρτητες μεταβλητές, όπου κάθε ανεξάρτητη μεταβλητή είναι ένας συνδυασμός των παλιών ανεξαρτήτων μεταβλητών (Guyon et al., 2008). Αυτές οι νέες μεταβλητές ταξινομούνται ανάλογα με την επίδραση τους στην πρόβλεψη της εξαρτημένης μεταβλητής. Επομένως, διατηρούνται οι καλύτερες από τις νέες μεταβλητές καθώς και οι καλύτερες παλιές. Ένα πρόσθετο πλεονέκτημα είναι πως οι νέες μεταβλητές δεν προκύπτουν ως γραμμικός συνδυασμός των παλαιών κι επομένως νέες και παλιές μεταβλητές μπορούν να διατηρηθούν χωρίς κίνδυνο να παραβιαστούν οι απαιτήσεις ενός γραμμικού μοντέλου (Khalid et al., 2014).
- **Εξάλειψη χαρακτηριστικών (*feature elimination*):** Η εξάλειψη χαρακτηριστικών περιλαμβάνει τη μείωση του πλήθους των χαρακτηριστικών αποκλείοντας ορισμένα χαρακτηριστικά (Chen and Jeong, 2007). Βασικό πλεονέκτημα των μεθόδων εξάλειψης χαρακτηριστικών είναι η απλότητα στην εφαρμογή τους καθώς και η διατήρηση της ερμηνευσιμότητας των μεταβλητών.

2.2.3 Μέθοδοι Ενισχυτικής Μάθησης

Η ενισχυτική μάθηση (*Reinforcement Learning*) ανήκει στον κλάδο της ΜΜ, ωστόσο διαφοροποιείται σημαντικά στη φιλοσοφία και τη λειτουργία της από τις κατηγορίες της επιβλεπόμενης και της μη επιβλεπόμενης μάθησης. Η ενισχυτική μάθηση έχει ως στόχο την εκμάθηση της βέλτιστης συμπεριφοράς σε ένα σαφώς οριοθετημένο περιβάλλον επιδιώκοντας τη λήψη της μέγιστης ανταμοιβής (Kaelbling et al., 1996). Η εκμάθηση της βέλτιστης συμπεριφοράς επιτυγχάνεται μέσω αλληλεπιδράσεων με το περιβάλλον, πραγματοποιώντας παρατηρήσεις για το πως ανταποκρίνεται το περιβάλλον ανάλογα με τις ενέργειες που πραγματοποιούνται. Όπως και στον πραγματικό κόσμο η εκμάθηση διαφόρων ενεργειών αιτίου-αποτελέσματος επιφέρει

σταδιακά τη γνώση για το σύνολο και τη διαδοχή ενεργειών που συμβάλλουν στην επίτευξη του στόχου. Η θεωρητική βάση της ενισχυτικής μάθησης είναι οι διαδικασίες απόφασης Markov (Otterlo and Wiering, 2012).

Δεδομένου πως στην κατηγορία των μεθόδων ενισχυτικής μάθησης δεν υπάρχει επόπτης (*supervisor*), ο αλγόριθμος πρέπει να ανακαλύψει από μόνος του το σειρά ενεργειών που επιφέρουν τη μέγιστη ανταμοιβή. Οι περισσότερες μέθοδοι ενισχυτικής μάθησης ακολουθούν μια επαναληπτική μέθοδο εκμάθησης στα πρότυπα τεχνικών *trial-and-error* κι επομένως η ανταμοιβή μπορεί να μετρηθεί με κριτήριο όχι μόνο το μέγεθος της αλλά και την καθυστέρηση στην παράδοση της. Γενικότερα, τα μοντέλα ενισχυτικής μάθησης είναι πολύ δημοφιλή την τελευταία δεκαετία επειδή μπορούν να αντιμετωπίσουν προβλήματα σε μεγάλα και αχανή περιβάλλοντα επιφέροντας τη βέλτιστη λύση χωρίς τη βοήθεια επισημασμένων δεδομένων.



Σχήμα 2.9: Η διαδικασία της Ενισχυτικής Μάθησης.

Στο Σχήμα 2.9 παρουσιάζεται το περίγραμμα ενός βασικού αλγορίθμου ενισχυτικής μάθησης. Το κυριότερο στοιχείο που διαχωρίζει τέτοιους αλγορίθμους από τους υπόλοιπους αλγορίθμους MM είναι η ύπαρξη ενός πράκτορα (*agent*) ο οποίος εξερευνά ένα άγνωστο περιβάλλον (*environment*) με σκοπό να επιτύχει έναν στόχο, ή ακριβέστερα να μεγιστοποιήσει την ανταμοιβή του (*reward*). Η ενισχυτική μάθηση εδράζεται στην υπόθεση πως κάθε στόχος μπορεί να εκφραστεί σαν ένα πρόβλημα μεγιστοποίησης της αναμενόμενης αθροιστικής ανταμοιβής (Szepesvári, 2010). Ο ρόλος του πράκτορα είναι να πραγματοποιεί ορισμένες ενέργειες (*actions*) προκειμένου να καταλάβει καλύτερα το περιβάλλον και να διαταράσσει την κατάσταση του προκειμένου να ανταμειφθεί όσο το δυνατόν καλύτερα. Επομένως με βάση αυτή την περιγραφή τα κυριότερα στοιχεία που απαρτίζουν ένα πρόβλημα ενισχυτικής μάθησης είναι:

- Ένας ή περισσότεροι πράκτορες (*agents*).

- Το σύνολο αποφάσεων που λαμβάνει ο πράκτορας για να πραγματοποιήσει μια ενέργεια (*action*).
- Το περιβάλλον (*environment*) με το οποίο αλληλοεπιδρά ο πράκτορας.
- Το σχήμα ανταμοιβής (*reward*) που εφαρμόζεται στο υπάρχον περιβάλλον.

Οι αλγόριθμοι ενισχυτικής μάθησης διακρίνονται σε *model-free* και *model-based* (Gläscher et al., 2010). Οι *model-free* αλγόριθμοι δεν κατασκευάζουν ένα ακριβές στιγμιότυπο του περιβάλλοντος, χρησιμοποιώντας, όπως αναφέρθηκε και παραπάνω, κυρίως *trial-and-error* τεχνικές για να μεγιστοποιήσουν το κέρδος. Αυτοί οι αλγόριθμοι χωρίζονται σε *policy-based* και *value-based*. Οι *policy-based* αλγόριθμοι εκτιμούν άμεσα τη βέλτιστη πολιτική χωρίς να μοντελοποιούν τη συνάρτηση τιμής, ενώ οι *value-based* αλγόριθμοι θεωρούν τη βέλτιστη πολιτική ως άμεσο αποτέλεσμα της ακριβούς εκτίμησης της συνάρτησης τιμής κάθε κατάστασης. Από την άλλη πλευρά, οι *model-based* αλγόριθμοι κατασκευάζουν ένα στιγμιότυπο του περιβάλλοντος, κωδικοποιώντας τις πιθανές καταστάσεις, τις πιθανές δράσεις που μπορεί να πραγματοποιήσει ο πράκτορας και τα πιθανά σχήματα ανταμοιβής. Πιο συγκεκριμένα, τέτοιοι αλγόριθμοι προβλέπουν την αναμενόμενη ανταμοιβή και την αναμενόμενη επόμενη κατάσταση για κάθε πιθανή παρούσα κατάσταση και επικείμενη δράση. Παραδείγματα γνωστών αλγορίθμων ενισχυτικής μάθησης είναι οι *Trust Region Policy Optimization (TRPO)* (Schulman et al., 2015), *Proximal Policy Optimization (PPO)* (Schulman et al., 2017) και *Twin Delayed Deep Deterministic Policy Gradient (TD3)* (Zhou et al., 2021).

2.3 Βαθιά Μάθηση

Όπως αναφέρθηκε στην εισαγωγή του κεφαλαίου, η BM αποτελεί ένα υποσύνολο της MM, η οποία με τη σειρά της αποτελεί ένα υποσύνολο της TN. Το κυριότερο χαρακτηριστικό της BM είναι πως έχει εμπνευστεί από τη δομή και τις λειτουργίες του ανθρώπινου εγκεφάλου, με συνέπεια οι αλγόριθμοι BM να στοχεύουν στην εξαγωγή συμπερασμάτων και την επίλυση προβλημάτων με παρόμοιο τρόπο με τους ανθρώπους, αναλύοντας δεδομένα και μοτίβα με μια δεδομένη συνέχεια και μια λογική δομή (Goodfellow et al., 2016).

Ο πυρήνας της BM είναι μια πολυεπίπεδη δομή αλγορίθμων που ονομάζονται TNΔ ή απλώς νευρωνικά δίκτυα (*neural networks*) και επιτρέπουν την μίμηση των λειτουργιών του ανθρώπινου εγκεφάλου. Επομένως, είναι λογικό πως ο σχεδιασμός ενός TNΔ βασίζεται στη δομή του ανθρώπινου εγκεφάλου. Μπορεί κανείς να προσομοιώσει τη λειτουργικότητα που έχουν οι άνθρωποι να αναγνωρίζουν διάφορα μοτίβα και να ταξινομήσουν διάφορους τύπους πληροφοριών με τη δυνατότητα των αλγορίθμων BM να αναγνωρίζουν μοτίβα και να παράγουν προβλέψεις για δεδομένα (LeCun et al., 2015). Όπως θα παρουσιαστεί λεπτομερώς στην παρακάτω ενότητα, τα TNΔ έχουν επιμέρους επίπεδα που λειτουργούν ως φίλτρα, διατηρώντας τις χρήσιμες πληροφορίες και αποβάλλοντας λεπτομέρειες που θεωρούνται άσχετες με το πρόβλημα.

Οι αλγόριθμοι BM μπορούν να χρησιμοποιηθούν σε ένα πλήθος διαφορετικών προβλημάτων όπως ομαδοποίηση, ταξινόμηση ή παλινδρόμηση. Για παράδειγμα, υπάρχουν αλγόριθμοι BM που εξυπηρετούν στην ομαδοποίηση δεδομένων χωρίς ετικέτα σύμφωνα με τις ομοιότητες μεταξύ των δειγμάτων σε αυτά τα δεδομένα, αλλά υπάρχουν και άλλοι αλγόριθμοι που χρησιμοποιούνται για ταξινόμηση ή παλινδρόμηση μέσω εκπαίδευσης ενός μοντέλου σε ένα επισημασμένο σύνολο δεδομένων. Επομένως, η BM ενσωματώνει αλγορίθμους επιβλεπόμενης και μη επιβλεπόμενης μάθησης.

Στο σημείο αυτό, και πριν παρουσιαστούν αναλυτικά οι κυριότερες κατηγορίες αλγορίθμων BM, είναι χρήσιμο να αναδειχθούν τα πλεονεκτήματα της έναντι της MM και να πραγματοποιηθεί μια αναφορά στην τεράστια συμβολή της BM στο μετασχηματισμό του κόσμου όπως τον γνωρίζουμε σήμερα. Αρχικά, πριν την ανάπτυξη της BM, βρέθηκαν για αρκετές δεκαετίες στο επίκεντρο οι αλγόριθμοι MM που αναλύσαμε στο προηγούμενο κεφάλαιο, πολλοί από τους οποίους είναι δημοφιλείς ως σήμερα. Ωστόσο, η πλειοψηφία αυτών των αλγορίθμων έχει ένα

βασικό μειονέκτημα; δε μπορούν να εφαρμοστούν απευθείας σε ανεπεξέργαστα δεδομένα με συνέπεια να απαιτείται προεπεξεργασία δεδομένων με τεχνικές εξαγωγής χαρακτηριστικών που είδαμε στο προηγούμενο κεφάλαιο. Πολλές φορές το βήμα της εξαγωγής χαρακτηριστικών είναι πολύ δύσκολο και χρονοβόρο σε περίπλοκα προβλήματα. Αντίθετα, οι αλγόριθμοι BM διαθέτουν πολλά επίπεδα (*layers*) νευρώνων, με αποτέλεσμα να είναι σε θέση να επεξεργαστούν τα πρωτογενή δεδομένα χωρίς εξαγωγή χαρακτηριστικών. Η δυναμική των αλγορίθμων BM να πραγματοποιούν από μόνοι τους την εξαγωγή χαρακτηριστικών (*feature engineering*) τα κατέστησε εξαιρετικά δημοφιλή.

Ένα ακόμη σημαντικό πλεονέκτημα των αλγορίθμων BM είναι ότι τροφοδοτείται από τεράστιες ποσότητες δεδομένων. Διανύοντας πια την εποχή των μεγάλων δεδομένων, η ύπαρξη άφθονων δεδομένων από έξυπνους μετρητές, συσκευές IoT και από άλλες πηγές προσφέρει τεράστιες ευκαιρίες για νέες καινοτομίες στη BM (Chen and Lin, 2014). Δεν είναι υπερβολή ο ισχυρισμός ότι η BM είναι ένα πολύ ισχυρό εργαλείο για πλειάδα προβλημάτων, η οποία απαιτεί ως καύσιμο τεράστιες ποσότητες δεδομένων που μπορούμε να τροφοδοτήσουμε σε αυτούς τους αλγόριθμους. Έχει παρατηρηθεί πως τα μοντέλα BM τείνουν να αυξάνουν την ακρίβειά τους με τον αυξανόμενο όγκο δεδομένων εκπαίδευσης, σε αντίθεση με τα παραδοσιακά μοντέλα MM όπως οι μηχανές διανυσμάτων υποστήριξης και ο αλγόριθμος k-πλησιέστερων γειτόνων σταματούν να βελτιώνονται σε απόδοση μετά από ένα σημείο κορεσμού.

Συμπερασματικά, όπως γίνεται εμφανές η BM διαμορφώνει ένα νέο τοπίο στον κόσμο καταφέροντας να επιλύει προβλήματα που τα μοντέλα MM δεν μπορούν να επιλύσουν (Le-Cun et al., 2015). Χαρακτηριστικά επακόλουθα της ανάπτυξης της BM είναι η ανάπτυξη τεχνολογιών όπως προηγμένα συστήματα συστάσεων (*recommender systems* της Google, του YouTube κλπ.), αλγόριθμοι αναγνώρισης κειμένου και φωνής (ακριβής μηχανή μετάφρασης και φωνητικών οδηγιών της Google), αλγόριθμοι αναγνώρισης προτύπων και όρασης υπολογιστών και πολλές άλλες. Εν τέλει, δε θα ήταν υπερβολή ο ισχυρισμός πως η BM είναι η πιο κοντινή προσέγγιση πραγματικής νοημοσύνη μηχανών που έχει υπάρξει στον κόσμο έως σήμερα.

Υπάρχουν πολλές διαφορετικές αρχιτεκτονικές αλγορίθμων BM και ΤΝΔ. Παρακάτω θα παρουσιαστούν οι τρεις κυριότερες και πιο δημοφιλείς κατηγορίες τέτοιων αλγορίθμων: Τα νευρωνικά δίκτυα πρόσθιας τροφοδότησης, τα συνελικτικά νευρωνικά δίκτυα και τα αναδρομικά νευρωνικά δίκτυα.

2.3.1 Νευρωνικά Δίκτυα Πρόσθιας Τροφοδότησης

Ένα Νευρωνικό Δίκτυο Πρόσθιας Τροφοδότησης (*Feed-Forward Neural Network - FFNN*) είναι ένα ΤΝΔ στο οποίο οι συνδέσεις (*connections*) μεταξύ των κόμβων (*nodes*) δεν σχηματίζουν κύκλους ή βρόχους στο δίκτυο (Sanger, 1989). Αυτός ο τύπος ΤΝΔ είναι ο απλούστερος τύπος αλγορίθμου BM. Η πληροφορία κινείται μόνο προς τα εμπρός από τους κόμβους εισόδου (*input nodes*) προς τους κόμβους εξόδου (*output nodes*) μέσω των κρυφών κόμβων (*hidden nodes*). Τα FFNNs χρησιμοποιούνται κυρίως για την επίλυση προβλημάτων επιβλεπόμενης μάθησης, και ειδικότερα σε περιπτώσεις όπου τα δεδομένα δεν έχουν χρονικές εξαρτήσεις.

Ο βασικότερος τύπος τέτοιων δικτύων είναι ο απλός νευρώνας perceptron, ενώ πιο σύνθετες αρχιτεκτονικές περιλαμβάνουν το perceptron πολλαπλών επιπέδων ή πολυστρωματικό perceptron. Τα δύο αυτά μοντέλα περιγράφονται αναλυτικά στις επόμενες παραγράφους.

Το Απλό Perceptron

Το απλό perceptron, επίσης γνωστό με την ονομασία νευρώνας *McCulloch-Pitts* ή *single-layer perceptron*, είναι ο απλούστερος τύπος ΤΝΔ και χρησιμοποιείται για προβλήματα επιβλεπόμενης μάθησης δυαδικών ταξινομητών μέσω μιας συνάρτησης που μπορεί να αποφασίσει εάν μια είσοδος ανήκει ή όχι σε κάποια συγκεκριμένη κλάση (Zhang and Zhang, 1999). Η

πρώτη αναφορά σε αυτό τον τύπο ΤΝΔ πραγματοποιήθηκε από τους Warren McCulloch και Walter Pitts τη δεκαετία του 1940 (Chakraverty et al., 2019).

Το απλό perceptron ανήκει στην κατηγορία των αλγορίθμων ΒΜ και επομένως περιλαμβάνει τα δομικά στοιχεία που έχουν αυτοί οι αλγόριθμοι, δηλαδή τους κόμβους εισόδου, τους κρυφούς κόμβους και τους κόμβους εξόδου. Επίσης, περιλαμβάνει τις συνδέσεις, τα βάρη και τις μεταβλητές προκατάληψης. Όλα τα δομικά στοιχεία ενός απλού perceptron περιγράφονται παρακάτω:

- Επίπεδο εισόδου (*Input Layer*): Αποτελείται από έναν ή περισσότερους κόμβους εισόδου και αφορά τις μεταβλητές που εισέρχονται στο ΤΝΔ.
- Κρυφό επίπεδο (*Hidden Layer*): Περιλαμβάνει κρυφούς κόμβους ο καθένας από τους οποίους περιέχει μια συνάρτηση ενεργοποίησης. Τα κρυφά επίπεδα βρίσκονται ανάμεσα στο επίπεδο εισόδου και στο επίπεδο εξόδου. Το απλό perceptron έχει ένα κρυφό επίπεδο, ενώ πιο περίπλοκες αρχιτεκτονικές έχουν περισσότερα.
- Επίπεδο εξόδου (*Output Layer*): Αποτελείται από έναν ή περισσότερους κόμβους εξόδου. Το επίπεδο εξόδου είναι το τελικό επίπεδο που καταλήγει το ΤΝΔ όπου παράγονται οι τελικές προβλέψεις.
- Συνδέσεις (*Connections*): Έχουν ως ρόλο να ενώνουν τους κόμβους του ΤΝΔ. Κάθε σύνδεση έχει τα δικά της βάρη και τιμές προκατάληψης, τα οποία βελτιστοποιούνται κατά την διαδικασία της εκπαίδευσης του ΤΝΔ.
- Βάρη (*Weights*): Χρησιμοποιούνται για να διαμορφώσουν την κλίμακα τιμών εισόδου και κρυφών κόμβων. Κάθε σύνδεση έχει συνήθως διαφορετικό βάρος.
- Μεταβλητές προκατάληψης (*Biases*): Χρησιμοποιούνται για την προσαρμογή των κλιμακωμένων τιμών πριν αυτές δοθούν ως είσοδος στη συνάρτηση ενεργοποίησης.
- Συνάρτηση ενεργοποίησης (*Activation Function*): Οι συναρτήσεις ενεργοποίησης χρησιμοποιούνται από το ΤΝΔ για τη δημιουργία μιας προσαρμοσμένης καμπύλης που ταιριάζει στα δεδομένα εκπαίδευσης. Περνώντας διαφορετικές τιμές εισόδου μέσω του δικτύου επιλέγονται διαφορετικά τμήματα της τυπικής καμπύλης. Υπάρχουν πολλές συναρτήσεις ενεργοποίησης, με τις Softplus, ReLU και Sigmoid να είναι οι πιο συχνά χρησιμοποιούμενες (Sharma et al., 2017).

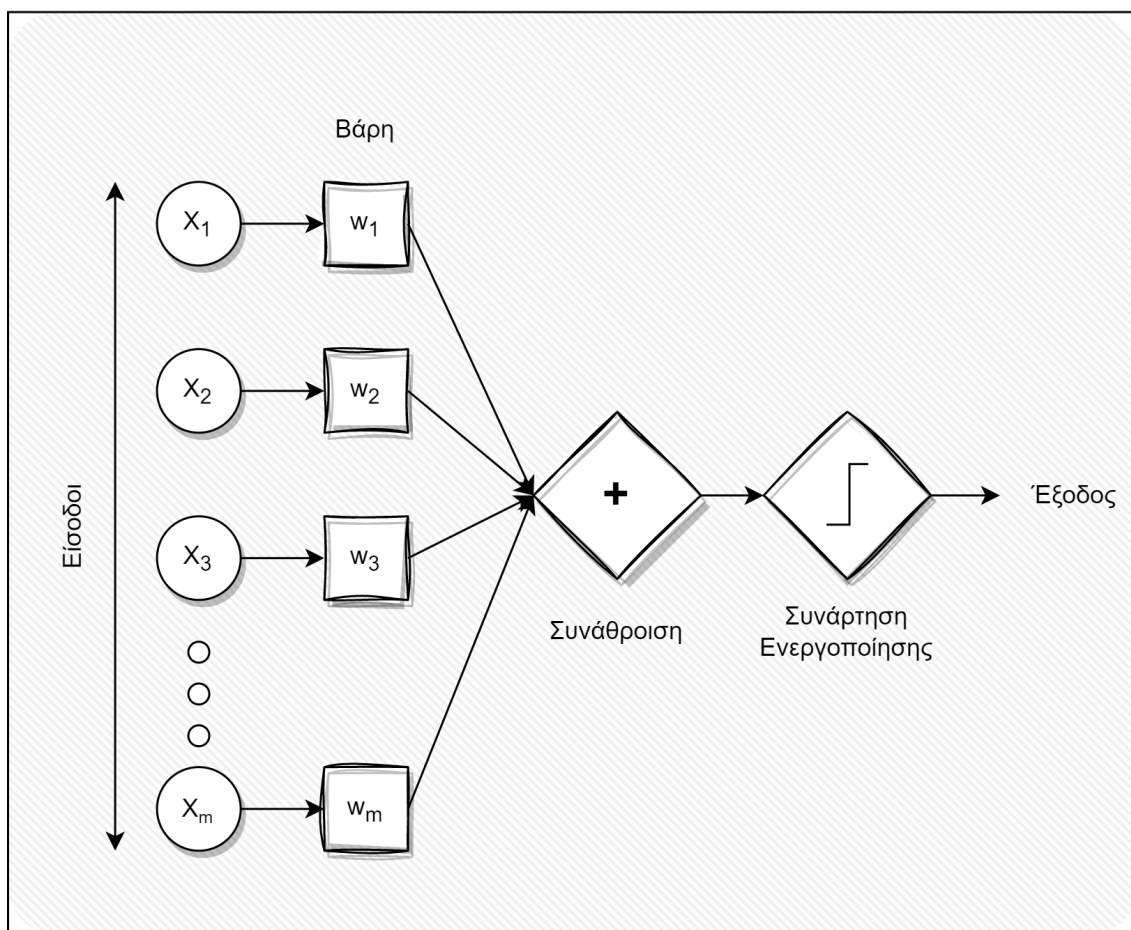
Το απλό perceptron αποτελείται από ένα μόνο επίπεδο κόμβων εξόδου. Οι είσοδοι τροφοδοτούνται απευθείας στις εξόδους μέσω μιας σειράς βαρών. Το άθροισμα των γινομένων των βαρών και των εισόδων, που ονομάζεται συνάρτηση ενεργοποίησης, υπολογίζεται σε κάθε κόμβο και αν η τιμή είναι πάνω από κάποιο όριο τότε ο νευρώνας πυροδοτείται και παίρνει την ενεργοποιημένη τιμή, ενώ αν είναι κάτω από αυτό το όριο τότε παίρνει την απενεργοποιημένη τιμή. Η παραπάνω περιγραφή της μορφής του απλού perceptron παρουσιάζεται στο Σχήμα 2.10.

Επομένως, η συνάρτηση ενεργοποίησης για το απλό perceptron δυαδικής ταξινόμησης αντιστοιχεί την είσοδο \mathbf{x} στην έξοδο $f(\mathbf{x})$ με την παρακάτω εξίσωση:

$$f(\mathbf{x}) = \begin{cases} 1 & \text{if } \sum_{i=1}^m w_i x_i + b > 0, \\ 0 & \text{otherwise} \end{cases} \quad (2.13)$$

όπου το x_i αντιπροσωπεύει το διάνυσμα των μεταβλητών εισόδου, το w_i αντιπροσωπεύει το διάνυσμα των βαρών, b είναι η μεταβλητή προκατάληψης και m ο αριθμός των εισόδων του perceptron.

Η εκπαίδευση του perceptron, αλλά και γενικότερα των αλγορίθμων ΒΜ, βασίζονται στην διαδικασία της οπισθοδιάδοσης, ευρύτερα γνωστής με τον όρο *back-propagation* (Hecht-Nielsen, 1992). Το back-propagation λειτουργεί διαδίδοντας τη συνολική απώλεια πίσω στο



Σχήμα 2.10: Σχηματική απεικόνιση του μοντέλου Perceptron.

ΤΝΔ ώστε να υπολογιστεί για ποιο ποσοστό της απώλειας ευθύνεται κάθε κόμβος. Έπειτα, ενημερώνονται τα βάρη με κριτήριο την ελαχιστοποίηση της απώλειας, δίνοντας μεγαλύτερο βάρος σε κόμβους με μικρό σφάλμα και αντίθετα μικρότερο βάρος σε κόμβους με μεγάλο σφάλμα. Η απώλεια (*loss*) είναι το σφάλμα μεταξύ πραγματικών και προβλεπόμενων τιμών. Όσο μικρότερη είναι η απώλεια, τόσο καλύτερη είναι η αντιστοίχιση μεταξύ των αληθινών και των προβλεπόμενων τιμών. Υπάρχουν πολλές συναρτήσεις απώλειας ανάλογα με το πρόβλημα, με τις πιο δημοφιλείς να είναι το μέσο τετραγωνικό σφάλμα και η cross entropy (Goh, 1995). Για να πραγματοποιηθεί το back-propagation χρησιμοποιούνται αλγόριθμοι βελτιστοποίησης (*optimizers*). Οι αλγόριθμοι βελτιστοποίησης βρίσκουν τα βέλτιστα βάρη για την ελαχιστοποίηση της απώλειας, βασιζόμενοι στην μέθοδο gradient descent. Οι γνωστότεροι αλγόριθμοι βελτιστοποίησης είναι ο *Stochastic Gradient Descent* και ο *Adam*.

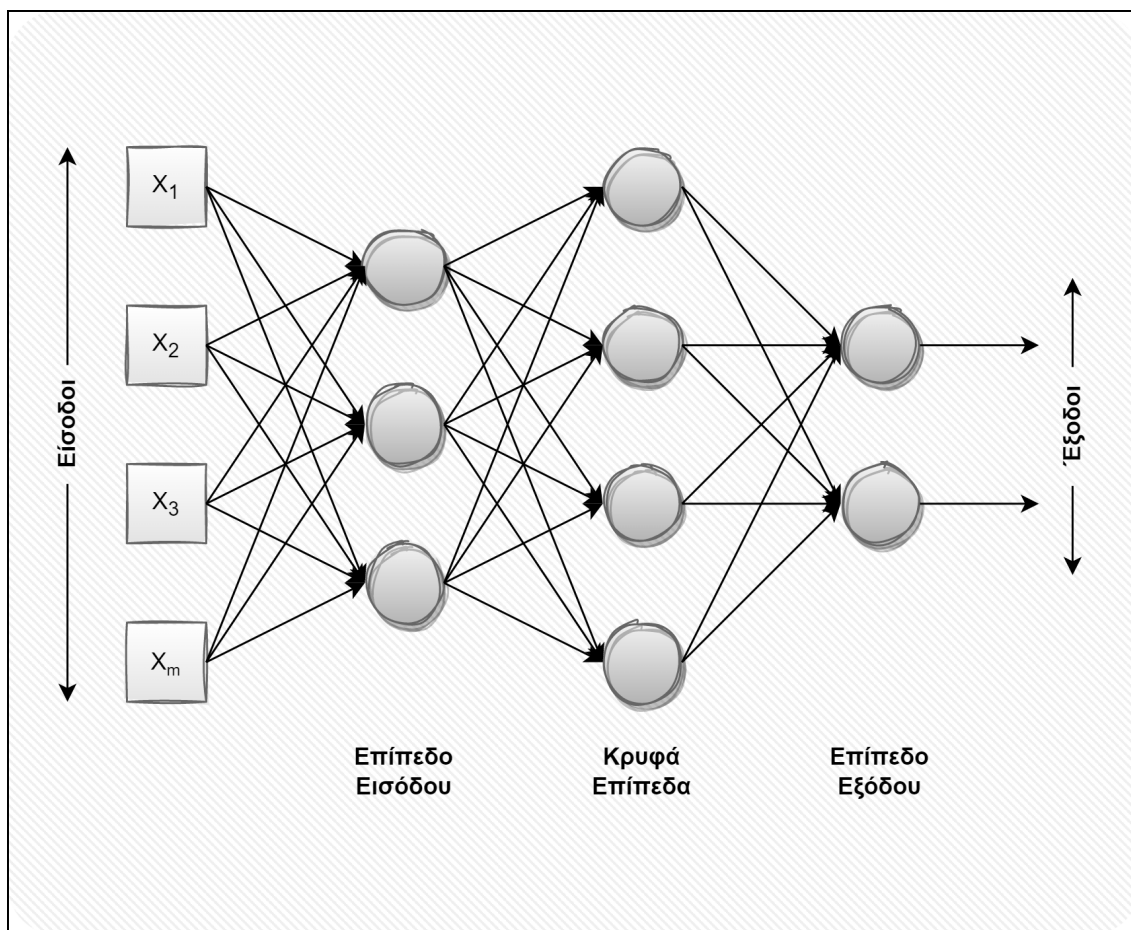
Το απλό perceptron είναι ένας γραμμικός ταξινομητής, δηλαδή μαθαίνει ένα σύνορο απόφασης με στόχο να χωρίσει δύο κλάσεις χρησιμοποιώντας μια ευθεία γραμμή στο χώρο δεδομένων (υπερεπίπεδο). Επομένως, μπορεί να μάθει μόνο γραμμικά διαχωρίσιμα (*linearly separable*) μοτίβα. Αυτό αποδείχθηκε μάλιστα το 1969 από τους Marvin Minsky και Seymour Papert, οι οποίοι απέδειξαν πως το απλό perceptron δεν μπορεί να μάθει τη συνάρτηση XOR, λόγω του ότι δεν ικανοποιεί την προϋπόθεση γραμμικότητας (Minsky and Papert, 1969).

Το Multi-layer Perceptron

Όπως είδαμε στην παραπάνω παράγραφο, το απλό perceptron είναι ένα χρήσιμο μοντέλο για την ταξινόμηση συνόλων δεδομένων τα οποία είναι γραμμικά διαχωρίσιμα. Όμως, τέτοια δίκτυα έχουν ένα θεμελιώδες πρόβλημα, καθώς αντιμετωπίζουν σοβαρούς περιορισμούς με σύνολα δεδομένων που δεν συμμορφώνονται με αυτό το μοτίβο, όπως η συνάρτηση XOR. Το

multi-layer perceptron ξεπερνάει αυτόν τον περιορισμό και ταξινομεί σύνολα δεδομένων που δεν είναι γραμμικά διαχωρίσιμα. Αυτό οφείλεται στη χρήση μιας πιο πολύπλοκης αρχιτεκτονική ώστε τα δίκτυα να μάθουν μοντέλα παλινδρόμησης και ταξινόμησης για δύσκολα, μη γραμμικά σύνολα δεδομένων (Svozil et al., 1997).

Σε αντίθεση με το perceptron που αποτελείται από ένα επίπεδο εισόδου και ένα επίπεδο εξόδου, το multi-layer perceptron αποτελείται από ένα επίπεδο εισόδου και πολλαπλά κρυφά επίπεδα τα οποία ακολουθούνται από ένα επίπεδο εξόδου. Όλα τα προαναφερθέντα επίπεδα είναι πλήρως συνδεδεμένα (fully connected layers) (Ramchoun et al., 2016). Η βασική μορφή ενός multi-layer perceptron παρουσιάζεται στο Σχήμα 2.11.



Σχήμα 2.11: Σχηματική απεικόνιση του μοντέλου Multi-layer Perceptron.

Πιο συγκεκριμένα, η βασική ιδιότητα των multi-layer perceptron δικτύων είναι η ύπαρξη πολλαπλών επιπέδων υπολογιστικών μονάδων που διασυνδέονται με τρόπο τροφοδοσίας μόνο προς τα εμπρός. Επομένως, κάθε νευρώνας ενός επιπέδου έχει κατευθυνόμενες συνδέσεις με όλους τους νευρώνες του επόμενου επιπέδου. Συνήθως, στους νευρώνες των ενδιάμεσων στρωμάτων εφαρμόζεται η σιγμοειδής (*sigmoid*) συνάρτηση ενεργοποίησης. Η σιγμοειδής συνάρτηση ενεργοποίησης εκφράζεται με τον παρακάτω μαθηματικό τύπο:

$$\sigma(x) = 1 - \sigma(-x) = \frac{1}{1 + e^{-x}} = \frac{e^x}{e^x + 1} \quad (2.14)$$

Ωστόσο, η παράγωγος της σιγμοειδούς συνάρτησης ενεργοποίησης έχει πολύ μικρές τιμές έξω από ένα μικρό εύρος και επομένως ίσως να μη λειτουργούν καλά σε βαθιά ΤΝΔ λόγω του προβλήματος vanishing gradient (Hochreiter, 1998). Το πρόβλημα του vanishing gradient εμφανίζεται ουσιαστικά όταν κατά τη διάρκεια κάθε κύκλου εκπαίδευσης, κάθε ένα από τα βάρη του ΤΝΔ λαμβάνει μια ενημέρωση ανάλογη με τη μερική παράγωγο της συνάρτησης σφάλματος σε σχέση με το τρέχον βάρος. Σε ορισμένες περιπτώσεις, η κλίση είναι εξαιρετικά

μικρή, αποτρέποντας το βάρος από το να αλλάξει τιμή, οπότε το ΤΝΔ μπορεί να σταματήσει να εκπαιδεύεται (Graves, 2012). Για την αντιμετώπιση αυτού του εμποδίου χρησιμοποιούνται εναλλακτικές συναρτήσεις ενεργοποίησης οι οποίες διευκολύνουν την εκπαίδευση βαθύτερων αρχιτεκτονικών.

Αν και τα δίκτυα multi-layer perceptron μπορούν να εκπαιδευτούν με ποικίλες τεχνικές μάθησης, η πιο δημοφιλής μεταξύ αυτών παραμένει η τεχνική back-propagation. Η τεχνική αυτή, όπως και στην περίπτωση του απλού perceptron, αφορά την ανατροφοδότηση του σφάλματος (διαφορά μεταξύ πραγματικής τιμής και πρόβλεψης) μέσα στο δίκτυο. Με βάση αυτές τις πληροφορίες ο αλγόριθμος προσαρμόζει τα βάρη κάθε σύνδεσης προκειμένου να μειώσει την τιμή της συνάρτησης σφάλματος. Αυτή η ρουτίνα εκτελείται για αρκετούς κύκλους (ή εποχές) εκπαίδευσης (*training epochs*) έως ότου το δίκτυο συγκλίνει σε κάποια σταθερή κατάσταση. Για τη ρύθμιση των βαρών το δίκτυο χρησιμοποιεί τη μέθοδο γραμμικής βελτιστοποίησης gradient descent, που βασίζεται στον υπολογισμό της παραγώγου της συνάρτησης σφάλματος (Ruder, 2016). Αυτή η μέθοδος απαιτεί την ύπαρξη παραγωγίσιμων συναρτήσεων ως συνάρτηση ενεργοποίησης.

2.3.2 Συνελικτικά Νευρωνικά Δίκτυα

Τα Συνελικτικά Νευρωνικά Δίκτυα (*Convolutional Neural Networks - CNNs*) είναι μια κατηγορία ΤΝΔ που είναι σχεδιασμένα για την επεξεργασία δομημένων συστοιχιών (*structured arrays*) δεδομένων, με χαρακτηριστικό παράδειγμα την επεξεργασία εικόνων (Alzubaidi et al., 2021). Η κυριότερη εφαρμογή των CNNs είναι στην όραση υπολογιστών, όπου αυτά τα δίκτυα είναι η πιο σύγχρονη τεχνολογία για πλήθος οπτικών εφαρμογών όπως η αναγνώριση και η ταξινόμηση εικόνων (Hijazi et al., 2015). Τα CNNs έχουν αντιμετωπίσει με παρόμοια επιτυχία προβλήματα επεξεργασίας φυσικής γλώσσας και φωνής και ταξινόμησης κειμένου (Young et al., 2018).

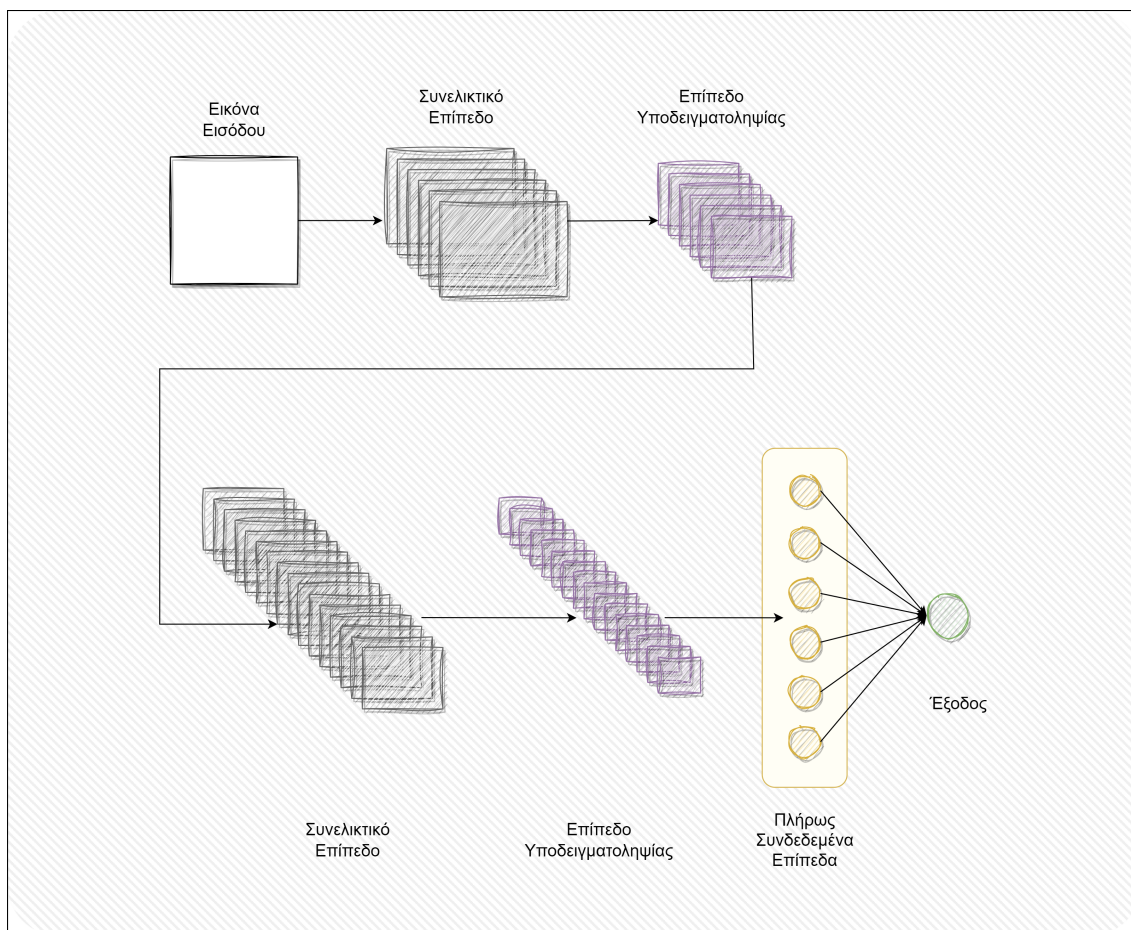
Η κύρια διαφοροποίηση των CNNs με τα κλασικά δίκτυα πρόσθιας τροφοδότησης είναι η ικανότητα τους να εντοπίζουν με ακρίβεια μοτίβα στην εικόνα εισόδου, όπως γραμμές, διαβαθμίσεις, κύκλους ή ακόμα και μάτια και πρόσωπα, εξ' ου και βρίσκουν ευρείες εφαρμογές στην όραση υπολογιστών. Ένα επιπλέον πλεονέκτημα αυτών των δικτύων είναι η ικανότητα τους να επεξεργάζονται απευθείας ακατέργαστες εικόνες χωρίς την ανάγκη καμίας προεπεξεργασίας.

Επίσης αξίζει να αναφερθεί πως τα CNNs έχουν γνωρίσει μεγάλη ανάπτυξη την τελευταία δεκαετία, λόγω της προόδου στις υπολογιστικές μονάδες (Bhatt et al., 2021). Ένα CNN είναι ένα δίκτυο βασισμένο σε αρχιτεκτονικές που συχνά έχουν έως και 30 επίπεδα, απαιτώντας μεγάλη υπολογιστική ισχύ. Συνεπώς, δε θα ήταν εύκολο να εκπαιδευτούν τέτοια δίκτυα παλαιότερα χωρίς την απαιτούμενη ισχύ, πρόβλημα που σήμερα έχει επιλυθεί με τις GPUs και TPUs (Sharif Razavian et al., 2014).

Η ακρίβεια ενός CNN στην επεξεργασία εικόνων προέρχεται από ένα ειδικό είδος επιπέδου που ονομάζεται συνελικτικό επίπεδο. Τα CNNs περιέχουν πολλά συνελικτικά επίπεδα στοιβαγμένα το ένα πάνω στο άλλο, το καθένα ικανό να αναγνωρίζει πιο εξελιγμένα σχήματα. Η χρήση συνελικτικών στρωμάτων σε ένα CNN αντικατοπτρίζει τη δομή του ανθρώπινου οπτικού φλοιού, όπου μια σειρά στρωμάτων επεξεργάζεται μια εισερχόμενη εικόνα και εντοπίζει προοδευτικά πιο πολύπλοκα χαρακτηριστικά.

Με βάση και τις προηγούμενες παραγράφους γίνεται αντιληπτό πως η αρχιτεκτονική ενός CNN είναι ένα πολυεπίπεδο FFNN, επιτρέποντας σε τέτοια δίκτυα να μάθουν ιεραρχικά τα χαρακτηριστικά ενός πολύπλοκου αντικειμένου (Shin et al., 2016). Τα κρυφά επίπεδα συνήθως αποτελούνται από συνελικτικά επίπεδα (*convolutional layers*) που ακολουθούνται από ορισμένα επίπεδα ενεργοποίησης (*activation layers*), μερικά από τα οποία με τη σειρά τους ακολουθούνται από κάποια επίπεδα συγκέντρωσης (*pooling layers*). Η αρχιτεκτονική αυτή παρουσιάζεται σχηματικά στο Σχήμα 2.12

Η παραπάνω αρχιτεκτονική είναι αντιπροσωπευτική ενός απλού CNN χωρίς πολύπλοκες δομές, όπως για παράδειγμα το LeNet-5 (LeCun et al., 1998). Θα χρησιμοποιήσουμε το LeNet-5, ως ένα απλό υπόδειγμα συνελικτικού δικτύου, για να παρουσιάσουμε τα



Σχήμα 2.12: Σχηματική απεικόνιση του μοντέλου CNN.

βασικότερα επίπεδα των συνελικτικών δικτύων. Το LeNet-5 δέχεται ως είσοδο μια εικόνα μεγέθους 32x32 pixel και την περνά από μια σειρά επιπέδων όπως απεικονίζεται στο Σχήμα 2.12. Αξίζει να σημειωθεί πως συνήθως κάθε επίπεδο ακολουθείται από μια συνάρτηση ενεργοποίησης \tanh . Εξάιρεση αποτελεί το τελευταίο επίπεδο.

Το πρώτο συνελικτικό επίπεδο αποτελείται από έξι συνελικτικούς πυρήνες οι οποίοι στο LeNet-5 έχουν μέγεθος 5x5. Το επίπεδο αυτό δέχεται την εικόνα εισόδου και εξαίρει έξι εικόνες μεγέθους 28x28 προσδιορίζοντας τα βασικά χαρακτηριστικά της εικόνας όπως ευθείες ακμές και γωνίες. Το συνελικτικό επίπεδο ακολουθείται από ένα επίπεδο υποδειγματοληψίας (*sub-sampling layer*), γνωστό και ως *average pooling layer* (Kuo, 2016). Ο ρόλος αυτού του επιπέδου είναι η μείωση του μεγέθους των εικόνων από 28x28 σε 14x14, αντιστοιχίζοντας κάθε τετράγωνο από εικονοστοιχεία (*pixels*) σε ένα μόνο εικονοστοιχείο.

Η δομή του συνελικτικού δικτύου συνεχίζει με ένα ακόμη συνελικτικό επίπεδο που έχουν ως στόχο να παράγουν ακόμη περισσότερες εικόνες, ακόμη μικρότερου μεγέθους. Χαρακτηριστικά στο LeNet-5, παράγονται 16 εικόνες με μέγεθος 10x10. Στη συνέχεια ακολουθεί ένα δεύτερο μέσο επίπεδο συγκέντρωσης, το οποίο μειώνει τις εικόνες μεγέθους 10x10 σε εικόνες μεγέθους 5x5, ανάλογα με το πρώτο επίπεδο συγκέντρωσης. Στο σημείο αυτό παρεμβάλλεται ένα πλήρως συνδεδεμένο συνελικτικό επίπεδο (*fully connected convolutional layer*), όπου στο LeNet-5 έχει 120 εξόδους. Ο ρόλος αυτού του επιπέδου είναι να δώσει πλέον ως έξοδο έναν μονοδιάστατο πίνακα και όχι εικόνες.

Τέλος, ακολουθεί συνήθως ένα απλό πλήρως συνδεδεμένο επίπεδο, το οποίο μειώνει το πλήθος των εξόδων (συγκεκριμένα στο LeNet-5 η μείωση είναι από 120 εξόδους σε 10, που αντιστοιχούν στα δέκα ψηφία). Το επίπεδο αυτό καταλήγει σε μια συνάρτηση softmax που μετατρέπει την έξοδο του σε κατανομή πιθανότητας 10 τιμών, οι οποίες πρέπει να αθροίζονται σε 1.

Το παράδειγμα που περιεγράφηκε παραπάνω αποτελεί ένα από τα απλούστερα CNNs, καθώς έχει μόλις 6 επίπεδα. Αυτό σημαίνει πως μπορεί να διακρίνει κάποια βασικά μοτίβα σε εικόνες, αλλά δε μπορεί να αναγνωρίσει περίπλοκα σχέδια όπως πρόσωπα, ζώα ή αντικείμενα. Τα πιο σύγχρονα CNNs αποτελούνται από περισσότερα από 30 επίπεδα που συνοδεύονται από χιλιάδες ή εκατομμύρια ενώσεις και διακλαδώσεις, που τα διευκολύνουν να αναγνωρίζουν με μεγάλη ακρίβεια μεγάλο πλήθος περίπλοκων εικόνων σε πολλές εφαρμογές διαφόρων τομέων (Hu et al., 2015).

2.3.3 Αναδρομικά Νευρωνικά Δίκτυα

Τα Αναδρομικά Νευρωνικά Δίκτυα (*Recurrent neural networks* ή *RNNs*) είναι μια υποκατηγορία ΤΝΔ, τα οποία ενσωματώνουν την ιδιότητα οι συνδέσεις μεταξύ των κόμβων να μπορούν να δημιουργήσουν κυκλικά μονοπάτια (Medsker and Jain, 2001). Έτσι, σε αυτό τον τύπο δικτύων η έξοδος ενός κόμβου μπορεί να επηρεάσει την είσοδο που θα εισέλθει έπειτα στον ίδιο κόμβο, σε αντίθεση με όσα ισχύουν στα FFNNs. Το κυριότερο πλεονέκτημα των RNNs είναι η δυνατότητα τους να χρησιμοποιούν την εσωτερική τους κατάσταση για να επεξεργάζονται ακολουθίες δεδομένων με μεταβλητό μήκος εισόδων που παραπέμπει στο ίδιο μέγεθος σε προηγούμενες χρονικές στιγμές. Αυτή η δυνατότητα μπορεί να παρομοιασθεί με την ύπαρξη μνήμης σε τέτοιους κόμβους, που τους επιτρέπει να επεξεργάζονται και να μαθαίνουν χρονικές δυναμικές συμπεριφορές (Mikolov et al., 2010).

Αναλυτικότερα, στα δίκτυα αυτά η πληροφορία ανακυκλώνεται μέσω βρόχων, με συνέπεια όταν χρειαστεί να προβλέψουν μια μελλοντική τιμή να εξετάζει τόσο την τρέχουσα είσοδο όσο και τις πληροφορίες που έχει μάθει από τις εισροές που έλαβε από προηγούμενες εισόδους, όπως φαίνεται και στο Σχήμα 2.13. Επομένως, ένα RNN δέχεται δύο εισόδους: παροντικές τιμές και τιμές του πρόσφατου παρελθόντος. Επιπλέον, τα RNNs εφαρμόζουν βάρη και στις παροντικές και στις παρελθοντικές εισόδους.

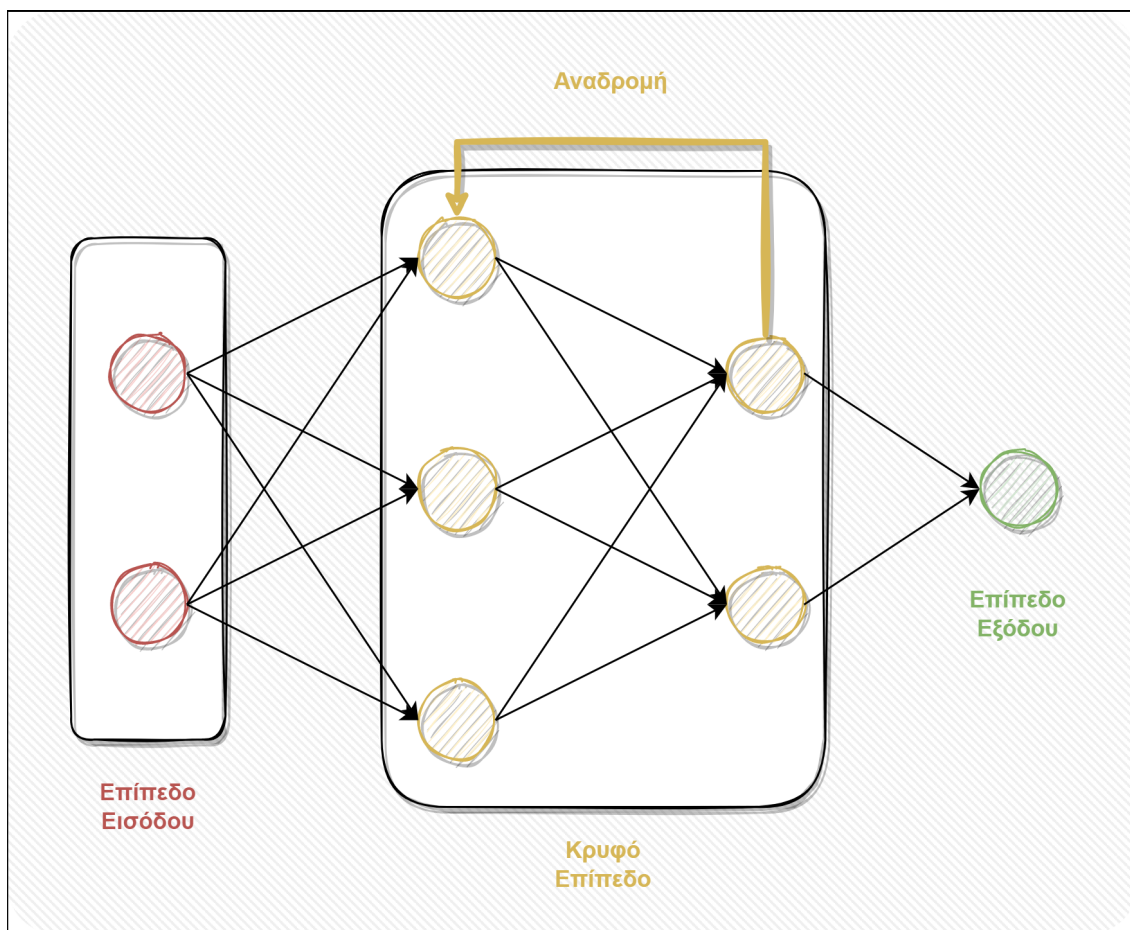
Τα RNNs χρησιμοποιούνται σε πλήθος εφαρμογών επιτυγχάνοντας εντυπωσιακής ακρίβειας αποτελέσματα. Η κυριότερη εφαρμογή τους είναι σε προβλήματα πρόβλεψης χρονοσειρών (Connor et al., 1994; Petneházi, 2019), όπου τα δίκτυα αυτά έχουν πολύ καλή επίδοση στην ακριβή πρόβλεψη ακολουθιών, σε πολλές μορφές με διαφορετικό πλήθος και τύπους εισόδων και εξόδων όπως:

- *One-to-Many*: Σε τέτοια προβλήματα, μια είσοδος χρησιμοποιείται για την πρόβλεψη πολλών εξόδων σε διαδοχικούς χρονικούς ορίζοντες (time steps).
- *Many-to-One*: Αντίθετα με την προηγούμενη κατηγορία, εδώ χρησιμοποιείται μια ακολουθία πολλών εισόδων για την πρόβλεψη μιας εξόδου σε μετέπειτα χρονικό σημείο.
- *Many-to-Many* (ή *seq2seq*): Σε τέτοια προβλήματα, δίνεται μια ακολουθία από εισόδους σε διαδοχικές χρονικές στιγμές για την πρόβλεψη μιας νέας ακολουθίας εξόδων σε μετέπειτα χρονικές στιγμές (Sutskever et al., 2014).

Πέραν αυτών των προβλημάτων πρόβλεψης, τα RNNs χρησιμοποιούνται και σε πολλές άλλες εφαρμογές. Οι συνηθέστερες εφαρμογές περιλαμβάνουν τη μοντελοποίηση φυσικής γλώσσας και την αναγνώριση κειμένου (Morchid, 2018), την αναγνώριση φωνής (Graves et al., 2013), την μετάφραση μηχανών και την αναγνώριση προτύπων (Kamijo and Tanigawa, 1990), την ταξινόμηση βίντεο, τη δημιουργία περιγραφών εικόνων και την ανάλυση τηλεφωνικών κέντρων (Jalal et al., 2016), μεταξύ πολλών άλλων.

Υπάρχουν τρεις βασικές κατηγορίες RNNs: τα Bidirectional recurrent neural networks (BRNNs), τα Long short-term memory networks (LSTMs) και τα Gated recurrent units (GRUs). Μια σύντομη περιγραφή της κάθε κατηγορίας παρουσιάζεται παρακάτω:

- *Bidirectional Recurrent Neural Networks (BRNN)*: Η φιλοσοφία του BRNN είναι να διαχωρίζει τους νευρώνες ενός κανονικού αναδρομικού δικτύου σε δύο κατευθύνσεις, μία για τη θετική χρονική κατεύθυνση (διάδοση προς τα εμπρός) και μια άλλη για



Σχήμα 2.13: Σχηματική απεικόνιση του μοντέλου RNN.

την αρνητική χρονική κατεύθυνση (διάδοση προς τα πίσω). Οι έξοδοι των δύο αυτών καταστάσεων δεν συνδέονται με τις εισόδους καταστάσεων αντίθετης κατεύθυνσης (Schuster and Paliwal, 1997).

- *Long Short-Term Memory (LSTM)*: Το LSTM είναι μια ειδική κατηγορία RNNs τα οποία μπορούν να μαθαίνουν μακροπρόθεσμες εξαρτήσεις, ειδικότερα σε προβλήματα πρόβλεψης χρονοσειρών. Το LSTM βασίζεται σε συνδέσεις ανάδρασης, όντας ικανό να επιλύσει το πρόβλημα των vanishing gradients (Graves and Schmidhuber, 2005).
- *Gated Recurrent Unit (GRU)*: Η δομή των GRUs είναι παρόμοια με το κλασικό RNN, με τη διαφορά πως ενσωματώνουν δύο διαφορετικές πύλες. Προκειμένου να αντιμετωπίσει το πρόβλημα των vanishing gradients που αντιμετωπίζουν τα τυπικά αναδρομικά δίκτυα, το GRU ενσωματώνει δύο μηχανισμούς που ονομάζονται πύλη ενημέρωσης (*update gate*) και πύλη επαναφοράς (*reset gate*) (Dey and Salem, 2017).

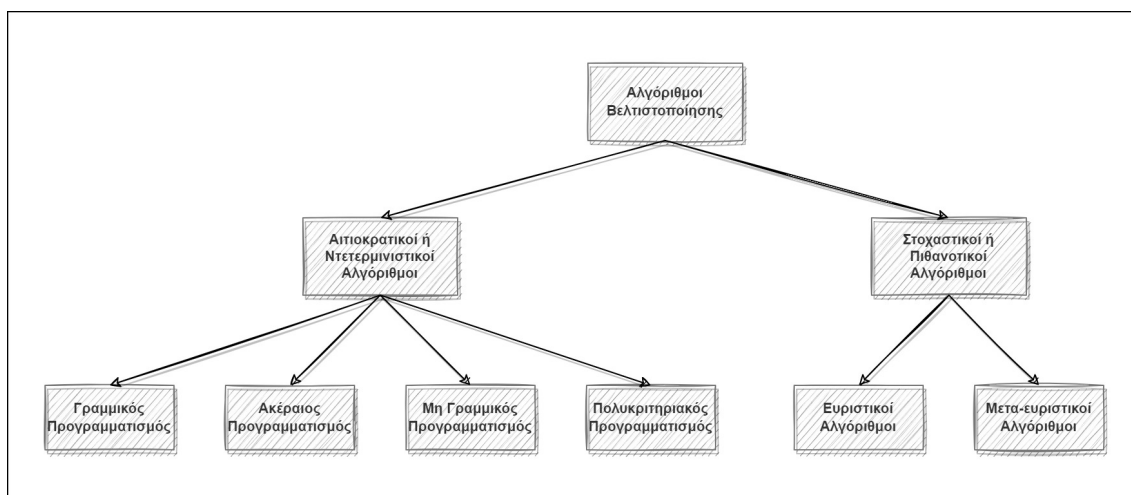
2.4 Αλγόριθμοι Βελτιστοποίησης

Πέραν του τομέα της MM, η επιστήμη των υπολογιστών είναι εφαρμόσιμη για την επίλυση προβλημάτων και τη βελτίωση διαδικασιών σε πολλούς διαφορετικούς τομείς. Η επίλυση τέτοιων προβλημάτων γίνεται εφικτή μοντελοποιώντας το πρόβλημα και τις εισόδους του με τυπικό τρόπο ώστε να πραγματοποιηθεί η επεξεργασία των διαθέσιμων δεδομένων με τον κατάλληλο αλγόριθμο επίλυσης. Η πιο τυπική χρήση αλγορίθμων επίλυσης προβλημάτων είναι η λήψη βελτιστοποιημένων λύσεων για πολύπλοκα προβλήματα απόφασης. Όπως υποδηλώνει και η παραπάνω περιγραφή, αυτοί οι αλγόριθμοι ονομάζονται **αλγόριθμοι βελτιστοποίησης**. Με τον όρο βελτιστοποίηση εννοούμε την προσπάθεια να εν-

τοπιστεί η βέλτιστη λύση σε ένα πρόβλημα. Βέβαια, κανείς πρέπει να λάβει υπ' όψιν πως ένα πρόβλημα έχει συνήθως πολλές πιθανές λύσεις (Chong and Zak, 2013). Συνεπώς, οι αλγόριθμοι βελτιστοποίησης αξιολογούν αντικειμενικές συναρτήσεις για να καθορίσουν ποια υποψήφια λύση είναι η καλύτερη.

Πολλοί ορισμοί έχουν δοθεί σε διάφορους κλάδους για τον όρο βελτιστοποίηση. Ένας από τους πιο εύστοχους ορισμός για την βελτιστοποίηση την ορίζει ως τον κλάδο που διασφαλίζει ότι ορισμένοι στόχοι επιτυγχάνονται χρησιμοποιώντας τους διαθέσιμους πόρους όπως αυτοί έχουν οριστεί από το πρόβλημα με τον πιο αποτελεσματικό τρόπο. Ο κλάδος της βελτιστοποίησης έχει χρησιμοποιηθεί αποτελεσματικά σε πληθώρα προβλημάτων για την επιτάχυνση των διαδικασιών λήψης αποφάσεων και την αύξηση της ποιότητας των αποφάσεων. Τα βασικότερα στοιχεία ενός προβλήματος βελτιστοποίησης είναι η μοντελοποίηση και η ανάλυση. Η μοντελοποίηση είναι η μαθηματική έκφραση ενός προβλήματος βελτιστοποίησης που αντιμετωπίζεται στην πραγματική ζωή, ενώ η ανάλυση περιλαμβάνει την εύρεση της βέλτιστης λύσης (Farina and Amato, 2002).

Η επίλυση των προβλημάτων βελτιστοποίησης πραγματοποιούνται με τη χρήση διαφορετικών μεθόδων ανάλυσης και αλγορίθμων. Έως σήμερα έχουν αναπτυχθεί πολλές μελέτες βελτιστοποίησης με τη χρήση διαφορετικών μεθόδων ανάλυσης και αλγορίθμων. Οι αλγόριθμοι που χρησιμοποιούνται για την επίλυση προβλημάτων βελτιστοποίησης μπορούν επίσης να αναφέρονται σύντομα ως αλγόριθμοι βελτιστοποίησης, όπως αναφέρθηκε και παραπάνω. Οι αλγόριθμοι βελτιστοποίησης χωρίζονται γενικά σε δύο κατηγορίες. Αυτές οι κατηγορίες είναι οι αιτιοκρατικοί ή ντετερμινιστικοί αλγόριθμοι (*deterministic algorithms*) και οι ευριστικοί ή στοχαστικοί αλγόριθμοι (*heuristic or stochastic algorithms*). Οι ντετερμινιστικοί αλγόριθμοι ακολουθούν μια ακριβή ακολουθία ενεργειών. Έτσι, οι μεταβλητές σχεδιασμού και η αντικειμενική συνάρτηση μπορούν να έχουν τις ίδιες τιμές και να επαναλαμβάνουν την ίδια διαδρομή για τον εντοπισμό της βέλτιστης λύσης (Lin et al., 2012). Από την άλλη πλευρά, οι ευριστικοί αλγόριθμοι εμπεριέχουν πάντα μια τυχαιότητα. Πέραν των κλασικών αυτών μεθόδων, έχουν αναπτυχθεί διάφορες μέθοδοι μέσω της υβριδικής χρήσης ντετερμινιστικών και ευριστικών μεθόδων (Silver, 2004). Με κριτήριο και την έρευνα των (Roni et al., 2022) μια ταξινόμηση των αλγορίθμων βελτιστοποίησης παρουσιάζεται στο Σχήμα 2.14.



Σχήμα 2.14: Επισκόπηση των αλγορίθμων βελτιστοποίησης.

Υπάρχουν αρκετές διαφορές μεταξύ των ντετερμινιστικών και των στοχαστικών αλγορίθμων. Οι ντετερμινιστικοί αλγόριθμοι δέχονται δεδομένα εισόδου τα οποία είναι γνωστά με ακρίβεια. Ωστόσο, Υπάρχουν πολλά προβλήματα όπου τα δεδομένα εισόδου για το συγκεκριμένο πρόβλημα δεν είναι γνωστά με ακρίβεια. Εκεί υπεισέρχεται η στοχαστική βελτιστοποίηση όπου ο αλγόριθμος βελτιστοποίησης υπό αβεβαιότητα επιλέγεται με τρόπο ώστε η αβεβαιότητα να θεωρείται υπό την παραδοχή μιας δεδομένης κατανομής πιθανότητας. Επιπλέον, υπάρχει ένας ενδιαμέσος ειδικός τύπος προβλημάτων όπου οι παράμετροι είναι γνωστές αλλά μόνο εντός συγκεκριμένων ορίων. Σε αυτές τις περιπτώσεις, οι ισχυρές τεχνικές

βελτιστοποίησης (*robust optimization*) έχει αποδειχθεί πως είναι συνήθως πιο κατάλληλες (Ben-Tal et al., 2009).

Δεν είναι ασυνήθιστο να αντιμετωπίζονται προβλήματα που είναι υπολογιστικά πολύ δύσκολα. Τότε ο χρόνος που αφιερώνεται σε υπολογισμούς δεν είναι επαρκής και υπάρχουν κάποιες ενδείξεις ότι για αυτά τα προβλήματα, οι ευριστικές τεχνικές αναζήτησης είναι καλύτερες μέθοδοι. Παραδείγματα μεθόδων ευριστικής βελτιστοποίησης είναι οι γενετικοί αλγόριθμοι και οι εξελικτικοί αλγόριθμοι. Μια συγκριτική ανασκόπηση των ντετερμινιστικών και των στοχαστικών αλγορίθμων πραγματοποιείται στον Πίνακα 2.1.

	Αιτιοκρατικοί	Στοχαστικοί
Εύρεση Βέλτιστης Λύσης	Εγγυημένη	Μη Εγγυημένη
Χρόνος Εκτέλεσης	Ίσως μεγάλος για μεγάλα προβλήματα	Μπορεί να ελεγχθεί
Παραδείγματα	Cutting Plane, Branch-and-Bound	Genetic, Grey Wolf

Πίνακας 2.1: Σύγκριση των αλγορίθμων βελτιστοποίησης.

2.4.1 Αιτιοκρατικοί Αλγόριθμοι

Ένα πρόβλημα που απαιτεί την επιλογή της βέλτιστης λύσης (*optimal solution*) από ένα σύνολο εφικτών λύσεων (*feasible solutions*) ονομάζεται πρόβλημα βελτιστοποίησης (*optimization problem*). Αυτά τα προβλήματα θεραπεύονται από ένα επιστημονικό πεδίο που ονομάζεται μαθηματικός προγραμματισμός (*mathematical optimization* ή *mathematical programming*) (Winston et al., 2003).

Η ντετερμινιστική βελτιστοποίηση έχει ως στόχο την εύρεση του καλύτερου αποτελέσματος που υπάρχει (*global optimal results*), και είναι βασισμένη σε θεωρητικές αποδείξεις που υποστηρίζουν πως το επιστρεφόμενο αποτέλεσμα είναι πράγματι το καλύτερο ανάμεσα στο σύνολο των εφικτών αποτελεσμάτων. Προκειμένου να οδηγήσουν στη λύση, οι ντετερμινιστικοί αλγόριθμοι βελτιστοποίησης εκμεταλλεύονται συγκεκριμένα χαρακτηριστικά ενός δεδομένου προβλήματος (Ben-Tal and Nemirovski, 2000). Έτσι, η ντετερμινιστική βελτιστοποίηση αναφέρεται σε κατηγορίες αλγορίθμων που περιλαμβάνουν τα ακόλουθα χαρακτηριστικά:

- Πληρότητα (*Completeness*): Οι αλγόριθμοι αυτοί επιτυγχάνουν το καλύτερο ανάμεσα σε όλα τα πιθανά αποτελέσματα με απεριόριστα μεγάλο χρόνο εκτέλεσης. Ωστόσο, είναι δυνατό να αξιολογηθεί και να βρεθεί ένα επαρκές τοπικά καλύτερο αποτέλεσμα σε πεπερασμένο χρόνο λαμβάνοντας υπόψη τις προκαθορισμένες ανοχές σε σφάλμα.
- Σχολαστικότητα (*Rigorousness*): Οι αλγόριθμοι αυτοί βρίσκουν συνολικά καλύτερα αποτελέσματα σε πεπερασμένο χρόνο εκτέλεσης και λαμβάνοντας υπόψη προκαθορισμένες ανοχές.

Η τεχνική της ντετερμινιστικής βελτιστοποίησης είναι ιδιαίτερα χρήσιμη για την επίλυση προβλημάτων με σαφή εκμεταλλεύσιμα χαρακτηριστικά που βοηθούν στον υπολογισμό του συνολικά βέλτιστου αποτελέσματος. Ωστόσο, οι ντετερμινιστικοί αλγόριθμοι μπορεί να έχουν προβλήματα στην αντιμετώπιση προβλημάτων *black-box* ή εξαιρετικά περίπλοκων και ασταθών συναρτήσεων βελτιστοποίησης, λόγω των μεγάλων χώρων αναζήτησης και περίπλοκων δομών προβλημάτων.

Υπάρχουν δύο κύριες κατηγορίες προβλημάτων βελτιστοποίησης: Η διακριτή βελτιστοποίηση αναφέρεται σε προβλήματα με διακριτές μεταβλητές και η λύση είναι ένα ή περισσότερα στοιχεία του εφικτού συνόλου, το οποίο είναι ένα μετρήσιμο σύνολο πιθανών λύσεων. Η συνεχής βελτιστοποίηση αναφέρεται σε προβλήματα με συνεχείς μεταβλητές και η λύση απαιτεί τη βελτιστοποίηση μιας συνεχούς συνάρτησης που υπόκειται σε έναν ή περισσότερους περιορισμούς ισότητας ή ανισότητας. Η έννοια της διακριτής βελτιστοποίησης

θεραπεύεται με τις μεθόδους πολυκριτήριας ανάλυσης αποφάσεων (*multi-criteria decision analysis*) (Wang et al., 2009). Σε αυτή την ενότητα, θα γίνει μια σύντομη εισαγωγή στα προβλήματα συνεχούς βελτιστοποίησης.

Η τυπική μορφή ενός προβλήματος συνεχούς βελτιστοποίησης είναι η εξής:

$$\begin{aligned} \min_x \quad & f(x) \\ \text{s. t.} \quad & g_i(x) \leq 0, \quad i = 1, \dots, m \\ & h_j(x) = 0, \quad j = 1, \dots, n \end{aligned} \quad (2.15)$$

όπου $f : \mathbb{R}^n \rightarrow \mathbb{R}$ είναι η αντικειμενική συνάρτηση που πρέπει να ελαχιστοποιηθεί σε ένα διάνυσμα, x , $g_i(x) \leq 0$ είναι περιορισμοί ανισότητας m και $h_j(x) = 0$ είναι n περιορισμοί ισότητας, όπου $m, n \geq 0$. Στον παραπάνω ορισμό, η αντικειμενική συνάρτηση θα πρέπει να ελαχιστοποιείται κατά σύμβαση. Σε περίπτωση προβλήματος μεγιστοποίησης, η αντικειμενική συνάρτηση θα πρέπει να αντιστραφεί, μετατρέποντας έτσι το πρόβλημα σε πρόβλημα ελαχιστοποίησης.

Στις επόμενες παραγράφους γίνεται αναφορά σε μερικές από τις κυριότερες κατηγορίες ντετερμινιστικών αλγορίθμων, όπως ο γραμμικός, ο τετραγωνικός, ο αχέραιος και ο πολυκριτήριος προγραμματισμός.

Γραμμικός και Τετραγωνικός Προγραμματισμός

Ο γραμμικός προγραμματισμός (*Linear Programming*) (Dantzig, 1998) είναι μια συνεχής μαθηματική μέθοδος βελτιστοποίησης που χρησιμοποιείται σε μια κατηγορία προβλημάτων βελτιστοποίησης, όταν όλοι οι περιορισμοί εκφράζονται αυστηρά με γραμμικές εξισώσεις. Πιο συγκεκριμένα, αυτή η τεχνική μπορεί να χρησιμοποιηθεί εάν η αντικειμενική συνάρτηση του προβλήματος είναι γραμμική και οι απαιτήσεις του προβλήματος είναι περιορισμοί γραμμικής ισότητας ή ανισότητας. Αυτοί οι γραμμικοί περιορισμοί σχηματίζουν ένα κυρτό πολύεδρο που ονομάζεται εφικτή περιοχή του προβλήματος. Η γραμμική συνάρτηση ορίζεται σε αυτό το πολύεδρο. Ένας αλγόριθμος γραμμικού προγραμματισμού βρίσκει το σημείο όπου αυτή η συνάρτηση έχει τη μικρότερη τιμή (για πρόβλημα ελαχιστοποίησης). Μερικές από τις πιο διάσημες εφαρμογές του γραμμικού προγραμματισμού είναι στους τομείς της επιχειρησιακής έρευνας, της μηχανικής, του προγραμματισμού και των μεταφορών.

Έστω το x να αντιπροσωπεύει ένα διάνυσμα μεταβλητών απόφασης, το b , το c να αντιπροσωπεύει διανύσματα στηλών γνωστών σταθερών και το A να αντιπροσωπεύει έναν πίνακα γνωστών σταθερών. Η κανονική μορφή του γραμμικού προβλήματος εκφράζεται ως εξής:

$$\begin{aligned} \min_x \quad & \mathbf{c}^T \mathbf{x} \\ \text{s. t.} \quad & \mathbf{A} \mathbf{x} \leq \mathbf{b} \\ & \mathbf{x} \geq \mathbf{0} \end{aligned} \quad (2.16)$$

Οι ανισότητες $\mathbf{A} \mathbf{x} \leq \mathbf{b}$ και $\mathbf{x} \geq \mathbf{0}$ είναι γραμμικοί περιορισμοί που καθορίζουν έναν κυρτό πολύεδρο.

Ένας πιο διαισθητικός ορισμός ενός προβλήματος γραμμικού προγραμματισμού είναι η τυπική φόρμα, η οποία περιλαμβάνει την περιγραφή της αντικειμενικής συνάρτησης, τις μεταβλητές απόφασης και τους περιορισμούς του προβλήματος. Υπάρχουν δύο κατηγορίες αλγορίθμων γραμμικού προγραμματισμού. Η πρώτη κατηγορία αποτελείται από αλγορίθμους ανταλλαγής, όπως ο αλγόριθμος simplex και ο διασταυρούμενος αλγόριθμος. Ο αλγόριθμος simplex εισήχθη από τον Dantzig το 1947 και είναι ένας από τους πιο αποτελεσματικούς αλγορίθμους LP (Klee and Minty, 1972). Ο αλγόριθμος ανιχνεύει μια εφικτή λύση σε μια τυχαία κορυφή του πολυέδρου και στη συνέχεια περπατά κατά μήκος των άλλων κορυφών μέχρι να βρεθεί η βέλτιστη λύση. Η δεύτερη κατηγορία αποτελείται από αλγορίθμους εσωτερικού σημείου, όπως ο ελλειψοειδής αλγόριθμος και ο προβολικός αλγόριθμος του Kar-markar (Adler et al., 1989).

Ο τετραγωνικός προγραμματισμός (*Quadratic Programming*) είναι μια συνεχής μαθηματική μέθοδος βελτιστοποίησης που χρησιμοποιείται για προβλήματα τετραγωνικής βελτιστοποίησης με γραμμικό περιορισμό (Nocedal and Wright, 2006). Πιο συγκεκριμένα, η αντικειμενική συνάρτηση είναι τετραγωνική συνάρτηση και οι περιορισμοί του προβλήματος σχηματίζονται ως γραμμικές εξισώσεις και ανισώσεις. Ο τετραγωνικός προγραμματισμός είναι ένας συγκεκριμένος τύπος μη γραμμικής βελτιστοποίησης.

Έστω το x να αντιπροσωπεύει ένα διάνυσμα n μεταβλητών απόφασης, το c ένα n -διάνυσμα διαστάσεων, το b ένα m -διάνυσμα, το Q το $n \times n$ συμμετρικό πραγματικό πίνακα και A a $m \times n$ πραγματικό διάνυσμα. Το πρόβλημα του τετραγωνικού προγραμματισμού με n μεταβλητές και m περιορισμούς διατυπώνεται ως εξής:

$$\begin{aligned} \min_x \quad & \frac{1}{2} \mathbf{x}^T Q \mathbf{x} + \mathbf{c}^T \mathbf{x} \\ \text{s.t.} \quad & A \mathbf{x} \leq \mathbf{b} \end{aligned} \quad (2.17)$$

Η λύση των προβλημάτων τετραγωνικού προγραμματισμού είναι ιδιαίτερα απλή όταν το Q είναι θετικά ορισμένο και υπάρχουν μόνο περιορισμοί ισότητας. Η λύση παράγεται χρησιμοποιώντας πολλαπλασιαστές Lagrange και αναζητώντας το ακρότατο του Lagrange. Το πρόβλημα βελτιστοποίησης χαρτοφυλακίου ανήκει σε αυτή την κατηγορία. Ως εκ τούτου δεδομένου του τετραγωνικού προβλήματος:

$$\begin{aligned} \min_x \quad & \frac{1}{2} \mathbf{x}^T Q \mathbf{x} + \mathbf{c}^T \mathbf{x} \\ \text{s.t.} \quad & A \mathbf{x} = \mathbf{b} \end{aligned} \quad (2.18)$$

αν το λ είναι ένα σύνολο πολλαπλασιαστών Lagrange, η λύση δίνεται από το γραμμικό σύστημα:

$$\begin{bmatrix} Q & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \mathbf{x} \\ \lambda \end{bmatrix} = \begin{bmatrix} -\mathbf{c} \\ \mathbf{b} \end{bmatrix} \quad (2.19)$$

Εάν το Q είναι ένας θετικός ορισμένος πίνακας, ο κατάλληλος αλγόριθμος είναι η ελλειψοειδής μέθοδος που παρέχει τη λύση σε πολυωνυμικό χρόνο. Διαφορετικά, το πρόβλημα είναι NP-hard, που σημαίνει ότι δεν υπάρχει αλγόριθμος με πολυωνυμική πολυπλοκότητα για το πρόβλημα.

Ακέραιος Προγραμματισμός

Ο ακέραιος προγραμματισμός (*Integer Programming*) είναι μια μαθηματική μέθοδος βελτιστοποίησης για ορισμένα συγκεκριμένα προβλήματα όπου όλες οι μεταβλητές περιορίζονται να είναι ακέραιοι (Wolsey, 2020). Στην ειδική περίπτωση που η αντικειμενική συνάρτηση και ένα μέρος των περιορισμών είναι γραμμικές εκφράσεις αλλά οι μεταβλητές απόφασης είναι ακέραιες μεταβλητές, η κατάλληλη μέθοδος ονομάζεται ακέραιος γραμμικός προγραμματισμός (*integer linear programming*). Ειδικότερα, σε περίπτωση που ακόμη και μερικές από τις μεταβλητές απόφασης είναι συνεχείς, η μέθοδος ονομάζεται μεικτός ακέραιος προγραμματισμός (*mixed-integer programming*) (Wolsey, 2007). Τέλος, σε περίπτωση που και μερικές από τις μεταβλητές απόφασης είναι συνεχείς και η αντικειμενική συνάρτηση ή κάποιοι από τους περιορισμούς είναι γραμμικές συναρτήσεις, τότε το πρόβλημα ανήκει σε μια συγκεκριμένη υποκατηγορία που ονομάζεται γραμμικός μεικτός ακέραιος προγραμματισμός (*mixed-integer linear programming*).

Η κανονική μορφή ενός προβλήματος ακέραιου γραμμικού προγραμματισμού εκφράζεται ως:

$$\begin{aligned} \min \quad & \mathbf{c}^T \mathbf{x} \\ \text{s.t.} \quad & A \mathbf{x} \leq \mathbf{b}, \\ & \mathbf{x} \geq \mathbf{0}, \\ \text{and} \quad & \mathbf{x} \in \mathbb{Z}^n, \end{aligned} \quad (2.20)$$

όπου \mathbf{c} , \mathbf{b} είναι διανύσματα και το A είναι ένας πίνακας, υπό τον περιορισμό ότι όλες οι εγγραφές είναι ακέραιοι.

Υπάρχουν δύο υποκατηγορίες ακέραιου προγραμματισμού ανάλογα με το εύρος των μεταβλητών απόφασης. Η πρώτη υποκατηγορία περιλαμβάνει όλα τα προβλήματα που απαιτούν λήψη απόφασης. Σε αυτά τα προβλήματα, οι ακέραιες μεταβλητές αντιπροσωπεύουν αποφάσεις με πιθανές απαντήσεις «ναι» ή «όχι», οι οποίες μεταφράζονται ως 1 ή 0. Επομένως, τα προβλήματα στα οποία οι ακέραιες μεταβλητές είναι περιορισμένες στην περιοχή $\{0, 1\}$ ονομάζονται ανήκουν στον “0-1” γραμμικό προγραμματισμό. Η δεύτερη υποκατηγορία περιλαμβάνει προβλήματα στα οποία οι ακέραιες μεταβλητές αντιπροσωπεύουν διακριτές ποσότητες, όπως ο αριθμός διακριτών τεμαχίων ενός προϊόντος. Τέτοια προβλήματα εμφανίζονται συχνά στον προγραμματισμό παραγωγής.

Τις τελευταίες δεκαετίες έχουν αναπτυχθεί ποικίλοι αλγόριθμοι, προκειμένου να βρεθεί η βέλτιστη λύση ενός προβλήματος ακέραιου προγραμματισμού. Η πιο απεικονιστική προσέγγιση ονομάζεται χαλάρωση σε γραμμικό προγραμματισμό, συνιστώντας την αφαίρεση όλων των ακέραιων περιορισμών, την επίλυση του προβλήματος “χαλαρού γραμμικού προγραμματισμού” και στη συνέχεια τη στρογγυλοποίηση της λύσης. Ωστόσο, αυτή η τεχνική μπορεί να βρει μια μη βέλτιστη λύση ή ακόμα και μια μη εφικτή, εάν παραβιαστούν κάποιοι περιορισμοί κατά τη διάρκεια της διαδικασίας στρογγυλοποίησης. Η βέλτιστη λύση μπορεί να βρεθεί επίσης με τις τεχνικές cutting plane και branch and bound. Τέλος, μια άλλη προσέγγιση για τον εντοπισμό μιας κατά προσέγγιση λύσης σε προβλήματα ακέραιου γραμμικού προγραμματισμού είναι το πεδίο των ευριστικών μεθόδων, οι οποίες δεν εγγυώνται μια βέλτιστη λύση αλλά προσφέρουν καλύτερη πολυπλοκότητα. Τέτοιες μέθοδοι θα παρουσιαστούν στην επόμενη ενότητα.

Πολυκριτήριος Προγραμματισμός

Η βελτιστοποίηση πολλαπλών στόχων ή πολυκριτήρια βελτιστοποίηση είναι ένας τομέας των πολυκριτήριων ανάλυσης συστημάτων που χρησιμοποιείται για προβλήματα μαθηματικής βελτιστοποίησης που απαιτούν περισσότερες από μία αντικειμενικές συναρτήσεις να βελτιστοποιηθούν ταυτόχρονα.

Πιο συγκεκριμένα, η πολυκριτήρια γραμμική βελτιστοποίηση (Steuer, 1986) είναι μια επέκταση του γραμμικού προγραμματισμού σε περίπτωση που υπάρχουν πολλαπλές αντικειμενικές συναρτήσεις $f_i(\mathbf{x}) = \mathbf{c}_i^T \mathbf{x}$, $i = 1, 2, \dots, k$. Το πρόβλημα διατυπώνεται ως εξής:

$$\begin{aligned} \min_{\mathbf{x}} \quad & \{f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_n(\mathbf{x})\} \\ \text{s.t.} \quad & \mathbf{Ax} \leq \mathbf{b} \\ & \mathbf{x} \geq \mathbf{0} \end{aligned} \quad (2.21)$$

Στον πολυκριτήριο προγραμματισμό, δεν υπάρχει βέλτιστη λύση λόγω της ύπαρξης πολλών αντικειμενικών συναρτήσεων, καθώς είναι αδύνατη η βελτιστοποίηση όλων των αντικειμενικών συναρτήσεων ταυτόχρονα. Συνεπώς, η έννοια της βέλτιστης λύσης αντικαθίσταται με την έννοια της αποδοτικής (ή βέλτιστης λύσης Pareto), με βάση τη θεωρία κυριαρχίας (dominance theory). Στις παραγράφους που ακολουθούν, εισάγονται οι σημαντικότεροι ορισμοί της θεωρίας πολλαπλών ιδιοτήτων (Pavlou et al., 2018).

Οποιαδήποτε λύση x που ικανοποιεί τους περιορισμούς του προβλήματος ονομάζεται εφικτή λύση (feasible solution). Το σύνολο όλων των εφικτών λύσεων ονομάζεται εφικτό σύνολο (feasible set).

Μια εφικτή λύση \mathbf{x} ονομάζεται Pareto dominant επί μιας άλλης εφικτής λύσης \mathbf{x}' εάν και μόνο εάν: (α) $f_i(\mathbf{x}) \leq f_i(\mathbf{x}')$ $\forall i \in \{1, 2, \dots, k\}$ και (β) $f_j(\mathbf{x}) < f_j(\mathbf{x}')$ για τουλάχιστον ένα $i \in \{1, 2, \dots\}$.

Μια λύση \mathbf{x}^* ονομάζεται Pareto βέλτιστη, εάν και μόνο εάν δεν υπάρχει άλλη εφικτή λύση που να κυριαρχεί επί αυτής. Το σύνολο που αποτελείται από όλες τις βέλτιστες λύσεις Pareto ονομάζεται σύνορο Pareto ή όριο Pareto (Pareto frontier ή Pareto boundary).

Τέλος, μια λύση x ονομάζεται ασθενώς βέλτιστη (weakly optimal) εάν και μόνο εάν δεν υπάρχει άλλη εφικτή λύση τέτοια ώστε $f_i(\mathbf{x}') \geq f_i(\mathbf{x}) \forall i$.

2.4.2 Στοχαστικοί Αλγόριθμοι

Η στοχαστική ή πιθανοτική βελτιστοποίηση (*stochastic optimization*) στοχεύει στην εύρεση των πιο κατάλληλων λύσεων σε πολλαπλά προβλήματα, παρόμοια με την ντετερμινιστική βελτιστοποίηση. Ωστόσο, σε αντίθεση με την ντετερμινιστική βελτιστοποίηση, οι αλγόριθμοι στοχαστικής βελτιστοποίησης χρησιμοποιούν διαδικασίες που ενσωματώνουν τυχαίους παράγοντες για την εύρεση της βέλτιστης λύσης. Λόγω των διαδικασιών που βασίζονται σε τυχαίους παράγοντες, η στοχαστική βελτιστοποίηση δεν εγγυάται την εύρεση του βέλτιστου αποτελέσματος για ένα δεδομένο πρόβλημα. Ωστόσο, υπάρχει πάντα η πιθανότητα να βρεθεί το βέλτιστο συνολικά αποτέλεσμα.

Πιο συγκεκριμένα, η πιθανότητα εύρεσης του βέλτιστου αποτελέσματος μέσω μεθόδων στοχαστικής βελτιστοποίησης σχετίζεται με τον διαθέσιμο υπολογιστικό χρόνο. Η πιθανότητα εύρεσης του βέλτιστου αποτελέσματος αυξάνεται όσο αυξάνεται ο χρόνος εκτέλεσης. Έτσι, εάν ο χρόνος εκτέλεσης είναι άπειρος, έχει αποδειχθεί πως είναι βέβαιη η εύρεση του βέλτιστου αποτελέσματος. Επομένως, με αυτόν τον τρόπο είναι αδύνατο να υπάρξει 100% βεβαιότητα για την εύρεση του βέλτιστου αποτελέσματος σε πραγματικές εφαρμογές με στοχαστικούς αλγόριθμους, καθώς σε πραγματικές συνθήκες ο χρόνος εκτέλεσης είναι πεπερασμένος.

Παρά το γεγονός αυτό, υπάρχουν πολλές πρακτικές εφαρμογές στην πραγματική ζωή στις οποίες δεν απαιτείται το global βέλτιστο αποτέλεσμα. Σε τέτοιες περιπτώσεις, αρκεί η εύρεση ενός αρκετά καλού αποτελέσματος σε εφικτό χρόνο, αναδεικνύοντας τη στοχαστική βελτιστοποίηση ως μια πολύ χρήσιμη μέθοδο λόγω της μειωμένης υπολογιστικής πολυπλοκότητας σε συνδυασμό με την εύρεση μιας αποδεκτής (αν και ίσως όχι της βέλτιστης) λύσης. Έτσι, το πιο σημαντικό πλεονέκτημα της στοχαστικής βελτιστοποίησης σε σύγκριση με την ντετερμινιστική βελτιστοποίηση είναι η δυνατότητα ελέγχου του χρόνου εκτέλεσης, επιτρέποντας τη γρήγορη εύρεση ενός αποτελέσματος για ένα σύνθετο πρόβλημα με μεγάλο χώρο αναζήτησης.

Γενικά, οι στοχαστικοί αλγόριθμοι χωρίζονται σε δύο κατηγορίες: τους ευριστικούς αλγόριθμους και τους μετα-ευριστικούς αλγόριθμους. Εν ολίγοις, οι ευριστικοί αλγόριθμοι περιλαμβάνουν στρατηγικές που χρησιμοποιούνται για την επίλυση ενός συγκεκριμένου προβλήματος. Αντίθετα, οι μετα-ευριστικοί αλγόριθμοι είναι γενικές στρατηγικές προσαρμοσμένες για την επίλυση πολλαπλών προβλημάτων. Οι δύο αυτές κατηγορίες παρουσιάζονται στις παρακάτω παραγράφους.

Ευριστικοί Αλγόριθμοι

Οι ευριστικοί αλγόριθμοι (*heuristic algorithms*) είναι τεχνικές που εξαρτώνται από το πρόβλημα. Ως εκ τούτου, συνήθως οι αλγόριθμοι αυτοί προσαρμόζονται στο πρόβλημα που αντιμετωπίζουν και προσπαθούν να εκμεταλλευτούν πλήρως τις ιδιαιτερότητες και τις ιδιότητες αυτού του προβλήματος. Ωστόσο, επειδή συνήθως ακολουθούν greedy στρατηγικές, αυτό έχει ως συνέπεια να παγιδούνται σε ένα τοπικό βέλτιστο και έτσι να αποτυγχάνουν, γενικά, να εντοπίσουν την global βέλτιστη λύση.

Καθώς οι ευριστικοί αλγόριθμοι εξαρτώνται από το πρόβλημα, δεν υπάρχει γενικό παράδειγμα στοχαστικών ευριστικών αλγορίθμων. Οι ευριστικοί αλγόριθμοι συχνά χρησιμοποιούνται για την επίλυση προβλημάτων απόφασης που ανήκουν στην κατηγορία NP-complete. Σε τέτοια προβλήματα δεν υπάρχει γνωστός αποτελεσματικός τρόπος για να βρεθεί μια λύση γρήγορα και με ακρίβεια. Επομένως, οι ευριστικοί αλγόριθμοι μπορούν να παράγουν μια λύση μεμονωμένα (όχι απαραίτητα τη βέλτιστη) ή να χρησιμοποιηθούν για να παρέχουν μια καλή βάση και συμπληρώμενοι από αλγόριθμους βελτιστοποίησης. Οι ευριστικοί αλγόριθμοι χρησιμοποιούνται συχνότερα όταν οι κατά προσέγγιση λύσεις είναι αποδεκτές, ενώ οι ακριβείς λύσεις είναι υπολογιστικά ακριβές.

Ορισμένοι ευριστικοί αλγόριθμοι βασίζονται σε ισχυρό θεωρητικό υπόβαθρο. Ωστόσο, υπάρχουν κι άλλοι οι οποίοι έχει αποδειχθεί πειραματικά πως λειτουργούν σε πραγματικές εφαρμογές δίχως να υπάρχει το θεωρητικό υπόβαθρο που να στηρίζει την εφαρμογή τους.

Επομένως, βασίζονται σε εμπειρικούς κανόνες, στην παρατήρηση ή στην εμπειρία στον πραγματικό κόσμο. Ωστόσο, τέτοιοι αλγόριθμοι βασισμένη στην παρατήρηση ή στην εμπειρία κρύβουν ορισμένους κινδύνους. Πιο συγκεκριμένα, όταν ένας ευριστικός αλγόριθμος επαναχρησιμοποιείται σε διάφορα προβλήματα επειδή έχει παρατηρηθεί πως λειτουργεί καλά σε ένα συγκεκριμένο πλαίσιο, και χωρίς να έχει αποδειχθεί μαθηματικά ότι πληροί ένα δεδομένο σύνολο απαιτήσεων, τότε είναι πιθανό το συγκεκριμένο σύνολο δεδομένων να μην αντιπροσωπεύει απαραίτητα μελλοντικά σύνολα δεδομένων. Αυτό έχει ως άμεση συνέπεια οι λύσεις να είναι επιρρεπείς στο θόρυβο και ο αλγόριθμος να μη μπορεί να αποδώσει με ίδια ακρίβεια σε άλλα προβλήματα.

Μετα-ευριστικοί Αλγόριθμοι

Όπως είδαμε στην παραπάνω παράγραφο οι ευριστικοί αλγόριθμοι εξαρτώνται από το πρόβλημα με αποτέλεσμα να μην υπάρχουν συγκεκριμένοι ευριστικοί αλγόριθμοι. Δεν ισχύει όμως το ίδιο με τους μετα-ευριστικούς αλγόριθμους (*meta-heuristic algorithms*), οι οποίοι μπορούν να χωριστούν σε κατηγορίες και υπάρχουν συγκεκριμένα παραδείγματα.

Πιο συγκεκριμένα, στην κατηγορία των μετα-ευριστικών αλγορίθμων υπόκεινται οι μέθοδοι τροχιάς (*trajectory methods*), όπως η αναζήτηση tabu, που μπορεί να χρησιμοποιηθούν σε στοχαστικές αποφάσεις. Επιπλέον, υπάρχουν μέθοδοι βασισμένες στον πληθυσμό (*population based*), όπως οι γενετικοί αλγόριθμοι, η βελτιστοποίηση grey-wolf και η βελτιστοποίηση particle swarm, που χρησιμοποιούν πολλές πλήθος τυχαίων διαδικασιών. Πολύ δημοφιλείς αλγόριθμοι στην κατηγορία των μετα-ευριστικών αλγορίθμων είναι οι εξελικτικοί αλγόριθμοι και η γενετικοί αλγόριθμοι που αποτελούν υποκατηγορία των εξελικτικών.

Πιο συγκεκριμένα, Ο εξελικτικός υπολογισμός (*evolutionary computation*) είναι ένα επιστημονικό πεδίο της ΤΝ που περιλαμβάνει μια αλγορίθμων για global βελτιστοποίηση. Τέτοιοι αλγόριθμοι είναι population-based, trial-and-error μοντέλα που ενσωματώνουν χαρακτηριστικά μετα-ευριστικής βελτιστοποίησης. Με βιολογικούς όρους, ένας πληθυσμός επιφανών λύσεων υποβάλλεται σε μια διαδικασία φυσικής επιλογής (*natural selection process*), με αποτέλεσμα μια σταδιακή εξέλιξη, βελτιστοποιώντας τη συνάρτηση καταλληλότητας (*fitness function*) του προβλήματος.

Οι εξελικτικοί αλγόριθμοι (*evolutionary algorithms*) βασίζονται στη συλλογική διαδικασία μάθησης σε έναν πληθυσμό ατόμων, καθένα από τα οποία αντιπροσωπεύει ένα σημείο αναζήτησης στο χώρο των πιθανών λύσεων σε ένα δεδομένο πρόβλημα (Bäck and Schwefel, 1993). Ο πληθυσμός αρχικοποιείται αυθαίρετα και εξελίσσεται προς όλο και καλύτερες περιοχές του χώρου αναζήτησης με τυχαιοποιημένες διαδικασίες επιλογής (*selection*), μετάλλαξης (*mutation*) και ανασυνδυασμού (*recombination*). Το περιβάλλον, που μεταφράζεται με τη fitness value, παρέχει ποιοτικές πληροφορίες σχετικά με τα σημεία αναζήτησης. Η διαδικασία επιλογής ευνοεί τα άτομα (*individuals*) με καλύτερο fitness value να αναπαράγονται πιο συχνά από εκείνα με χαμηλότερο fitness value. Ο μηχανισμός ανασυνδυασμού επιτρέπει την ανάμειξη των γονικών πληροφοριών ενώ τις μεταβιβάζει στους απογόνους τους και η μετάλλαξη εισάγει την καινοτομία στον πληθυσμό.

Οι γενετικοί αλγόριθμοι (*genetic algorithms*) είναι οι πιο γνωστοί εξελικτικοί αλγόριθμοι. Η έννοια των γενικών προσαρμοστικών διαδικασιών (*general adaptive processes*), που επικεντρώνεται στην ιδέα ενός συστήματος που λαμβάνει αισθητηριακές εισροές από το περιβάλλον με δυαδικούς ανιχνευτές, εισήχθη αρχικά από τον J. Holland το 1962 (Holland, 1962). Ως αποτέλεσμα, οι δομές στον χώρο αναζήτησης (*search space*) τροποποιήθηκαν από χειριστές που επιλέχθηκαν από έναν προσαρμοστικό σχέδιο, κρίνοντας την ποιότητα των προηγούμενων δοκιμών με μια μετρική αξιολόγησης. Σε έναν γενετικό αλγόριθμο, ένας πληθυσμός ατόμων εξελίσσεται προς καλύτερες λύσεις. Κάθε λύση περιέχει ένα σύνολο χαρακτηριστικών, που ονομάζονται χρωμοσώματα (*chromosomes*) που έχουν τη δυνατότητα να μεταλλαχθούν και να αλλοιωθούν.

2.5 Συμπεράσματα

Στο κεφάλαιο αυτό πραγματοποιήθηκε μια εμπεριστατωμένη παρουσίαση των διαφορετικών κατηγοριών αλγορίθμων TN και βελτιστοποίησης. Γενικότερα, η TN και επιστήμη υπολογιστών επικεντρώνονται στην εφαρμογή αλγορίθμων και δεδομένων για την αναπαραγωγή του τρόπου με τον οποίο μαθαίνουν οι άνθρωποι. Η πρόοδος της MM τα τελευταία χρόνια έχει σίγουρα βελτιώσει τη ζωή των ανθρώπων. Ωστόσο, η εφαρμογή της MM έχει επίσης θέσει αρκετά ηθικά ζητήματα σχετικά με τις εφαρμογές TN. Μερικά από αυτά είναι η πλήρης κατανόηση των διεργασιών που χρειάζονται αυτοματισμό, η έλλειψη ποιοτικών δεδομένων, η ανεπαρκής υποδομές και η έλλειψη εξειδικευμένου ανθρωπίνου δυναμικού.

Πιο συγκεκριμένα, ο διαχωρισμός των γεγονότων που μπορούν να αντιμετωπιστούν με μεθόδους TN από αυτά που απαιτούν απλές αποφάσεις βασισμένες σε κανόνες γίνεται όλο και πιο δύσκολος σήμερα. Προτού αποφασιστεί ποιος αλγόριθμος TN θα χρησιμοποιηθεί, πρέπει να λαμβάνεται υπόψη ποιο είναι το πρόβλημα προς επίλυση. Συνήθως, οι ευκολότερες διαδικασίες που απαιτούν αυτοματοποίηση είναι αυτές που γίνονται χειροκίνητα καθημερινά χωρίς μεταβλητή έξοδο. Αντίθετα, πιο περίπλοκες διαδικασίες απαιτούν περαιτέρω έλεγχο πριν το στάδιο της αυτοματοποίησης. Συνεπώς, ακόμη κι αν η MM μπορεί να βοηθήσει στην αυτοματοποίηση ορισμένων διαδικασιών, δεν είναι απαραίτητο πως όλα τα προβλήματα αυτοματισμού απαιτούν την εφαρμογή MM.

Επιπλέον, το νούμερο ένα πρόβλημα που αντιμετωπίζει η MM είναι η έλλειψη ποιοτικών δεδομένων. Ενώ η βελτίωση των αλγορίθμων καταναλώνει συχνά τον περισσότερο χρόνο των προγραμματιστών και των ερευνητών, η ποιότητα των δεδομένων είναι απαραίτητη για να λειτουργήσουν οι αλγόριθμοι όπως προβλέπεται. Τα θορυβώδη δεδομένα, τα βρώμικα δεδομένα και τα ελλιπή δεδομένα είναι συνήθη προβλήματα που αποτρέπουν τα μοντέλα TN να αποδώσουν το βέλτιστο. Η λύση σε αυτό το πρόβλημα είναι η αξιολόγηση των δεδομένων εφαρμόζοντας σχολαστικά τεχνικές διακυβέρνησης δεδομένων, ενοποίηση και εξερεύνηση των δεδομένων ώστε αυτά να μετασχηματιστούν στην καταλληλότερη μορφή. Μια ακόμη πρόκληση είναι η απαίτηση των αλγορίθμων MM για σύγχρονα υπολογιστικά συστήματα. Τα παλαιού τύπου υπολογιστικά συστήματα συχνά δεν μπορούν να χειριστούν τον φόρτο εργασίας που περιλαμβάνει η διαδικασία εκπαίδευσης του μοντέλου σε ένα πρόβλημα μάθησης.

Τέλος, μια σημαντική πρόκληση εκφράζεται με τον όρο της ερμηνευσιμότητας. Η ερμηνευσιμότητα σε έναν αλγόριθμο TN είναι απαραίτητη όταν οι μετρήσεις του μοντέλου δεν επαρκούν. Η ερμηνευσιμότητα μάς επιτρέπει να κατανοήσουμε τι ακριβώς μαθαίνει ένα μοντέλο, ποιες άλλες πληροφορίες έχει να προσφέρει το μοντέλο και πως δικαιολογούνται οι αποφάσεις του. Συνέπεια των παραπάνω είναι η διευκόλυνση του χρήστη να αξιολογήσει όλα τα χαρακτηριστικά του μοντέλου στο πλαίσιο του πραγματικού προβλήματος προς επίλυση. Η ερμηνευσιμότητα του μοντέλου εμπίπτει σε δύο μεγάλες κατηγορίες: τη διαφάνεια και τις εκ των υστέρων εξηγήσεις. Στη διαφάνεια, στοχεύουμε να κατανοήσουμε τον μηχανισμό με τον οποίο λειτουργεί το μοντέλο. Αντίθετα, οι εκ των υστέρων εξηγήσεις στοχεύουν στην εξαγωγή πληροφοριών από εκπαιδευμένα μοντέλα για να διασαφηνίσουν τι ακριβώς έχουν μάθει. Και οι δύο παραπάνω έννοιες είναι εξίσου σημαντικές για το χρήστη, ειδικά σε περιπτώσεις στις οποίες οι έξοδοι των μοντέλων επηρεάζουν σημαντικές αποφάσεις.

Βιβλιογραφία

- Abdi, H. and Williams, L. J. (2010). Principal component analysis. *Wiley interdisciplinary reviews: computational statistics*, 2(4):433–459.
- Adler, I., Resende, M. G., Veiga, G., and Karmarkar, N. (1989). An implementation of karmarkar’s algorithm for linear programming. *Mathematical programming*, 44(1):297–335.
- Alevizos, E. (2020). A combined machine learning and residual analysis approach for improved retrieval of shallow bathymetry from hyperspectral imagery and sparse ground truth data. *Remote Sensing*, 12(21):3489.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., and Farhan, L. (2021). Review of deep learning: Concepts, cnn architectures, challenges, applications, future directions. *Journal of big Data*, 8(1):1–74.
- Anguita, D., Ghio, A., Greco, N., Oneto, L., and Ridella, S. (2010). Model selection for support vector machines: Advantages and disadvantages of the machine learning theory. In *The 2010 international joint conference on neural networks (IJCNN)*, pages 1–8. IEEE.
- Ashari, A., Paryudi, I., and Tjoa, A. M. (2013). Performance comparison between naïve bayes, decision tree and k-nearest neighbor in searching alternative design in an energy simulation tool. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 4(11).
- Bäck, T. and Schwefel, H.-P. (1993). An overview of evolutionary algorithms for parameter optimization. *Evolutionary computation*, 1(1):1–23.
- Barlow, H. B. (1989). Unsupervised learning. *Neural computation*, 1(3):295–311.
- Bayindir, R., Yesilbudak, M., Colak, M., and Genc, N. (2017). A novel application of naive bayes classifier in photovoltaic energy prediction. In *2017 16th IEEE international conference on machine learning and applications (ICMLA)*, pages 523–527. IEEE.
- Ben-Tal, A., El Ghaoui, L., and Nemirovski, A. (2009). *Robust optimization*, volume 28. Princeton university press.
- Ben-Tal, A. and Nemirovski, A. (2000). Robust solutions of linear programming problems contaminated with uncertain data. *Mathematical programming*, 88(3):411–424.
- Bernard, S., Heutte, L., and Adam, S. (2009). Influence of hyperparameters on random forest accuracy. In *International workshop on multiple classifier systems*, pages 171–180. Springer.
- Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., Modi, K., and Ghayvat, H. (2021). Cnn variants for computer vision: History, architecture, application, challenges and future scope. *Electronics*, 10(20):2470.
- Biau, G. (2012). Analysis of a random forests model. *The Journal of Machine Learning Research*, 13(1):1063–1095.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1):5–32.
- Caruana, R. and Niculescu-Mizil, A. (2006). An empirical comparison of supervised learning algorithms. In *Proceedings of the 23rd international conference on Machine learning*, pages 161–168.

- Chakraverty, S., Sahoo, D. M., and Mahato, N. R. (2019). Mcculloch–pitts neural network model. In *Concepts of Soft Computing*, pages 167–173. Springer.
- Chen, X.-w. and Jeong, J. C. (2007). Enhanced recursive feature elimination. In *Sixth International Conference on Machine Learning and Applications (ICMLA 2007)*, pages 429–435. IEEE.
- Chen, X.-W. and Lin, X. (2014). Big data deep learning: challenges and perspectives. *IEEE access*, 2:514–525.
- Chong, E. K. and Zak, S. H. (2013). *An introduction to optimization*, volume 75. John Wiley & Sons.
- Connor, J. T., Martin, R. D., and Atlas, L. E. (1994). Recurrent neural networks and robust time series prediction. *IEEE transactions on neural networks*, 5(2):240–254.
- Cover, T. and Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1):21–27.
- Craven, B. and Islam, S. M. (2011). Ordinary least-squares regression. *The SAGE dictionary of quantitative management research*, pages 224–228.
- Cunningham, P., Cord, M., and Delany, S. J. (2008). Supervised learning. In *Machine learning techniques for multimedia*, pages 21–49. Springer.
- Dantzig, G. (1998). Linear programming and extensions, ser.
- Demšar, J. and Zupan, B. (2021). Hands-on training about overfitting. *PLoS Computational Biology*, 17(3):e1008671.
- Dey, R. and Salem, F. M. (2017). Gate-variants of gated recurrent unit (gru) neural networks. In *2017 IEEE 60th international midwest symposium on circuits and systems (MWSCAS)*, pages 1597–1600. IEEE.
- Dike, H. U., Zhou, Y., Deveerasetty, K. K., and Wu, Q. (2018). Unsupervised learning based on artificial neural network: A review. In *2018 IEEE International Conference on Cyborg and Bionic Systems (CBS)*, pages 322–327. IEEE.
- Dismuke, C. and Lindrooth, R. (2006). Ordinary least squares. *Methods and Designs for Outcomes Research*, 93:93–104.
- Dumais, S., Platt, J., Heckerman, D., and Sahami, M. (1998). Inductive learning algorithms and representations for text categorization. In *Proceedings of the seventh international conference on Information and knowledge management*, pages 148–155.
- Esposito, F., Malerba, D., Semeraro, G., and Kay, J. (1997). A comparative analysis of methods for pruning decision trees. *IEEE transactions on pattern analysis and machine intelligence*, 19(5):476–491.
- Farina, M. and Amato, P. (2002). On the optimal solution definition for many-criteria optimization problems. In *2002 annual meeting of the North American fuzzy information processing society proceedings. NAFIPS-FLINT 2002 (Cat. No. 02TH8622)*, pages 233–238. IEEE.
- Garcia-Escudero, L. A. and Gordaliza, A. (1999). Robustness properties of k means and trimmed k means. *Journal of the American Statistical Association*, 94(447):956–969.

- Gläscher, J., Daw, N., Dayan, P., and O'Doherty, J. P. (2010). States versus rewards: dissociable neural prediction error signals underlying model-based and model-free reinforcement learning. *Neuron*, 66(4):585–595.
- Goh, A. T. (1995). Back-propagation neural networks for modeling complex systems. *Artificial intelligence in engineering*, 9(3):143–151.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep learning*. MIT press.
- Graves, A. (2012). Long short-term memory. *Supervised sequence labelling with recurrent neural networks*, pages 37–45.
- Graves, A., Mohamed, A.-r., and Hinton, G. (2013). Speech recognition with deep recurrent neural networks. In *2013 IEEE international conference on acoustics, speech and signal processing*, pages 6645–6649. Ieee.
- Graves, A. and Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional lstm and other neural network architectures. *Neural networks*, 18(5-6):602–610.
- Guyon, I., Gunn, S., Nikravesh, M., and Zadeh, L. A. (2008). *Feature extraction: foundations and applications*, volume 207. Springer.
- Hamerly, G. and Elkan, C. (2003). Learning the k in k-means. *Advances in neural information processing systems*, 16.
- Harrell, F. E. (2015). Ordinal logistic regression. In *Regression modeling strategies*, pages 311–325. Springer.
- Hassanat, A. B., Abbadi, M. A., Altarawneh, G. A., and Alhasanat, A. A. (2014). Solving the problem of the k parameter in the knn classifier using an ensemble learning approach. *arXiv preprint arXiv:1409.0919*.
- Hastie, T., Tibshirani, R., and Friedman, J. (2009a). Overview of supervised learning. In *The elements of statistical learning*, pages 9–41. Springer.
- Hastie, T., Tibshirani, R., and Friedman, J. (2009b). Random forests. In *The elements of statistical learning*, pages 587–604. Springer.
- Hastie, T., Tibshirani, R., and Friedman, J. (2009c). Unsupervised learning. In *The elements of statistical learning*, pages 485–585. Springer.
- Hecht-Nielsen, R. (1992). Theory of the backpropagation neural network. In *Neural networks for perception*, pages 65–93. Elsevier.
- Hidalgo, B. and Goodman, M. (2013). Multivariate or multivariable regression? *American journal of public health*, 103(1):39–40.
- Hijazi, S., Kumar, R., Rowen, C., et al. (2015). Using convolutional neural networks for image recognition. *Cadence Design Systems Inc.: San Jose, CA, USA*, 9.
- Hochreiter, S. (1998). The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 6(02):107–116.
- Holland, J. H. (1962). Outline for a logical theory of adaptive systems. *Journal of the ACM (JACM)*, 9(3):297–314.
- Hu, W., Huang, Y., Wei, L., Zhang, F., and Li, H. (2015). Deep convolutional neural networks for hyperspectral image classification. *Journal of Sensors*, 2015.

- Isa, N. E. M., Amir, A., Ilyas, M. Z., and Razalli, M. S. (2017). The performance analysis of k-nearest neighbors (k-nn) algorithm for motor imagery classification based on eeg signal. In *MATEC web of conferences*, volume 140, page 01024. EDP Sciences.
- Jahromi, A. H. and Taheri, M. (2017). A non-parametric mixture of gaussian naive bayes classifiers based on local independent features. In *2017 Artificial intelligence and signal processing conference (AISP)*, pages 209–212. IEEE.
- Jalal, M. E., Hosseini, M., and Karlsson, S. (2016). Forecasting incoming call volumes in call centers with recurrent neural networks. *Journal of Business Research*, 69(11):4811–4814.
- Jordan, M. I. and Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245):255–260.
- Kaelbling, L. P., Littman, M. L., and Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4:237–285.
- Kamijo, K.-i. and Tanigawa, T. (1990). Stock price pattern recognition—a recurrent neural network approach. In *1990 IJCNN international joint conference on neural networks*, pages 215–221. IEEE.
- Khalid, S., Khalil, T., and Nasreen, S. (2014). A survey of feature selection and feature extraction techniques in machine learning. In *2014 science and information conference*, pages 372–378. IEEE.
- Kibriya, A. M., Frank, E., Pfahringer, B., and Holmes, G. (2004). Multinomial naive bayes for text categorization revisited. In *Australasian Joint Conference on Artificial Intelligence*, pages 488–499. Springer.
- King, J. E. (2008). Binary logistic regression. *Best practices in quantitative methods*, pages 358–384.
- Kirkos, E., Spathis, C., and Manolopoulos, Y. (2007). Data mining techniques for the detection of fraudulent financial statements. *Expert systems with applications*, 32(4):995–1003.
- Klee, V. and Minty, G. J. (1972). How good is the simplex algorithm. *Inequalities*, 3(3):159–175.
- Kleinbaum, D. G., Dietz, K., Gail, M., Klein, M., and Klein, M. (2002). *Logistic regression*. Springer.
- Kotsiantis, S. B., Zaharakis, I. D., and Pintelas, P. E. (2006). Machine learning: a review of classification and combining techniques. *Artificial Intelligence Review*, 26(3):159–190.
- Kumbhare, T. A. and Chobe, S. V. (2014). An overview of association rule mining algorithms. *International Journal of Computer Science and Information Technologies*, 5(1):927–930.
- Kuo, C.-C. J. (2016). Understanding convolutional neural networks with a mathematical model. *Journal of Visual Communication and Image Representation*, 41:406–413.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *nature*, 521(7553):436–444.
- LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324.

- Li, B., Friedman, J., Olshen, R., and Stone, C. (1984). Classification and regression trees (cart). *Biometrics*, 40(3):358–361.
- Likas, A., Vlassis, N., and Verbeek, J. J. (2003). The global k-means clustering algorithm. *Pattern recognition*, 36(2):451–461.
- Lin, M.-H., Tsai, J.-F., and Yu, C.-S. (2012). A review of deterministic optimization methods in engineering and management. *Mathematical Problems in Engineering*, 2012.
- Maron, O. and Moore, A. W. (1997). The racing algorithm: Model selection for lazy learners. *Artificial Intelligence Review*, 11(1):193–225.
- Maulud, D. and Abdulazeez, A. M. (2020). A review on linear regression comprehensive in machine learning. *Journal of Applied Science and Technology Trends*, 1(4):140–147.
- Medsker, L. R. and Jain, L. (2001). Recurrent neural networks. *Design and Applications*, 5:64–67.
- Mikolov, T., Karafiát, M., Burget, L., Cernocký, J., and Khudanpur, S. (2010). Recurrent neural network based language model. In *Interspeech*, volume 2, pages 1045–1048. Makuhari.
- Minsky, M. and Papert, S. (1969). An introduction to computational geometry. *Cambridge tiass.*, *HIT*, 479:480.
- Mitchell, T. M. (1997). *Machine learning*, volume 1. McGraw-hill New York.
- Mohamad, I. B. and Usman, D. (2013). Standardization and its effects on k-means clustering algorithm. *Research Journal of Applied Sciences, Engineering and Technology*, 6(17):3299–3303.
- Montgomery, D. C., Peck, E. A., and Vining, G. G. (2021). *Introduction to linear regression analysis*. John Wiley & Sons.
- Morchid, M. (2018). Parsimonious memory unit for recurrent neural networks with application to natural language processing. *Neurocomputing*, 314:48–64.
- Murtagh, F. and Contreras, P. (2012). Algorithms for hierarchical clustering: an overview. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 2(1):86–97.
- Myles, A. J., Feudale, R. N., Liu, Y., Woody, N. A., and Brown, S. D. (2004). An introduction to decision tree modeling. *Journal of Chemometrics: A Journal of the Chemometrics Society*, 18(6):275–285.
- Naghizadeh, A. and Metaxas, D. N. (2020). Condensed silhouette: An optimized filtering process for cluster selection in k-means. *Procedia Computer Science*, 176:205–214.
- Negnevitsky, M. (2005). *Artificial intelligence: a guide to intelligent systems*. Pearson education.
- Noble, W. S. (2006). What is a support vector machine? *Nature biotechnology*, 24(12):1565–1567.
- Nocedal, J. and Wright, S. J. (2006). Quadratic programming. *Numerical optimization*, pages 448–492.
- Omran, M. G., Engelbrecht, A. P., and Salman, A. (2007). An overview of clustering methods. *Intelligent Data Analysis*, 11(6):583–605.

- Otterlo, M. v. and Wiering, M. (2012). Reinforcement learning and markov decision processes. In *Reinforcement learning*, pages 3–42. Springer.
- Pavlou, A., Doumpos, M., and Zopounidis, C. (2018). The robustness of portfolio efficient frontiers: A comparative analysis of bi-objective and multi-objective approaches. *Management Decision*.
- Peng, G. et al. (2004). Testing normality of data using sas. *Indianapolis: Lilly Corporate Center*.
- Petneházi, G. (2019). Recurrent neural networks for time series forecasting. *arXiv preprint arXiv:1901.00069*.
- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Taieb, S. B., Bergmeir, C., Bessa, R. J., Bijak, J., Boylan, J. E., et al. (2022). Forecasting: theory and practice. *International Journal of Forecasting*.
- Platt, J. et al. (1999). Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods. *Advances in large margin classifiers*, 10(3):61–74.
- Quinlan, J. R. (1987). Simplifying decision trees. *International journal of man-machine studies*, 27(3):221–234.
- Ramchoun, H., Ghanou, Y., Ettaouil, M., and Janati Idrissi, M. A. (2016). Multilayer perceptron: Architecture optimization and training. *International Journal of Interactive Multimedia and Artificial Intelligence . . .*
- Rish, I. et al. (2001). An empirical study of the naive bayes classifier. In *IJCAI 2001 workshop on empirical methods in artificial intelligence*, volume 3, pages 41–46.
- Roni, M., Karim, H., Rana, M., Pota, H., Hasan, M., Hussain, M., et al. (2022). Recent trends in bio-inspired meta-heuristic optimization techniques in control applications for electrical systems: A review. *International Journal of Dynamics and Control*, pages 1–13.
- Rosenblatt, F. (1957). *The perceptron, a perceiving and recognizing automaton Project Para*. Cornell Aeronautical Laboratory.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747*.
- Samuel, A. L. (1959). Machine learning. *The Technology Review*, 62(1):42–45.
- Sanger, T. D. (1989). Optimal unsupervised learning in a single-layer linear feedforward neural network. *Neural networks*, 2(6):459–473.
- Schein, A. I. and Ungar, L. H. (2007). Active learning for logistic regression: an evaluation. *Machine Learning*, 68(3):235–265.
- Schuchmann, S. (2019). History of the first ai winter. *Towards Data Science, May*, 12.
- Schulman, J., Levine, S., Abbeel, P., Jordan, M., and Moritz, P. (2015). Trust region policy optimization. In *International conference on machine learning*, pages 1889–1897. PMLR.
- Schulman, J., Wolski, F., Dhariwal, P., Radford, A., and Klimov, O. (2017). Proximal policy optimization algorithms. *arXiv preprint arXiv:1707.06347*.

- Schuster, M. and Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE transactions on Signal Processing*, 45(11):2673–2681.
- Schützenmeister, A., Jensen, U., and Piepho, H.-P. (2012). Checking normality and homoscedasticity in the general linear model using diagnostic plots. *Communications in Statistics-Simulation and Computation*, 41(2):141–154.
- Sharif Razavian, A., Azizpour, H., Sullivan, J., and Carlsson, S. (2014). Cnn features off-the-shelf: an astounding baseline for recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, pages 806–813.
- Sharma, S., Sharma, S., and Athaiya, A. (2017). Activation functions in neural networks. *towards data science*, 6(12):310–316.
- Shin, M., Kim, M., and Kwon, D.-S. (2016). Baseline cnn structure analysis for facial expression recognition. In *2016 25th IEEE international symposium on robot and human interactive communication (RO-MAN)*, pages 724–729. IEEE.
- Shlens, J. (2014). A tutorial on principal component analysis. *arXiv preprint arXiv:1404.1100*.
- Silver, E. A. (2004). An overview of heuristic solution methods. *Journal of the operational research society*, 55(9):936–956.
- Singh, A., Halgamuge, M. N., and Lakshmiganthan, R. (2017). Impact of different data types on classifier performance of random forest, naive bayes, and k-nearest neighbors algorithms. *International Journal of Advanced Computer Science and Applications*, 8(12).
- Spyromitros, E., Tsoumakas, G., and Vlahavas, I. (2008). An empirical study of lazy multilabel classification algorithms. In *Hellenic conference on artificial intelligence*, pages 401–406. Springer.
- Steuer, R. E. (1986). Multiple criteria optimization. *Theory, computation and applications*.
- Strobl, C., Malley, J., and Tutz, G. (2009). An introduction to recursive partitioning: rationale, application, and characteristics of classification and regression trees, bagging, and random forests. *Psychological methods*, 14(4):323.
- Suthaharan, S. (2016a). Supervised learning algorithms. In *Machine learning models and algorithms for big data classification*, pages 183–206. Springer.
- Suthaharan, S. (2016b). Support vector machine. In *Machine learning models and algorithms for big data classification*, pages 207–235. Springer.
- Sutskever, I., Vinyals, O., and Le, Q. V. (2014). Sequence to sequence learning with neural networks. *Advances in neural information processing systems*, 27.
- Svozil, D., Kvasnicka, V., and Pospichal, J. (1997). Introduction to multi-layer feed-forward neural networks. *Chemometrics and intelligent laboratory systems*, 39(1):43–62.
- Szepesvári, C. (2010). Algorithms for reinforcement learning. *Synthesis lectures on artificial intelligence and machine learning*, 4(1):1–103.
- Van Der Maaten, L., Postma, E., Van den Herik, J., et al. (2009). Dimensionality reduction: a comparative. *J Mach Learn Res*, 10(66-71):13.
- Walker, S. H. and Duncan, D. B. (1967). Estimation of the probability of an event as a function of several independent variables. *Biometrika*, 54(1-2):167–179.

- Wang, H., Lei, Z., Zhang, X., Zhou, B., and Peng, J. (2016). Machine learning basics. *Deep learning*, pages 98–164.
- Wang, J.-J., Jing, Y.-Y., Zhang, C.-F., and Zhao, J.-H. (2009). Review on multi-criteria decision analysis aid in sustainable energy decision-making. *Renewable and sustainable energy reviews*, 13(9):2263–2278.
- Winston, W. L., Venkataramanan, M., and Goldberg, J. B. (2003). *Introduction to mathematical programming*, volume 1. Thomson/Brooks/Cole Duxbury, Pacific Grove, CA.
- Wolsey, L. A. (2007). Mixed integer programming. *Wiley Encyclopedia of Computer Science and Engineering*, pages 1–10.
- Wolsey, L. A. (2020). *Integer programming*. John Wiley & Sons.
- Wu, Y. and Liu, Y. (2007). Robust truncated hinge loss support vector machines. *Journal of the American Statistical Association*, 102(479):974–983.
- Young, T., Hazarika, D., Poria, S., and Cambria, E. (2018). Recent trends in deep learning based natural language processing. *iee Computational intelligence magazine*, 13(3):55–75.
- Zhang, L. and Zhang, B. (1999). A geometrical representation of mcculloch-pitts neural model and its applications. *IEEE Transactions on Neural Networks*, 10(4):925–929.
- Zhang, S., Li, X., Zong, M., Zhu, X., and Cheng, D. (2017). Learning k for knn classification. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 8(3):1–19.
- Zhang, Z. (2016). Introduction to machine learning: k-nearest neighbors. *Annals of translational medicine*, 4(11).
- Zhou, J., Xue, S., Xue, Y., Liao, Y., Liu, J., and Zhao, W. (2021). A novel energy management strategy of hybrid electric vehicle via an improved td3 deep reinforcement learning. *Energy*, 224:120118.
- Zhu, X. J. (2005). *Semi-supervised learning literature survey*. University of Wisconsin-Madison Department of Computer Sciences.

Κεφάλαιο 3

Διατύπωση Προβλήματος και Επισκόπηση Συσχετιζόμενης Βιβλιογραφίας

3.1 Εισαγωγή

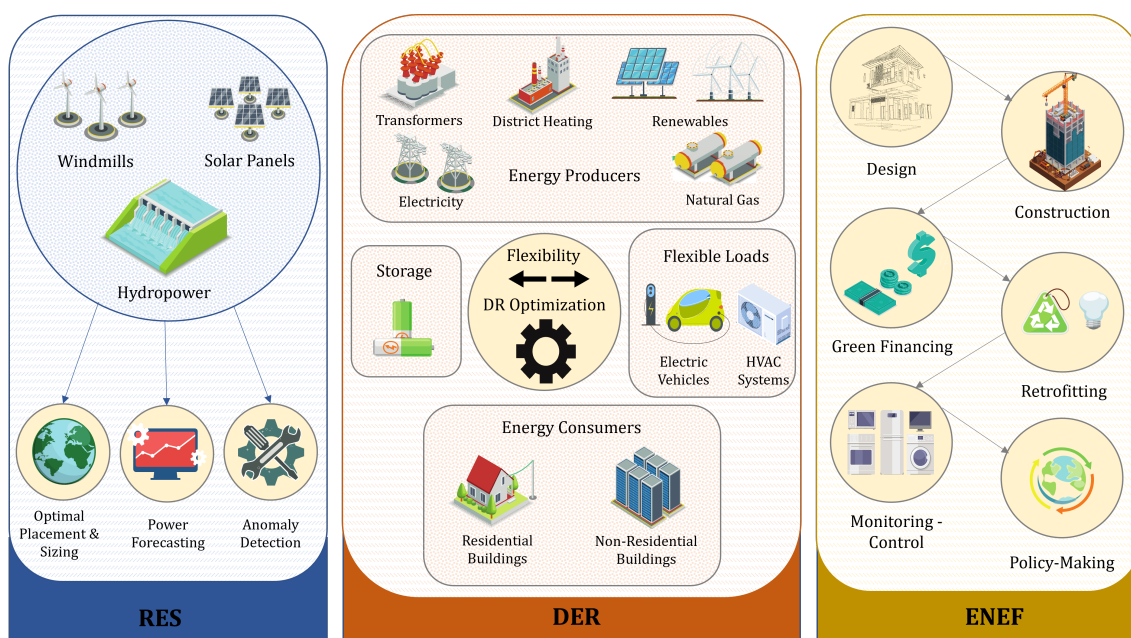
Η ταχεία ανάπτυξη της τεχνολογίας των αισθητήρων, των τεχνολογιών ασύρματης μετάδοσης και των δικτυακών επικοινωνιών καθώς και η ραγδαία εξέλιξη του υπολογιστικού νέφους (*cloud computing*) και των έξυπνων φορητών μετρητικών συσκευών, έχουν επιφέρει τη συσσώρευση μεγάλων δεδομένων σε πολλούς τομείς της ζωής μας. Δε θα ήταν υπερβολή να ισχυριστεί κανείς πως διανύουμε την εποχή των μεγάλων δεδομένων, αφού -όπως αναφέρεται και στο άρθρο της McKinsey σχεδόν μια δεκαετία πριν ([Heck and Rogers, 2014](#))- ο όγκος των διαθέσιμων πηγών πληροφοριών αυξάνεται ταχύτατα, δημιουργώντας πρωτοφανείς ευκαιρίες για μια νέα βιομηχανική επανάσταση. Ταυτόχρονα, η μορφή των δεδομένων γίνεται όλο και πιο περίπλοκη επιφέροντας την ανάγκη για σύγχρονους τρόπους διαχείρισης, αποθήκευσης και επεξεργασίας της πληροφορίας.

Ο τομέας της ενέργειας δε θα μπορούσε να παραμείνει ανεπηρέαστος από αυτές τις εξελίξεις. Οι καινοτομίες που επιφέρουν τα μεγάλα δεδομένα διαμορφώνουν ένα νέο τοπίο στη βιομηχανία της ενέργειας. Η διαθεσιμότητα μεγάλου όγκου δεδομένων παραγωγής και κατανάλωσης ενέργειας υποβοηθούν στη διεύθυνση καινοτόμων εφαρμογών της πληροφορικής, εντείνοντας τη διαδικασία ψηφιοποίησης των ενεργειακών συστημάτων ([Zhou et al., 2016](#)). Τέτοια σύγχρονα ενεργειακά συστήματα μπορούν να αντιμετωπίσουν μεγάλες σύγχρονες προκλήσεις στον τομέα της ενέργειας όπως η λειτουργική αποδοτικότητα, η βέλτιστη διαχείριση των ΑΠΕ, η σταθερότητα και η αξιοπιστία των ενεργειακών συστημάτων και ο σχεδιασμός κτιρίων, έξυπνων δικτύων και ολοκληρωμένων συστημάτων ενέργειας, μεταξύ άλλων ([Amin, 2008](#); [Momoh, 2009](#)). Όλα αυτά έχουν ως απώτερο σκοπό αφ' ενός την ομαλή πράσινη μετάβαση, και αφ' ετέρου τον έλεγχο και μείωση του κόστους, μέσω της υλοποίησης συστημάτων ευφυούς διαχείρισης ενέργειας.

Επιπλέον, η τεχνολογική επανάσταση έχει δημιουργήσει νέους όρους και καινοτομίες, που δε θα μπορούσαν να είναι εφικτά στα παραδοσιακά ενεργειακά συστήματα. Ένας από τους σημαντικότερους τέτοιους όρους είναι το έξυπνο δίκτυο (*smart grid*), το οποίο μπορεί να προσδιοριστεί ως ένα δίκτυο ηλεκτρικής ενέργειας που βασίζεται στην ψηφιακή τεχνολογία, με οφέλη την αποτελεσματικότερη μεταφορά της ηλεκτρικής ενέργειας, την ταχύτερη αποκατάσταση μετά από διακοπές ρεύματος, τη βέλτιστη χρήση των ΑΠΕ και το μειωμένο κόστος λειτουργίας και διαχείρισης ([Amin and Wollenberg, 2005](#); [Fadlullah et al., 2011](#)). Τα έξυπνα δίκτυα, μαζί με καινοτόμες τεχνικές λύσεις για την αποθήκευση της ενέργειας και την ενσωμάτωση καταναμημένων πόρων μπορούν να αποδειχθούν σε βασικό παράγοντα στην πράσινη ενεργειακή μετάβαση. Παράλληλα, τα έξυπνα δίκτυα ενσωματώνουν την έννοια της ροής της πληροφορίας (*information flow*), δηλαδή την αποθήκευση μεγάλου όγκου δεδομένων,

που μετέπειτα μπορεί να αξιοποιηθεί μέσα από μεθόδους TN για να υποστηρίξει απόφασης βελτιστοποίησης είτε σε επίπεδο δίκτυο (Zhou et al., 2014), είτε από την πλευρά της παραγωγής ή της κατανάλωσης ενέργειας σε επίπεδο κτιρίου (Fan and Hyndman, 2011). Συνεπώς, μπορεί να γίνει αντιληπτό πως η ανάλυση μεγάλων δεδομένων και η εφαρμογή μεθόδων TN επιτρέπει την μεθοδικότερη και αποδοτικότερη υποστήριξη αποφάσεων για πλήθος ενδιαφερόμενων μερών (*stakeholders*), με κυριότερους τους παραγωγούς, τους καταναλωτές και τις ρυθμιστικές αρχές.

Στο κεφάλαιο αυτό πραγματοποιείται μια λεπτομερής βιβλιογραφική ανασκόπηση των βασικότερων προβλημάτων στον ενεργειακό τομέα που μπορούν να αντιμετωπιστούν με τη χρήση μεθόδων TN και υπολογιστικής βελτιστοποίησης. Όπως αναφέρθηκε και στο κεφάλαιο της Εισαγωγής, τα προβλήματα ομαδοποιούνται σε τρεις επιμέρους συνιστώσες: την καταναεμημένη παραγωγή (**AI-4-RES**), την ευελιξία σε επίπεδο μικροδικτύου (**AI-4-FLEX**) και την ενεργειακή αποδοτικότητα κτιρίων (**AI-4-ENEF**). Οι τρεις συνιστώσες παρουσιάζονται αναλυτικότερα στο Σχήμα 3.1. Για καθεμία από τις προαναφερθείσες κατηγορίες πραγματοποιείται καταγραφή των κυριότερων προβλημάτων που έχουν εντοπιστεί στη διεθνή βιβλιογραφία, ενώ παράλληλα παρουσιάζονται οι κυριότερες εφαρμογές TN που έχουν αναπτυχθεί τις τελευταίες δεκαετίες ανά κατηγορία προβλημάτων.



Σχήμα 3.1: Παρουσίαση των τριών επιμέρους κατηγοριών εφαρμογών της TN στον τομέα της ενέργειας.

Η δομή του κεφαλαίου είναι η εξής: Αρχικά πραγματοποιείται μια περιγραφή του ρόλου και της σημασίας των μεγάλων δεδομένων στον τομέα της ενέργειας. Εν συνεχεία, αναλύονται οι τρεις κύριες κατηγορίες προβλημάτων όπως διατυπώθηκαν παραπάνω. Δίνεται έμφαση στην καταγραφή των σημαντικότερων επιμέρους προβλημάτων ανά κατηγορία, αλλά και στους τρόπους, τις μεθόδους και τις τεχνικές με τις οποίες η TN έχει συνδράμει στην επίλυση των συγκεκριμένων προβλημάτων. Τέλος, συλλέγονται χρήσιμα συμπεράσματα και μελλοντικές προοπτικές που προκύπτουν από την ανασκόπηση της βιβλιογραφίας.

3.2 Ο ρόλος των Μεγάλων Δεδομένων στον Ενεργειακό Τομέα

Τα μεγάλα δεδομένα επηρεάζουν καθοριστικά τον τρόπο παραγωγής ενέργειας και διαμορφώνουν νέα πρότυπα κατανάλωσης ενέργειας. Τα μεγάλα δεδομένα στον ενεργειακό τομέα επιφέρουν πλήθος ευκαιριών αλλά και προκλήσεων ταυτόχρονα, προκειμένου να υποβοηθηθούν στην πράσινη ενεργειακή μετάβαση που εκφράζεται μέσα από τα 4 'Ds'. Οι κυριότερες προκλήσεις που μπορούν να διατυπωθούν περιλαμβάνουν την προτυποποίηση του τρόπου συλλογής, αποθήκευσης και αποδοτικής διαχείρισης των μεγάλων ενεργειακών δεδομένων, την αποτελεσματική ανάλυση της πληροφορίας και τη χρήση τους για την υποστήριξη της λήψης αποφάσεων σε σημαντικά ενεργειακά προβλήματα (Zhou et al., 2016). Ο στόχος είναι η απόκτηση γνώσης σε πραγματικό χρόνο και η προσθήκη αξίας στα δεδομένα που συλλέγονται, ενώ ταυτόχρονα λαμβάνονται υπόψη όλες οι πολιτικές απορρήτου και ιδιωτικότητας. Τα δεδομένα, δίχως την κατάλληλη επεξεργασία και ανάλυση, παραμένουν απλώς ψηφία. Αντίθετα, αν αξιοποιηθούν σωστά μπορούν να οδηγήσουν σε νέα γνώση και στην επίλυση σύνθετων προβλημάτων.

Επομένως, είναι ιδιαίτερος κρίσιμος να αξιοποιήσουμε πλήρως τις δυνατότητες και τις ευκαιρίες που προσφέρουν τα μεγάλα δεδομένα και παράλληλα να αντιμετωπίσουμε τις διάφορες προκλήσεις που δημιουργούνται. Το πρώτο βήμα προς την επίτευξη αυτού του στόχου και τη μετάφραση των μεγάλων δεδομένων σε γνώση είναι η γνώση των πηγών προέλευσης τους και η κατανόηση της δομής και των χαρακτηριστικών τους (Sagiroglu and Sinanc, 2013). Γενικότερα, τα μεγάλα δεδομένα χαρακτηρίζονται από τα λεγόμενα 5 Vs: τον όγκο (Volume), την ποικιλομορφία (Variety), την ταχύτητα (Veracity), την αξιοπιστία (Veracity) και τελικά την αξία (Value). Αυτά τα χαρακτηριστικά, δε θα μπορούσαν να εκλείπουν και από τα μεγάλα ενεργειακά δεδομένα (Jiang et al., 2016; Hu and Vasilakos, 2016), όπως παρουσιάζεται παρακάτω:

- **Volume:** Όπως είναι φυσικό, η ευρεία χρήση έξυπνων μετρητικών συστημάτων και αισθητήρων σε κτίρια, ΑΠΕ και δίκτυα ηλεκτρικής ενέργειας επιφέρουν την συσσώρευση τεράστιου όγκου δεδομένων. Ο όγκος των δεδομένων αποτελεί μια από τις μεγαλύτερες προκλήσεις στο χώρο της πληροφορικής και αντικατοπτρίζεται σε όλες τις φάσεις του κύκλου ζωής των δεδομένων, όπως η ανάλυση, η αποθήκευση και η επεξεργασία (Al-Salim et al., 2017). Μάλιστα, η αποθήκευση όλων των παραγόμενων δεδομένων αποτελεί μειονέκτημα για οργανισμούς που βασίζουν τις δράσεις τους στα δεδομένα, καθιστώντας την αναγνώριση συγκεκριμένων συνόλων δεδομένων δύσκολη και απαιτώντας καλές διαδικασίες συνάντησης.
- **Velocity:** Η ταχύτητα ως χαρακτηριστικό των μεγάλων δεδομένων αναφέρεται κατά κύριο λόγο στην απαίτηση για συλλογή, επεξεργασία, ανάλυση και χρήση των διαθέσιμων ενεργειακών δεδομένων. Υπάρχουν πολλές διαφορετικές περιπτώσεις όσον αφορά στην ταχύτητα και τη χρονική ανάλυση της εισερχόμενης πληροφορίας. Πολλοί μετρητές παρέχουν τη δυνατότητα για καταγραφή δεδομένων σε σχεδόν πραγματικό χρόνο, προσφέροντας δεδομένα σε ανάλυση μερικών δευτερολεπτών έως ενός λεπτού, ενώ άλλοι λειτουργούν σε πιο αραιά χρονικά διαστήματα παρέχοντας μια τιμή σε διάστημα ενός τετάρτου ή μια ωριαία τιμή. Τα περισσότερα ενεργειακά προβλήματα, ωστόσο, απαιτούν την ανάλυση πληροφορίας σε πραγματικό χρόνο. Ζητήματα όπως η παρακολούθηση της σταθερότητας του ηλεκτρικού δικτύου και η πρόβλεψη της παραγωγής και της ζήτησης, απαιτούν δεδομένα σε υψηλή χρονική ανάλυση (δευτερόλεπτα ή λεπτά), προκειμένου να είναι εφικτή η εκπαίδευση μοντέλων που παρέχουν ακριβείς προβλέψεις και συστάσεις. Συνεπώς, ο χειρισμός δεδομένων διαφορετικών χρονικών αναλύσεων και ταχυτήτων είναι μια σημαντική πρόκληση.
- **Variety:** Η ποικιλομορφία των ενεργειακών δεδομένων είναι αδιαμφισβήτητο ένα πολύ σημαντικό θέμα που δημιουργεί ανάγκη για ευφυή συστήματα διαχείρισης δεδομένων και

για σχεδιασμό διαδικασιών προτυποποίησης των πληροφοριών σε κοινά πρότυπα. Πιο συγκεκριμένα, τα έξυπνα ενεργειακά συστήματα περιλαμβάνουν διαφορετικούς τύπους δεδομένων, όπως σχεσιακά δομημένα δεδομένα (π.χ. χρονοσειρές φορτίων), ημιδομημένα δεδομένα (π.χ. καιρικά δεδομένα), αλλά και πλήρως αδόμητα δεδομένα (δεδομένα σε μορφή ήχου, κειμένου ή εικόνας), που συνθέτουν το συνολικό μείγμα των διαθέσιμων πληροφοριών (Wilcox et al., 2019).

- **Veracity:** Η αξιοπιστία ή ειλικρίνεια των δεδομένων προσδιορίζει έννοιες όπως η προστασία των δεδομένων, οι περιορισμοί καθαρισμού και η ανάγκη δημιουργίας αντιγράφων ασφαλείας. Η αξιοπιστία των μεγάλων δεδομένων είναι μια πολύ σοβαρή πρόκληση για στον τομέα της έρευνας αλλά και πρακτικά, αφού η διάκριση μεταξύ των χρήσιμων και των 'βρώμικων' δεδομένων επηρεάζει άμεσα την εγκυρότητα των μοντέλων TN (Normandeau, 2013).
- **Value:** Όπως αναφέρθηκε και στην εισαγωγή του κεφαλαίου, τα μεγάλα ενεργειακά δεδομένα από μόνα τους δεν έχουν ιδιαίτερο νόημα, αν δεν 'ξεκλειδωθεί' η πραγματική τους αξία μέσα από μοντέλα και τεχνικές ανάλυσης δεδομένων με στόχο την υποστήριξη αποφάσεων σε όλη τη διαδικασία διαχείρισης ενέργειας. Επίσης, σύμφωνα με τους Mayer-Schönberger and Cukier (2013) η αξία των μεγάλων ενεργειακών δεδομένων χαρακτηρίζεται ως αραιή, γεγονός που σημαίνει ότι η αξία που προκύπτει από τα μεγάλα δεδομένα ενδέχεται να είναι περιορισμένη. Επομένως, είναι αδιαμφισβήτητη η ανάγκη για ανάπτυξη ευφυών συστημάτων που εκμεταλλεύονται τα διαθέσιμα δεδομένα με τον καλύτερο δυνατό τρόπο, και τα μετατρέπουν σε χρήσιμη γνώση για το αντίστοιχο πρόβλημα.

Από τα παραπάνω γίνεται σαφές πως τα μεγάλα δεδομένα από μόνα τους δεν μπορούν να παρέχουν λύσεις στα περίπλοκα σύγχρονα ενεργειακά προβλήματα. Αποτελούν ένα απαραίτητο εργαλείο που αν συνδυαστεί σωστά με μεθόδους ανάλυσης δεδομένων μπορούν να προσφέρουν αξιόπιστες εφαρμογές και συστήματα υποστήριξης αποφάσεων. Μια από τις πλέον σύγχρονες κατηγορίες μεθόδων ανάλυσης δεδομένων είναι η TN και οι επιμέρους κλάδοι της που θα αναλυθούν λεπτομερώς στο επόμενο κεφάλαιο. Ο συνδυασμός των μεγάλων δεδομένων και των μεθόδων TN έχει ως αποτέλεσμα τη δημιουργία ευφυών μοντέλων και εφαρμογών ενεργειακής διαχείρισης. Ο ρόλος των δύο πεδίων είναι άρρηκτα συνδεδεμένος, αφού η TN απαιτεί την ύπαρξη μεγάλων δεδομένων ώστε τα μοντέλα να μαθαίνουν από τις ιστορικές παρατηρήσεις και να βελτιώνουν την επίδοσή τους. Στις παρακάτω ενότητες παρουσιάζεται ένα μεγάλο πλήθος παραδειγμάτων, στα οποία τα μεγάλα δεδομένα και η TN συνδυάζονται επιτυχώς για την ανάπτυξη ευφυών συστημάτων υποστήριξης αποφάσεων.

3.3 Τεχνητή Νοημοσύνη και Κατανεμημένη Παραγωγή

Η διείσδυση των ΑΠΕ, ιδίως της αιολικής και της ηλιακής ενέργειας, αυξάνονται σταθερά. Μάλιστα, η ανάπτυξη της παγκόσμιας ικανότητας παραγωγής ηλεκτρικής ενέργειας από Φ/Β, ανεμογεννήτριες και άλλες τεχνολογίες ανανεώσιμων πηγών ενέργειας πρόκειται να επιταχυνθεί τα επόμενα χρόνια, αντιπροσωπεύοντας σχεδόν το 95% της αύξησης της παγκόσμιας ισχύος έως το 2026 (IEA, 2021). Όπως φαίνεται στο Σχήμα ??, ο (IEA) προβλέπει ότι η δυναμικότητα ηλεκτρικής ενέργειας από ΑΠΕ προβλέπεται να αυξηθεί κατά πάνω από 60% σε παγκόσμιο επίπεδο μεταξύ 2021 και 2026, φτάνοντας τα 4.800 GW, το οποίο ισοδυναμεί με την τρέχουσα παγκόσμια ικανότητα ισχύος των ορυκτών καυσίμων και των πυρηνικών. Την ίδια στιγμή, οι προσθήκες αιολικών πάρκων (*onshore*) έως το 2026 αναμένεται να είναι σχεδόν 25% υψηλότερες κατά μέσο όρο σε σχέση με την περίοδο 2015-2020. Μόνο το 2020, οι εγκαταστάσεις αιολικών πάρκων σε παγκόσμιο επίπεδο διπλασιάστηκαν, φτάνοντας στο δυσθεώρητο επίπεδο των σχεδόν 110 GW (IEA, 2021).

Επιπλέον, η τάση που παρατηρείται ως προς την αύξηση της δυναμικότητας ΑΠΕ κατά την περίοδο 2021-2026 δείχνει ότι η ανάπτυξη των ΑΠΕ στην Ευρωπαϊκή Ένωση στο σύνολό της πρόκειται να υπερβεί ό,τι προβλέπουν τα τρέχοντα Εθνικά Σχέδια για την Ενέργεια και το Κλίμα (*National Energy and climate Plans, NECPs*) για το 2030 (Williges et al., 2022). Αυτή η συνεχώς αυξανόμενη δυναμική των ΑΠΕ πηγάζει από την έμφαση που δίνεται τόσο από την Ευρωπαϊκή Ένωση, όσο και σε παγκόσμιο επίπεδο στην ενέργεια και στο κλίμα. Στο πλαίσιο αυτό, η Ευρωπαϊκή Ένωση σχεδίασε και πρότεινε το πακέτο *Fit for 55* για τη μείωση των εκπομπών αερίων θερμοκηπίου της Ευρωπαϊκής Ένωσης κατά 55% έως το 2030 (Council, 2020).

Συνεπώς, τα επόμενα χρόνια είναι πολύ κρίσιμα για την επιτυχή μετάβαση στις ΑΠΕ τόσο στο πλαίσιο της ανάπτυξη νέων τεχνολογιών για τη βέλτιστη παραγωγή από τους διαθέσιμους φυσικούς πόρους, όσο και για την καλύτερη διαχείριση και διανομή της ενέργειας που παράγεται. Οι στόχοι αυτοί μπορούν να επιτευχθούν με τη βοήθεια της ΤΝ, η οποία ήδη χρησιμοποιείται ευρέως σε αρκετές μελέτες για την επίτευξη μελλοντικών στόχων των ΑΠΕ (Jha et al., 2017).

3.3.1 Προβλεπτικά Μοντέλα ΑΠΕ

Η διείσδυση των ΑΠΕ - και κυρίως της ηλιακής και της αιολικής ενέργειας - αυξάνεται και οι ακριβείς προβλέψεις ως προς την παραγωγή τους συμβάλλουν στην ομαλή ενσωμάτωση τους στα υπάρχοντα δίκτυα ηλεκτρικής ενέργειας (Sweeney et al., 2020). Ως συνέπεια, η πρόβλεψη της παραγωγής από συστήματα ΑΠΕ είναι από τα πιο φλέγοντα ερευνητικά ζητήματα στον ενεργειακό τομέα. Τα κυριότερα συστήματα ΑΠΕ που επικεντρώνεται το ερευνητικό ενδιαφέρον είναι η πρόβλεψη ενέργειας από Φ/Β συστήματα και από αιολικά συστήματα. Στις παρακάτω παραγράφους θα δοθεί μια εκτενής περιγραφή των δύο προβλημάτων και θα πραγματοποιηθεί εκτεταμένη αναφορά στην κυριότερη και πιο πρόσφατη βιβλιογραφία.

Πρόβλεψη Παραγωγής σε Φ/Β Συστήματα

Η ακριβής πρόβλεψη της παραγόμενης ενέργειας από Φ/Β συστήματα αποτελεί ένα περίπλοκο υπολογιστικό πρόβλημα. Τα ζητήματα που προκύπτουν στο πρόβλημα αυτό πηγάζουν από την εγγενή μεταβλητότητα των καιρικών συνθηκών, και πιο συγκεκριμένα της ηλιακής ακτινοβολίας, της θερμοκρασίας και του επιπέδου νέφωσης. Οι διακυμάνσεις που παρατηρούνται στα μετεωρολογικά φαινόμενα οδηγούν σε αβεβαιότητα στην έξοδο του Φ/Β, επικίνδυνες διακοπόμενες διεισδύσεις, υπερτάσεις, αντίστροφες ροές ισχύος, διακυμάνσεις στην αρμονική παραμόρφωση συχνότητας στις κυματομορφές ρεύματος και τάσης και διάφορες άλλες συνέπειες που εντείνουν την ανάγκη για ανάπτυξη ισχυρών προβλεπτικών μοντέλων (Raza et al., 2016). Η απρόβλεπτη φύση της παραγωγής επηρεάζει σημαντικά την αξιοπιστία, τη

Μελέτη	Έτος	Κατηγορία	Υποκατηγορία
Luo et al. (2021)	2021	Πρόβλεψη Παραγωγής	Φ/B Συστήματα
Wang et al. (2019)	2019	Πρόβλεψη Παραγωγής	Φ/B Συστήματα
Dairi et al. (2020)	2020	Πρόβλεψη Παραγωγής	Φ/B Συστήματα
Li et al. (2020)	2020	Πρόβλεψη Παραγωγής	Φ/B Συστήματα
Mishra et al. (2020)	2020	Πρόβλεψη Παραγωγής	Φ/B Συστήματα
Cordeiro-Costas et al. (2022)	2022	Πρόβλεψη Παραγωγής	Φ/B Συστήματα
Abdel-Basset et al. (2021)	2021	Πρόβλεψη Παραγωγής	Φ/B Συστήματα
AlKandari and Ahmad (2020)	2020	Πρόβλεψη Παραγωγής	Φ/B Συστήματα
Mellit et al. (2021)	2021	Πρόβλεψη Παραγωγής	Φ/B Συστήματα
Agga et al. (2022)	2022	Πρόβλεψη Παραγωγής	Φ/B Συστήματα
Damousis and Dokopoulos (2001)	2001	Πρόβλεψη Παραγωγής	Αιολικά Συστήματα
Hong and Rioflorido (2019)	2019	Πρόβλεψη Παραγωγής	Αιολικά Συστήματα
Demolli et al. (2019)	2019	Πρόβλεψη Παραγωγής	Αιολικά Συστήματα
Wang et al. (2017b)	2017	Πρόβλεψη Παραγωγής	Αιολικά Συστήματα
Liu et al. (2020)	2020	Πρόβλεψη Παραγωγής	Αιολικά Συστήματα
Lin et al. (2021)	2021	Πρόβλεψη Παραγωγής	Αιολικά Συστήματα
Hong and Rioflorido (2019)	2019	Πρόβλεψη Παραγωγής	Αιολικά Συστήματα
Baruque et al. (2019)	2019	Πρόβλεψη Παραγωγής	Γεωθερμικές Εγκαταστάσεις
Gangwani et al. (2020)	2020	Πρόβλεψη Παραγωγής	Γεωθερμικές Εγκαταστάσεις
Sapitang et al. (2020)	2020	Πρόβλεψη Παραγωγής	Υδροηλεκτρικά Συστήματα
Ali et al. (2020)	2020	Ανίχνευση Σφαλμάτων	Φ/B Συστήματα
Veerasingam et al. (2021)	2021	Ανίχνευση Σφαλμάτων	Φ/B Συστήματα
Eskandari et al. (2020)	2020	Ανίχνευση Σφαλμάτων	Φ/B Συστήματα
Omran et al. (2020)	2020	Ανίχνευση Σφαλμάτων	Φ/B Συστήματα
Fazai et al. (2019)	2019	Ανίχνευση Σφαλμάτων	Φ/B Συστήματα
Mustafa et al. (2023)	2023	Ανίχνευση Σφαλμάτων	Φ/B Συστήματα
Hussain et al. (2022)	2022	Ανίχνευση Σφαλμάτων	Φ/B Συστήματα
Van Gompel et al. (2022)	2022	Ανίχνευση Σφαλμάτων	Φ/B Συστήματα
Helbing and Ritter (2018)	2018	Ανίχνευση Σφαλμάτων	Αιολικά Συστήματα
Zhao et al. (2018)	2018	Ανίχνευση Σφαλμάτων	Αιολικά Συστήματα
Hsu et al. (2020)	2020	Ανίχνευση Σφαλμάτων	Αιολικά Συστήματα
Chen et al. (2019)	2019	Ανίχνευση Σφαλμάτων	Αιολικά Συστήματα
Zhong et al. (2021)	2021	Βέλτιστη Τοποθέτηση	Φ/B Συστήματα
Kalyan and Sun (2022)	2022	Βέλτιστη Τοποθέτηση	Φ/B Συστήματα
Ren et al. (2022)	2022	Βέλτιστη Τοποθέτηση	Φ/B Συστήματα
Shahzad (2021)	2021	Βέλτιστη Τοποθέτηση	Χερσαία Αιολικά Συστήματα
Petrov and Wessling (2015)	2015	Βέλτιστη Τοποθέτηση	Χερσαία Αιολικά Συστήματα
Lee et al. (2010)	2010	Βέλτιστη Τοποθέτηση	Υπεράκτια Αιολικά Συστήματα
Wu et al. (2013)	2013	Βέλτιστη Τοποθέτηση	Υπεράκτια Αιολικά Συστήματα

Πίνακας 3.1: Ενδεικτικές μελέτες εφαρμογών TN σε προβλήματα ΑΠΕ.

σταθερότητα και τον προγραμματισμό της λειτουργίας του συστήματος, επιφέροντας επίσης οικονομικές συνέπειες (Shivashankar et al., 2016). Σε αυτό το πλαίσιο, η αξιόπιστη πρόβλεψη παραγωγής Φ/B μπορεί να μειώσει σημαντικά αυτήν την αβεβαιότητα, να ενισχύσει τη σταθερότητα και να βελτιώσει την οικονομική βιωσιμότητα αποτελώντας ένα κρίσιμο ερευνητικό πεδίο (Diagne et al., 2013; Voyant et al., 2017).

Υπάρχει μια σειρά από διαφορετικούς παράγοντες που επηρεάζουν την ακρίβεια της πρόβλεψης σε Φ/B, καθιστώντας την ανάπτυξη προβλεπτικών μοντέλων μια περίπλοκη διαδικασία. Η ανάπτυξη του κατάλληλου μοντέλου πρόβλεψης επηρεάζεται από παράγοντες όπως ο ορίζοντας πρόβλεψης, οι είσοδοι του μοντέλου πρόβλεψης και οι μετρικές εκτίμησης της απόδοσης. Ακόμη, για να επιτευχθεί καλύτερη ακρίβεια, σημαντικό είναι να πραγματοποιείται βελτιστοποίηση της ανάλυσης συσχέτισης και εκτίμηση αβεβαιότητας των μοντέλων πρόβλεψης μέσω πιθανοτικών μοντέλων πρόβλεψης.

Ίσως το σημαντικότερο στοιχείο που πρέπει να συνυπολογιστεί για την ανάπτυξη ενός μοντέλου πρόβλεψης παραγωγής ενέργειας είναι ο **ορίζοντας της πρόβλεψης**. Ως ορίζοντας της πρόβλεψης ορίζεται η μελλοντική χρονική περίοδος για την οποία πραγματοποιείται

η πρόβλεψη παραγωγής ή η χρονική διάρκεια μεταξύ του πραγματικού χρόνου και του χρόνου πρόβλεψης (Das et al., 2018). Όσον αφορά στην κατηγοριοποίηση των μοντέλων με βάση τον ορίζοντα πρόβλεψης, ορισμένοι ερευνητές (Raza and Khosravi, 2015; de Marcos et al., 2019) έχουν καθορίσει τρεις κατηγορίες ορίζοντα πρόβλεψης: βραχυπρόθεσμες, μεσοπρόθεσμες και μακροπρόθεσμες προβλέψεις. Ωστόσο, μέχρι στιγμής δεν υπάρχει καθολικά συμφωνημένο κριτήριο για τη διαφοροποίηση των μοντέλων μεταξύ των οριζόντων (Nespoli et al., 2019; Sobri et al., 2018). Για παράδειγμα οι Amral et al. (2007) θεωρούν μια ακόμη κατηγορία, τις πολύ βραχυπρόθεσμες ή εξαιρετικά βραχυπρόθεσμες προβλέψεις, οι οποίες χρησιμοποιούνται για τη διαχείριση ενέργειας σε μικροδίκτυα ή έξυπνα δίκτυα (Raza et al., 2016). Λαμβάνοντας υπόψιν τις παραπάνω μελέτες, μπορούμε να θεωρήσουμε τέσσερις κατηγορίες μοντέλων πρόβλεψης με κριτήριο τον ορίζοντα, οι οποίες αναλύονται παρακάτω:

- **Very short-term forecasting:** Η εξαιρετικά βραχυπρόθεσμη πρόβλεψη χρησιμοποιείται κυρίως στο σχεδιασμό συστημάτων ηλεκτρικής ενέργειας σε έξυπνα μικροδίκτυα, έχοντας ως ορίζοντα πρόβλεψης από λίγα δευτερόλεπτα έως λιγότερο από 30 λεπτά, σύμφωνα με τη μελέτη των Ren et al. (2015). Η χρησιμότητα αυτών των προβλέψεων επικεντρώνεται στην τιμολόγηση της ηλεκτρικής ενέργειας, στην παρακολούθηση της αποστολής ηλεκτρικής ενέργειας σε πραγματικό χρόνο, σε διαδικασίες εξομάλυνσης ισχύος σε μικροδίκτυα και στον έλεγχο αποθήκευσης ενέργειας από Φ/Β συστήματα (Das et al., 2018). Αξίζει να σημειωθεί πως διαφορετικοί ερευνητές εντάσσουν σε αυτή την κατηγορία και προβλέψεις για αρκετές ώρες μπροστά, όμως αυτό δεν είναι το σύνηθες.
- **Short-term forecasting:** Η βραχυπρόθεσμη πρόβλεψη έχει κυριότερη εφαρμογή αποφάσεις οικονομικής αποστολής φορτίου (economic load dispatch) και προγραμματισμό του συστήματος ηλεκτρικής ενέργειας. Ο ορίζοντας πρόβλεψης σε αυτή την κατηγορία είναι από 1 ώρα έως και έξι ώρες μπροστά, σύμφωνα με τη μελέτη των Ren et al. (2015).
- **Medium-term forecasting:** Η μεσοπρόθεσμη πρόβλεψη εκτείνεται από 6 ώρες έως και μια μέρα μπροστά. Η κυριότερη εφαρμογή αυτής της κατηγορίας είναι ο προγραμματισμός συντήρησης συμβατικών ή ολοκληρωμένων συστημάτων ηλιακής ενέργειας που αποτελούνται από μετασχηματιστές υψηλής τεχνολογίας αλλά και από διαφορετικούς τύπους ηλεκτρικών μηχανημάτων (Das et al., 2018).
- **Long-term forecasting:** Η μακροπρόθεσμη πρόβλεψη εκτείνεται σε περιπτώσεις προβλέψεων για περισσότερο από 24 ώρες μπροστά. Σε αυτή την κατηγορία προβλέψεων εντάσσονται περιπτώσεις όπου πρέπει να εκτιμηθεί η μακροχρόνια παραγωγή, μεταφορά και διανομή της παραγόμενης ενέργειας από Φ/Β (Behera et al., 2018). Όπως είναι φυσικό όμως, τα μακροπρόθεσμα μοντέλα έχουν μειωμένη ακρίβεια επειδή οι καιρικές διακυμάνσεις που εκτείνονται σε μία ή λίγες ημέρες δεν μπορούν να προβλεφθούν χρησιμοποιώντας τόσο μεγάλους ορίζοντες. Επομένως, με τη χρήση τέτοιων μοντέλων μπορεί να εκτιμηθεί η τάση της παραγωγής ενέργειας με κριτήριο την εποχικότητα. Χαρακτηριστικά παραδείγματα για τέτοιες περιπτώσεις αποτελούν οι μελέτες των Vehviläinen and Pyykkönen (2005); Hong et al. (2013), οι οποίοι έχουν αναπτύξει μεσοπρόθεσμα μοντέλα και μοντέλα για το επόμενο έτος για τον μηνιαίο προγραμματισμό συστημάτων ηλεκτρικής ενέργειας, την τιμολόγηση της ηλεκτρικής ενέργειας και την πρόβλεψη φορτίου.

Ένα ακόμη στοιχείο που διαφοροποιείται από έρευνα σε έρευνα είναι η **επιλογή χαρακτηριστικών εισόδου** των μοντέλων (Wang et al., 2017a). Η επιλογή κατάλληλων εισόδων για τα μοντέλα πρόβλεψης έχει άμεση επίδραση στην ακρίβεια της πρόβλεψης, αποτελώντας βασικό παράγοντα για τον καθορισμό της επιτυχίας ενός μοντέλου. Απαιτείται ορθή κρίση και λεπτομερές φιλτράρισμα κατά την επιλογή χαρακτηριστικών εισόδου, καθώς η αλόγιστη χρήση χαρακτηριστικών μπορεί να μειώσει την απόδοση του μοντέλου και παράλληλα να αυξήσει τη

χρονική καθυστέρηση, το κόστος και την υπολογιστική πολυπλοκότητα. Οι εισόδοι των μοντέλων πρόβλεψης σε Φ/Β συστήματα είναι ως επί το πλείστον μετεωρολογικές παράμετροι όπως η ηλιακή ακτινοβολία, η ατμοσφαιρική θερμοκρασία, η θερμοκρασία του Φ/Β, η ταχύτητα ανέμου και η υγρασία (Das et al., 2017; Wang et al., 2015). Ως εκ τούτου, η συσχέτιση μεταξύ της εξόδου Φ/Β και των μετεωρολογικών εισόδων ποικίλλει και μπορεί να είναι θετική ή αρνητική, με ισχυρότερη ή ασθενέστερη συσχέτιση. Όπως είναι φυσικό, η ηλιακή ακτινοβολία έχει τη μεγαλύτερη συσχέτιση με την έξοδο σε σύγκριση με τις υπόλοιπες μεταβλητές (Kasten and Czeplak, 1980). Στις επόμενες παραγράφους παρουσιάζονται εκτενέστερα τα βασικότερα χαρακτηριστικά εισόδου που χρησιμοποιούνται στη βιβλιογραφία.

- **Ηλιακή Ακτινοβολία:** Πρόκειται για τη βασικότερη μεταβλητή εισόδου στο πρόβλημα της πρόβλεψης της ηλιακής ενέργειας. Εκφράζει την ακτινοβολούμενη ενέργεια από τον ήλιο που εκπέμπεται με τη μορφή ηλεκτρομαγνητικής ακτινοβολίας. Η ηλιακή ακτινοβολία έχει το μεγαλύτερο βαθμό συσχέτισης με την παραγωγή ισχύος εξόδου από το Φ/Β και είναι ευθέως ανάλογη με την ποσότητα της ηλιακής ενέργειας που μπορεί να συλλεχθεί από αυτό. Στην έρευνα των (De Giorgi et al., 2014) χαρακτηριστικά χρησιμοποιήθηκε ένα νευρωνικό δίκτυο με είσοδο την ηλιακή ακτινοβολία και είχε ως αποτέλεσμα την επίτευξη πολύ ακριβώς προβλέψεων.
- **Θερμοκρασία:** Εκφράζει το μέτρο της μέσης θερμότητας ή θερμικής ενέργειας σε μια ουσία και καθορίζεται κυρίως από την ποσότητα του ηλιακού φωτός που απορροφάται από την επιφάνεια της γης και από την ποσότητα της θερμότητας που εκπέμπεται στην ατμόσφαιρα από τα αέρια του θερμοκηπίου. Η θερμοκρασία του περιβάλλοντος είναι μια ακόμη παράμετρος που επηρεάζει σημαντικά την παραγωγή του Φ/Β συστήματος, αφού έχει αποδειχθεί πως η συσχέτιση μεταξύ της θερμοκρασίας περιβάλλοντος και της ισχύος εξόδου των Φ/Β είναι ικανή ώστε να χρησιμοποιείται ως μεταβλητή εισόδου.
- **Κάλυψη Νεφών:** Η κάλυψη νεφών (ή νεφελότητα) αποτελεί έναν από τους πιο σημαντικούς παράγοντες που καθορίζει την ένταση της ηλιακής ακτινοβολίας που προσπίπτει στην επιφάνεια της γης, αφού το μέρος της ηλιακής ενέργειας που διέρχεται από τα σύννεφα δεν είναι σταθερό και εξαρτάται από τον τύπο και την ποσότητα των σχηματισμών νεφών (Mohammadi and Goudarzi, 2018). Σύμφωνα με τους Wang et al. (2011); Sun et al. (2015) η κίνηση, η διάχυση και η παραμόρφωση των νεφών προκαλούν διακυμάνσεις στην ένταση του ηλιακού φωτός επηρεάζοντας έτσι την έξοδο του Φ/Β συστήματος. Συνήθως, πληροφορίες για τη νεφελότητα συλλέγονται από εικόνες δορυφόρων (Martínez-Chico et al., 2011), χάνοντας όμως σε ακρίβεια όταν πρόκειται για συγκεκριμένες συντεταγμένες. Για το λόγο αυτό πλέον χρησιμοποιούνται εκτενώς επίγειες τεχνικές απεικόνισης.
- **Ταχύτητα Ανέμου:** Η ταχύτητα του ανέμου είναι μια από τις κρίσιμότερες μεταβλητές εισόδου στα προβλεπτικά μοντέλα Φ/Β συστημάτων, όντας μια επιπλέον πηγή αβεβαιότητας (Reddy, 2017). Ο κύριος ρόλος της ταχύτητας του ανέμου είναι στον τρόπο που διαχέεται η θερμότητα στο Φ/Β αλλά και στη μείωση της θερμοκρασίας των Φ/Β κυψελών (Reddy and Bijwe, 2015).
- **Χρονικές Μεταβλητές:** Οι μεταβλητές περιοδικότητας (ή χρονικές μεταβλητές) είναι η ώρα της μέρας, ο μήνας του έτους και η εποχή. Αυτές οι μεταβλητές είναι πολύ σημαντικές για την ακρίβεια του μοντέλου, καθώς η παραγωγή ενέργειας είναι άμεση συνάρτηση της θέσης του ηλίου, η οποία μεταβάλλεται περιοδικά στη διάρκεια της ημέρας και του χρόνου. Χαρακτηριστικό παράδειγμα αποτελεί η μελέτη των Al-Dahidi et al. (2019) όπου χρησιμοποιήθηκε η τρέχουσα χρονική σήμανση στη μορφή ωρών που ξεκινούν από την αρχή κάθε έτους.

Όπως μπορεί να γίνει εμφανές από τις προηγούμενες παραγράφους, η πρόβλεψη της ενέργειας ενός Φ/Β συστήματος είναι ένα πολύ περίπλοκο πρόβλημα στο οποίο πραγματοποιείται συνεχής και εκτενής προσπάθεια από την ερευνητική κοινότητα. Σύμφωνα με την

ανασκόπηση των [Ahmed et al. \(2020\)](#) διάφορες προσεγγίσεις μοντελοποίησης έχουν χρησιμοποιηθεί για προβλέψεις εξόδου σε Φ/Β, με κυριότερες κατηγορίες τα φυσικά μοντέλα, τα αμιγώς στατιστικά μοντέλα, και τα μοντέλα TN (μηχανικής μάθησης, βαθιάς μάθησης, νευρωνικά δίκτυα). Επιπλέον, συνδυασμοί των παραπάνω έχουν προταθεί επίσης, τα οποία είναι γνωστά ως υβριδικά μοντέλα. Συχνά, οι μελέτες συγκρίνουν την επίδοση των διαφορετικών μοντέλων με σκοπό να καταλήξουν στο βέλτιστο μοντέλο, όμως προς το παρόν δεν υπάρχει η ένδειξη πως κάποιο συγκεκριμένο μοντέλο υπερνικά όλα τα άλλα σε επαρκές πλήθος πειραμάτων. Για παράδειγμα, οι [Almonacid et al. \(2010\)](#) συνέκριναν ένα μοντέλο βασισμένο σε νευρωνικά δίκτυα με τρία συμβατικά στατιστικά μοντέλα, καταλήγοντας πως η προβλεπτική ικανότητα του νευρωνικού δικτύου είναι ανώτερη των συμβατικών. Αντίστοιχα, στη μελέτη των [Oudjana et al. \(2013\)](#) συγκρίθηκε ένα νευρωνικό δίκτυο με ένα απλό μοντέλο παλινδρόμησης με παρόμοια αποτελέσματα. Είναι ξεκάθαρο πως είναι πολλοί οι παράγοντες που επηρεάζουν την ακρίβεια ενός μοντέλου και συνεπώς οι άμεσες συγκρίσεις είναι πολύ δύσκολες. Οι τρεις βασικές κατηγορίες προβλεπτικών τεχνικών (φυσικά, στατιστικά, TN) παρουσιάζονται στις επόμενες παραγράφους.

Οι **φυσικές μέθοδοι** πρόβλεψης χρησιμοποιούν ένα θεωρητικό μοντέλο προσομοίωσης για τον υπολογισμό της ισχύος εξόδου ενός Φ/Β συστήματος με βάση τις κύριες παραμέτρους σχεδιασμού του ([Zhao et al., 2016](#)). Αυτές οι παράμετροι περιλαμβάνουν την πίεση αέρα, την τραχύτητα επιφάνειας, τη θερμοκρασία, διαταραχές και άλλα εμπόδια ([Zameer et al., 2017](#); [Lei et al., 2009](#)). Γενικότερα, έχει αποδειχθεί πως οι φυσικές μέθοδοι είναι καταλληλότερες για μακροπρόθεσμους ορίζοντες πρόβλεψης. Περισσότερες λεπτομέρειες για τις φυσικές μεθόδους δίδονται στις έρευνες των [Yang et al. \(2019\)](#) και [Mayer and Gróf \(2021\)](#).

Οι **στατιστικές μέθοδοι** στηρίζονται σε ιστορικά δεδομένα παραγωγής, χρησιμοποιώντας χρονοσειρές ιστορικών δεδομένων και δεδομένα που παράγονται σε πραγματικό χρόνο. Τα στατιστικά μοντέλα χρησιμοποιούν μαθηματικές εξισώσεις για να εξαγάγουν το μοτίβο των δεδομένων και τη συσχέτιση με ιστορικά δεδομένα εισόδου. Οι γνωστότεροι αλγόριθμοι που χρησιμοποιούνται είναι τα μοντέλα κινούμενου μέσου όρου και τα μοντέλα αυτόματης παλινδρόμησης, καθώς και συνδυασμοί τους (μοντέλα ARIMA). Το πλεονέκτημα τους σε σχέση με τα μοντέλα μάθησης είναι πως χρειάζονται λιγότερα δεδομένα εισόδου, παρουσιάζοντας όμως μικρότερη ακρίβεια πρόβλεψης σε σύγκριση με σύγχρονες αρχιτεκτονικές νευρωνικών δικτύων.

Τέλος οι μέθοδοι που βασίζονται σε **μοντέλα TN** αποτελεί μια κατηγορία μεθόδων που κερδίζει έδαφος συνεχώς τα τελευταία χρόνια λόγω της καλύτερης προβλεπτικής ικανότητας που προσφέρει. Αυτές οι μέθοδοι βασίζονται στην ικανότητα της TN να μαθαίνει από ιστορικά δεδομένα και να βελτιώνει περαιτέρω τις προγνωστική ικανότητα των μοντέλων μέσω περίπλοκων διαδικασιών εκπαίδευσης. Ως μειονέκτημα μπορεί να σημειωθεί πως πολλές φορές μπορεί να απαιτούνται ισχυροί υπολογιστές για την εκτέλεση πολλών επαναλήψεων προτού επιτευχθεί μια τελική πρόβλεψη, λόγω της αυξημένης υπολογιστικής πολυπλοκότητας. Τα κυριότερα μοντέλα TN θα παρουσιαστούν αναλυτικότερα στο επόμενο κεφάλαιο.

Πρόβλεψη Παραγωγής σε Αιολικά Συστήματα

Η πρόβλεψη παραγωγής ενέργειας από αιολικά συστήματα αποτελεί ένα ακόμη κρίσιμο πρόβλημα της επιστημονικής κοινότητας, καθώς είναι μια αρκετά απαιτητική κατηγορία προβλήματος πρόβλεψης. Καθώς ο άνεμος είναι εγγενώς μεταβλητός, η αιολική ενέργεια είναι μια πηγή ηλεκτρικής ενέργειας με πολλές διακυμάνσεις. Οι προβλέψεις σε αιολικά πάρκα έχουν πολλά κοινά με τις αντίστοιχες σε Φ/Β συστήματα, καθώς οι μέθοδοι που χρησιμοποιούνται έχουν αναλογίες μεταξύ των δύο συστημάτων και ο ορίζοντας πρόβλεψης καθορίζεται παρόμοια και για τα δύο προβλήματα. Η κυριότερη διαφορά έγκειται στις μεταβλητές εισόδου, καθώς στην περίπτωση των αιολικών συστημάτων ο κυριότερος παράγοντας είναι η ταχύτητα και η κατεύθυνση του ανέμου.

Σύμφωνα με την ανασκόπηση των [Foley et al. \(2012\)](#), οι βραχυπρόθεσμες προβλέψεις (οι συγγραφείς τις ορίζουν με ορίζοντα από 1 ώρα έως 72 ώρες) είναι χρήσιμες στον σχεδιασμό

του συστήματος ηλεκτρικής ενέργειας για δέσμευση και αποδέσμευση μονάδων και για εμπορία ηλεκτρικής ενέργειας σε αγορές ηλεκτρικής ενέργειας στις οποίες η αιολική ενέργεια και η αποθήκευση μπορούν να ανταλλάσσονται (Moyano and Lopes, 2009). Οι μεσοπρόθεσμες προβλέψεις (οι συγγραφείς τις ορίζουν από 3 ημέρες έως και 1 εβδομάδα μπροστά) χρησιμοποιούνται για τον προγραμματισμό της συντήρησης των αιολικών πάρκων, για τη δέσμευση και αποδέσμευση της μονάδας και για τη διακοπή λειτουργίας των θερμικών γεννητριών για λόγους ελέγχου και συντήρησης στο δίκτυο. Τέλος, οι μακροπρόθεσμες προβλέψεις (εβδομάδες ή μήνες μπροστά) είναι ιδιαίτερα χρήσιμες για τη χάραξη στρατηγικών και το σχεδιασμό τοποθέτησης αιολικών πάρκων. Όπως είναι φυσικό, το σφάλμα πρόβλεψης συνήθως αυξάνεται όσο διευρύνεται ο χρονικός ορίζοντας της πρόβλεψης.

Η πρόβλεψη αιολικής ενέργειας μπορεί να οριστεί ως η εφαρμογή των θεωριών και πρακτικών των κλάδων της μετεωρολογίας και της κλιματολογίας (Petersen et al., 1997). Πιο συγκεκριμένα, η πρόβλεψη του ανέμου για την παραγωγή ενέργειας επικεντρώνεται κυρίως σε βραχυπρόθεσμες περιόδους (έως μερικές ώρες μπροστά) και στις μεσοπρόθεσμες περιόδους (έως εβδομάδα μπροστά). Μια πολύ αναλυτική επισκόπηση για τα βραχυπρόθεσμα χαρακτηριστικά του ανέμου έχει αναπτυχθεί από τους Landberg (1999). Ο λόγος που οι ερευνητικές προσπάθειες επικεντρώνονται σε αυτούς τους ορίζοντες πρόβλεψης είναι η προστιθέμενη αξία που έχουν αυτές οι προβλέψεις σε πλήθος εφαρμογών, με χαρακτηριστικότερες τη ρύθμιση και παρακολούθηση φορτίων, την εξισορρόπηση και τη δέσμευση μονάδων και τον προγραμματισμό σε επίπεδο μικροδικτύων.

Γενικότερα, όπως ισχύει και στην περίπτωση των Φ/Β συστημάτων, τα μοντέλα πρόβλεψης για την αιολική ενέργεια μπορούν να χωριστούν σε δύο κατηγορίες, ανάλογα με τη φιλοσοφία των χαρακτηριστικών εισόδου που χρησιμοποιούν. Η πρώτη κατηγορία βασίζεται αποκλειστικά στην ανάλυση ιστορικών χρονοσειρών ανέμου, ενώ η δεύτερη κατηγορία μεθόδων χρησιμοποιεί ως είσοδο προβλέψεις ταχύτητας του ανέμου από μοντέλα αριθμητικής πρόβλεψης καιρού (*Numerical Weather Prediction - NWP*). Στην πρώτη κατηγορία χρησιμοποιούνται μοντέλα στατιστικής προσέγγισης για την πρόβλεψη της μέσης ωριαίας ταχύτητας ανέμου ή για την άμεση πρόβλεψη της παραγωγής ηλεκτρικής ενέργειας (Taylor and Buizza, 2003). Αντίθετα, τα μοντέλα που ανήκουν στη δεύτερη κατηγορία χρησιμοποιούν προβλέψεις για την ωριαία μέση ταχύτητα και κατεύθυνση ανέμου που προέρχονται από μετεωρολογικά μοντέλα. Μάλιστα η μελέτη των Nielsen et al. (2007) απέδειξε πως εάν χρησιμοποιούνται πολλές μετεωρολογικές προβλέψεις, τότε το σφάλμα πρόβλεψης μειώνεται. Στη δεύτερη κατηγορία μοντέλων, μεγάλη σημασία έχει η επιλογή του μετεωρολογικού μοντέλου, συμπεριλαμβανομένων της γεωγραφικής περιοχής, της χωρικής και χρονικής ανάλυσης και του ορίζοντα πρόβλεψης, καθώς επηρεάζονται σημαντικά τόσο την ακρίβεια όσο και την υπολογιστική πολυπλοκότητα.

Τέλος, κατ' αναλογία με τα μοντέλα πρόβλεψης ηλιακής ενέργειας, η πρόβλεψη της αιολικής ενέργειας μπορεί να πραγματοποιηθεί γενικά με φυσικές μεθόδους, με παραδοσιακές στατιστικές μεθόδους ή με μεθόδους μάθησης που βασίζονται στην TN. Βέβαια, κατά καιρούς έχουν προταθεί και υβριδικές μέθοδοι οι οποίες συνδυάζουν δύο ή περισσότερες προβλέψεις από τις βασικές κατηγορίες. Ωστόσο, η επιλογή του καταλληλότερου μοντέλου ή κατηγορίας μεθόδων υπαγορεύεται από το χρονικό ορίζοντα πρόβλεψης. Μια ανασκόπηση των τριών βασικών κατηγοριών πραγματοποιείται στην επόμενη παράγραφο.

Τα **φυσικά μοντέλα** βασίζονται στη χρήση δεδομένων καιρού και χρησιμοποιούνται τόσο για την πρόβλεψη της ταχύτητας ανέμου όσο και για προβλέψεις αιολικής ενέργειας (Landberg, 1998). Σύμφωνα με τους Landberg et al. (2003) η φυσική μοντελοποίηση απαιτεί διασύνδεση με μετεωρολογικές προβλέψεις και βασίζεται σε μεγάλα υπολογιστικά συστήματα προκειμένου να επιτευχθούν ακριβή αποτελέσματα, αφού η εκτίμηση της αιολικής ισχύος πραγματοποιείται μέσω λεπτομερούς περιγραφής της χαμηλότερης ατμόσφαιρας. Από την άλλη πλευρά, οι **στατιστικές μέθοδοι** χρησιμοποιούν ιστορικά δεδομένα για να πραγματοποιήσουν τις προβλέψεις. Σε αντίθεση με τις φυσικές μεθόδους, οι στατιστικές μέθοδοι περιλαμβάνουν μόνο ένα βήμα για τη μετατροπή των μεταβλητών εισόδου σε πρόβλεψη της ισχύος εξόδου λειτουργώντας σαν 'μαύρο κουτί'. Χαρακτηριστικό παράδειγμα στατιστικής

μεθόδου αποτελεί η έρευνα των [Torres et al. \(2005\)](#), που πρότειναν ένα μοντέλο ARMA το οποίο εκπαιδεύτηκε με εννέα έτη ιστορικών δεδομένων από αιολικά πάρκα και χρησιμοποιήθηκε για την πρόβλεψη της αιολικής ενέργειας έως και μερικές ώρες μπροστά. Βέβαια, τα τελευταία χρόνια οι κλασικές στατιστικές μέθοδοι έχουν δώσει τη θέση τους στις **μεθόδους TN**, με κυριότερα χρησιμοποιούμενα μοντέλα τα νευρωνικά συστήματα, τα δίκτυα βαθιάς μάθησης και τα ασαφή μοντέλα. Τα μοντέλα αυτά μαθαίνουν τη σχέση μεταξύ του προβλεπόμενου ανέμου και της προβλεπόμενης ισχύος εξόδου χρησιμοποιώντας ιστορικά δεδομένα στη μορφή χρονοσειρών. Για παράδειγμα, στη μελέτη των [Damousis and Dokopoulos \(2001\)](#) προτάθηκε ένα ασαφές σύστημα που προβλέπει την ταχύτητα του ανέμου, ενώ οι [Hong and Rioflorido \(2019\)](#) πρότειναν ένα υβριδικό μοντέλο βαθιάς μάθησης για προβλέψεις με ορίζοντα μιας μέρας, το οποίο παρουσίασε πολύ καλή προβλεπτική ικανότητα.

3.3.2 Ανίχνευση Σφαλμάτων και Προγνωστική Συντήρηση

Η δεύτερη σημαντικότερη κατηγορία προβλημάτων ΑΠΕ που έχει συμβάλει η TN είναι η ανίχνευση ανωμαλιών και η προγνωστική συντήρηση. Ειδικότερα όσον αφορά Φ/B συστήματα, η TN έχει διευρύνει τις δυνατότητες ανίχνευσης πολλών από τα βασικά σφάλματα που παρατηρούνται είτε στη DC είτε στην AC πλευρά τους. Στην ενότητα αυτή παρουσιάζεται ένα σύντομα η παρούσα κατάσταση όσον αφορά τις μεθόδους ανίχνευσης σφαλμάτων σε Φ/B συστήματα αλλά και η συμβολή της TN.

Η μείωση του κόστους των Φ/B συστημάτων καθώς και η αύξηση της επίδοσης τους, που προκύπτει από τη βελτιωμένη απόδοση των κυψελών και τις χαμηλότερες απώλειες μετατροπής της ενέργειας, οδήγησαν στην ανάπτυξη του ενδιαφέροντος για θέματα συντήρησης των Φ/B συστημάτων ([Bazilian et al., 2013](#); [Eftekharnjad et al., 2012](#)). Η συντήρηση τέτοιων συστημάτων περιλαμβάνει μια σειρά από δραστηριότητες που μπορεί να αποτελούνται από ελάχιστους ελέγχους έως και παρακολούθηση υψηλής ακρίβειας που επιτρέπει στον ιδιοκτήτη της μονάδας να εντοπίσει πιθανά προβλήματα ή να διαπιστώσει εγκαίρως την ανάγκη για εργασίες καθαρισμού ([Whaley, 2016](#)). Το ενδιαφέρον αυξάνεται ακόμη περισσότερο από τη στιγμή που η συντήρηση επηρεάζει άμεσα την απόδοση των Φ/B συστημάτων όσον αφορά την παραγόμενη ισχύ και, κατά συνέπεια, τα συνολικά έσοδα ([De Benedetti et al., 2018](#)).

Με τα χρόνια, έχουν προταθεί πολυάριθμες τεχνικές ανίχνευσης ανωμαλιών για την ανίχνευση και τη διάγνωση βλαβών σε Φ/B συστήματα. Μια σύντομη ανασκόπηση των διαφόρων συστημάτων παρακολούθησης που είναι διαθέσιμα για την παρακολούθηση της απόδοσης δίνεται από τις μελέτες των [Hare et al. \(2016\)](#) και [Triki-Lahiani et al. \(2018\)](#). Ωστόσο, την τελευταία δεκαετία έχουν εξελιχθεί πολυάριθμοι προηγμένοι αλγόριθμοι ανίχνευσης σφαλμάτων που είναι ικανοί να επιτύχουν ακριβή και ταχεία ανίχνευση σφαλμάτων ([Alam et al., 2015](#)). Σύμφωνα με τους [Pillai and Rajasekar \(2018\)](#), υπάρχουν τρία συμβατικά συστήματα για την προστασία ενός Φ/B συστήματος από βλάβες: (i) Χρήση τυπικών διατάξεων προστασίας, (ii) συνδυασμένη χρήση πολλαπλών συσκευών προστασίας σε μια ενιαία Φ/B συστοιχία και (iii) αλγόριθμοι ελέγχου σε πραγματικό χρόνο για την ανίχνευση της παρουσίας σφαλμάτων. Στην τελευταία κατηγορία εντάσσεται η συμβολή των μοντέλων μηχανικής μάθησης, οι οποίοι έχουν βοηθήσει σημαντικά στην ανίχνευση σφαλμάτων μέσω της ανάλυσης δεδομένων.

Οι τυπικότερες μέθοδοι ανάλυσης δεδομένων για την ανίχνευση ανωμαλιών είναι οι τεχνικές *Model-based Difference Measurement (MBDM)*, *Real-time Difference Measurement (RDM)* και *Output Signal Analysis (OSA)* ([Pillai and Rajasekar, 2018](#)). Οι τεχνικές MBDM βασίζονται στη σύγκριση των θεωρητικών παραμέτρων σε πραγματικό χρόνο με τα προβλεπόμενα από το μοντέλο δεδομένα για τον εντοπισμό σφαλμάτων στο σύστημα ([Alam et al., 2015](#)). Από την άλλη πλευρά, οι τεχνικές RDM συγκρίνουν τις παραμέτρους σε πραγματικό χρόνο με τα όρια κατωφλίου τους για τον εντοπισμό σφαλμάτων ([Shimakage et al., 2011](#)). Τα όρια κατωφλίου καθορίζονται από πειράματα σε συνθήκες πραγματικής λειτουργίας. Οι τεχνικές OSA συνήθως εφαρμόζουν κατάλληλη ανάλυση στο σήμα εξόδου

για να ανακαλύψουν τις παρούσες ανωμαλίες. Παράδειγμα αποτελεί ο εντοπισμός ανωμαλιών στην αφίδα του Φ/Β συστήματος, που μπορεί να εντοπιστεί μέσω ανάλυσης σημάτων χρησιμοποιώντας μετασχηματισμούς Fourier στην κυματομορφή του σήματος εξόδου (Zhao et al., 2013).

Ωστόσο, πρόσφατα έχουν αναπτυχθεί πολλές μέθοδοι μηχανικής μάθησης για την ανίχνευση σφαλμάτων σε Φ/Β συστήματα, που προσφέρουν καλύτερα αποτελέσματα από τις μεθόδους που παρουσιάστηκαν στην παραπάνω παράγραφο (Berghout et al., 2021). Οι αλγόριθμοι μηχανικής μάθησης εκπαιδεύονται για να μαθαίνουν τη σχέση μεταξύ των παραμέτρων εισόδου και της εξόδου του Φ/Β συστήματος, χρησιμοποιώντας δεδομένα από έξυπνους μετρητές. Ωστόσο, απαιτούνται ακόμη δεδομένα από περιπτώσεις σφάλματος προκειμένου τα μοντέλα να εκπαιδευτούν σε καταστάσεις μη ομαλής λειτουργίας. Ως συνέπεια, μόλις το μοντέλο εκπαιδευτεί, μπορεί εύκολα να εντοπίσει ελαττωματικές καταστάσεις αξιολογώντας τα σφάλματα. Επίσης, η ανίχνευση σφαλμάτων με αλγορίθμους μηχανικής μάθησης βοηθά στον ακριβή εντοπισμό και στην ταξινόμηση των σφαλμάτων. Όμως, όπως σε κάθε τεχνική που βασίζεται στα δεδομένα, έτσι και οι αλγόριθμοι μηχανικής μάθησης για ανίχνευση ανωμαλιών έχουν ορισμένους περιορισμούς, όπως η άμεση εξάρτηση της ακρίβειας της πρόβλεψης από την ποιότητα των δεδομένων, η δυσκολία απόκτησης δεδομένων σε περιπτώσεις μη ομαλής λειτουργίας και η δυσκολία χρήσης του ίδιου μοντέλου σε πολλά Φ/Β συστήματα, μη επιτρέποντας τη δημιουργία γενικευμένων λύσεων.

Συνεπώς, οι αλγόριθμοι ΤΝ χρησιμοποιούνται πλέον εντατικά για την ανίχνευση διαφορετικών τύπων σφαλμάτων. Αρχικά, στη μελέτη των Ali et al. (2020) προτείνεται ένα μοντέλο μηχανής διανυσμάτων υποστήριξης που βασίζεται σε υβριδικά χαρακτηριστικά του Φ/Β για την ανίχνευση και ταξινόμηση σφαλμάτων με τη χρήση τεχνικών υπέρυθρης θερμογραφίας (*infrared thermography*). Αντίστοιχα, οι Veerasamy et al. (2021) ανέπτυξαν ένα μοντέλο για την ανίχνευση σφαλμάτων υψηλής αντίστασης (*high impedance*) σε ολοκληρωμένα Φ/Β συστήματα ισχύος με χρήση αναδρομικών νευρωνικών δικτύων. Παρόμοιες έρευνες έχουν αναπτυχθεί για σφάλματα γραμμής (*line to line faults*). Χαρακτηριστικό παράδειγμα αποτελεί η έρευνα των Eskandari et al. (2020), οι οποίοι πρότειναν μια αυτόνομη μέθοδο για την ανίχνευση και ταξινόμηση σφαλμάτων γραμμής που βασίζεται στο συνδυασμό μεθόδων μηχανικής μάθησης και γενετικών αλγορίθμων εκμεταλλευόμενοι τις καμπύλες ρεύματος-τάσης του Φ/Β. Μια άλλη κατηγορία σφαλμάτων αφορά στα σφάλματα τόξου σειράς (*series arc fault*), τα οποία είναι από τα πιο συνήθη σφάλματα που εντοπίζονται σε Φ/Β συστήματα, με συνέπεια να έχουν πραγματοποιηθεί αρκετές ερευνητικές προσπάθειες για τον εντοπισμό τους. Ενδεικτικά, οι Omran et al. (2020) ανέπτυξαν ένα μοντέλο βασισμένο σε συνελκτικά νευρωνικά δίκτυα για τον εντοπισμό λανθασμένης λειτουργίας από τη DC πλευρά του Φ/Β.

3.3.3 Βέλτιστη Τοποθέτηση ΑΠΕ

Ένα από τα πιο κοινά ερευνητικά προβλήματα στο πεδίο των ΑΠΕ είναι η εύρεση της βέλτιστης τοποθεσίας για την εγκατάσταση ΑΠΕ, και κυρίως για την εγκατάσταση Φ/Β συστημάτων και αιολικών πάρκων. Το πρώτο βήμα για την εξασφάλιση μιας αποδοτικής τοποθεσίας όσον αφορά την παραγωγή ενέργειας, και κατά συνέπεια τα οικονομικά οφέλη, είναι η διεξαγωγή μιας ολοκληρωμένης ανάλυσης των παραγόντων που επηρεάζουν άμεσα το επίπεδο παραγωγής. Στην περίπτωση των Φ/Β συστημάτων ο κύριος παράγοντας είναι η ηλιακή ακτινοβολία, ενώ αντίστοιχα στην περίπτωση των αιολικών πάρκων βασικότερο κριτήριο είναι το αιολικό δυναμικό. Επιπλέον, η διαδικασία πρέπει να λαμβάνει υπόψιν και οποιαδήποτε άλλα υπάρχοντα κριτήρια απόφασης καθώς και όλους τους περιοριστικούς παράγοντες που πρέπει να αξιολογηθούν (Sengupta et al., 2021). Η ΤΝ σε συνδυασμό με άλλα πληροφοριακά συστήματα με υποστηρικτικό ρόλο προσφέρει τη δυνατότητα εύρεσης των βέλτιστων τοποθεσιών για την εγκατάσταση ΑΠΕ, κατέχοντας σημαντικό ρόλο στον επιτυχημένο σχεδιασμό σε εθνικό αλλά και παγκόσμιο επίπεδο. Στις επόμενες παραγράφους παρουσιάζεται η πρόοδος στον τομέα των Φ/Β συστημάτων και των αιολικών πάρκων.

Τοποθέτηση Φ/Β Συστημάτων

Ένα από τα βασικότερα υπολογιστικά συστήματα που χρησιμοποιείται για την εύρεση της καταλληλότερης τοποθεσίας για Φ/Β συστήματα είναι το σύστημα γεωγραφικών πληροφοριών (*Geographical Information System - GIS*). Αποτελεί ένα εργαλείο ανάλυσης και επεξεργασίας δεδομένων, χαρτών και χωρικών πληροφοριών, έχοντας γίνει πολύ δημοφιλές σε προβλήματα ενεργειακού σχεδιασμού. Μια πολύ συνήθης λύση είναι η ανάπτυξη μοντέλων υποστήριξης αποφάσεων που ενσωματώνουν το GIS με πολυκριτήρια προβλήματα για τον προσδιορισμό της ιδανικής τοποθεσίας όσον αφορά την ηλιακή ενέργεια που πρόκειται να παραχθεί. Για παράδειγμα, στην έρευνα των [Zambrano-Asanza et al. \(2021\)](#) συνδυάζεται το GIS με την πολυκριτήρια ανάλυση για τη βέλτιστη τοποθέτηση Φ/Β, χρησιμοποιώντας πληροφορίες υψηλής ανάλυσης για τον χωρικό χαρακτηρισμό της ζήτησης ενέργειας και την πραγματοποίηση ανάλυσης πυκνότητας.

Ωστόσο, εκτός από τις κλασσικές μεθόδους πολυκριτήριας ανάλυσης αποφάσεων, τα τελευταία χρόνια το GIS έχει συνδυαστεί επιτυχώς με μοντέλα TN, και ειδικότερα βαθιάς μάθησης, προσφέροντας αξιοσημείωτα αποτελέσματα. Στη μελέτη των ([Zhong et al., 2021](#)) προτείνεται ένα μεθοδολογικό πλαίσιο για την εκτίμηση του δυναμικού Φ/Β ταράτσας σε επίπεδο πόλης, με χρήση δορυφορικών εικόνων υψηλής ανάλυσης και ενός μοντέλου βαθιάς μάθησης που εξάγει αυτόματα την περιοχή της ταράτσας τμηματοποιώντας την εικόνα. Παρόμοια, ο πρωταρχικός στόχος στην έρευνα των [Kalyan and Sun \(2022\)](#) είναι να ανιχνεύσει ταράτσες που δεν διαθέτουν Φ/Β σύστημα αλλά δέχονται μέτρια έως υψηλή ηλιακή ακτινοβολία χρησιμοποιώντας το GIS και τεχνικές βαθιάς μάθησης. Τέλος, το πρόβλημα της δυσκολίας ανάλυσης της σκίασης και της διαθεσιμότητας των ταράτσων αποτέλεσε το αντικείμενο της μελέτης των [Ren et al. \(2022\)](#), που πρότειναν ένα νέο 3D-GIS σύστημα και μια προσέγγιση βαθιάς μάθησης, στην οποία αναλύεται η ηλιακή ακτινοβολία για την πρόβλεψη της παραγωγής από Φ/Β ταράτσας και παράλληλα λαμβάνονται υπόψη οι επιδράσεις της σκίασης των γύρω κτιρίων.

Τοποθέτηση Αιολικών Πάρκων

Όπως αναπτύχθηκε και στην αρχή του κεφαλαίου, η αιολική ενέργεια είναι ένα ταχέως εξελισσόμενο πεδίο που έχει προσελκύσει μεγάλη προσοχή και πολλές επενδύσεις τις τελευταίες δεκαετίες. Συνεπώς, όντας ένας πολύ ανταγωνιστικός τομέας, είναι πολύ σημαντικό να ελαχιστοποιηθεί το κόστος εγκατάστασης νέων αιολικών πάρκων και να αυξηθούν τα κέρδη παραγωγής ενέργειας από τη φάση του σχεδιασμού. Ο σχεδιασμός ενός αιολικού πάρκου είναι ένα σύνθετο έργο, που απαιτεί τεχνογνωσία από διαφορετικές ειδικότητες και εμπεριέχει ένα μεγάλο αριθμό μεταβλητών βελτιστοποίησης ([Fischetti and Pisinger, 2019](#)). Το πρόβλημα τοποθέτησης ενός αιολικού πάρκου δεν έχει αυτοματοποιηθεί πλήρως ακόμη, με την TN να προσφέρει πολλαπλές ευκαιρίες για τη βελτιστοποίηση της απόφασης σχεδιασμού.

Οι ερευνητικές προσπάθειες στον τομέα της εύρεσης βέλτιστης τοποθεσίας για την εγκατάσταση αιολικών πάρκων μπορούν να χωριστούν σε δύο υποκατηγορίες: χερσαία και υπεράκτια αιολικά πάρκα. Το πρόβλημα για καθεμιά από αυτές τις κατηγορίες εμπεριέχει διαφορετικούς περιορισμούς και συνεπώς είναι λογικό να εστιάζονται οι προσπάθειες σε συγκεκριμένο πλαίσιο. Όσον αφορά τα χερσαία αιολικά πάρκα, έχει αναπτυχθεί μια μεθοδολογία για τον προσδιορισμό της βέλτιστης θέσης ενός αιολικού πάρκου σε ένα δίκτυο μεταφοράς ηλεκτρικής ενέργειας με κυριότερο κριτήριο την αξιολόγηση ασφάλειας του δικτύου ([Shahzad, 2021](#)). Ακόμη, οι [Petrov and Wessling \(2015\)](#) προτείνουν μια εναλλακτική μεθοδολογία για τη βέλτιστη τοποθέτηση ανεμογεννητριών με κριτήριο περιβαλλοντολογικούς και οικολογικούς παράγοντες, συνδυάζοντας την πολυκριτήρια ανάλυση με τη μηχανική μάθηση. Όσον αφορά τα υπεράκτια αιολικά πάρκα, οι [Lee et al. \(2010\)](#) αναπτύσσουν μια μεθοδολογία βελτιστοποίησης που βασίζεται σε γενετικό αλγόριθμο. Αρχικά, χρησιμοποιούνται μοντέλα νευρωνικών δικτύων για την κατασκευή των χαρτών ανέμου και βαθυμετρίας και έπειτα ορίζεται ο γενετικός αλγόριθμος με στόχο τη μεγιστοποίηση της ενεργειακής πυκνότητας, ικανοποιώντας τα κριτήρια του

μέγιστου βάθους νερού και της μέγιστης απόστασης από την ακτογραμμή. Παρόμοια, η μελέτη των Wu et al. (2013) προτείνει μια μεθοδολογία για τον προσδιορισμό της βελτιστοποίησης της θέσης υπεράκτιων ανεμογεννητριών, χρησιμοποιώντας τεχνικές TN και γενετικούς αλγόριθμους.

3.4 Τεχνητή Νοημοσύνη και Ευελιξία σε Έξυπνα Δίκτυα

Όπως παρουσιάστηκε αναλυτικά στην προηγούμενη ενότητα, οι ΑΠΕ έχουν πολλαπλασιάσει τα τελευταία χρόνια, αποτελώντας κύρια αιτία για την αποκεντροποίηση και τον εκδημοκρατισμό της ενέργειας. Οι μικρές μονάδες παραγωγής που βρίσκονται στην πλευρά του καταναλωτή, όπως μικρά Φ/Β συστήματα στέγης και μικρές μονάδες αιολικής παραγωγής, ονομάζονται κατανεμημένοι ενεργειακοί πόροι (*distributed energy resources - DERs*). Από την άλλη πλευρά τα ηλεκτρικά φορτία που μπορούν να μετατοπιστούν κατά τη διάρκεια της ημέρας ή της εβδομάδας ονομάζονται ευέλικτα φορτία (*flexible loads*). Η ενσωμάτωση των κατανεμημένων ενεργειακών πόρων σε συνδυασμό με την αυξανόμενη χρήση συστημάτων αποθήκευσης και το βέλτιστο προγραμματισμό ευέλικτων φορτίων μπορούν να αποτελέσουν ένα δίκτυο διανομής χαμηλής τάσης που ονομάζεται μικροδίκτυο και μπορεί να λειτουργήσει είτε σε διασύνδεση με το κύριο δίκτυο είτε πλήρως αυτόνομα (Shayeghi et al., 2019).

Ουσιαστικά, κάθε προηγμένο σύστημα ηλεκτρικής ενέργειας που ενσωματώνει πληροφορίες από έξυπνα μετρητικά συστήματα και μπορεί να διαχειρίζεται βέλτιστα την παραγωγή και την κατανάλωση των κόμβων που το αποτελούν μπορεί να θεωρηθεί ως ευφυές δίκτυο. Τα κυριότερα προβλήματα στον τομέα των ευφύων δικτύων περιλαμβάνουν τη βέλτιστη αξιοποίηση των πόρων του δικτύου, την επίτευξη της υψηλότερης δυνατής ενεργειακής αποδοτικότητας, την υψηλότερη αξιοπιστία και ασφάλεια του συστήματος και την οικονομικότερη διανομή ηλεκτρικής ενέργειας στους καταναλωτές. Στον τομέα των έξυπνων δικτύων, τα παραγόμενα δεδομένα και οι αλγόριθμοι ΤΝ και βελτιστοποίησης αποτελούν καταλυτικούς παράγοντες στην επίλυση των προαναφερθέντων προβλημάτων και στην επίτευξη των στόχων σε επίπεδο μικροδικτύου.

Στην ενότητα αυτή εξετάζουμε προβλήματα που σχετίζονται με τους κατανεμημένους ενεργειακούς πόρους και μπορούν να επιλυθούν με τη χρήση αλγορίθμων βελτιστοποίησης και ΤΝ. Τα προβλήματα αυτά μπορούν να διαχωριστούν σε τέσσερις κύριες συνιστώσες: Η πρώτη εστιάζει στην πρόβλεψη της ζήτησης σε επίπεδο δικτύου, η δεύτερη επικεντρώνεται στην έννοια των προγραμμάτων απόκρισης ζήτησης και στο συσχετισμό τους με την αγορά ενέργειας, η τρίτη αφορά σε προβλήματα βελτιστοποίησης του προγραμματισμού ευέλικτων φορτίων και η τέταρτη μελετάει προβλήματα συστημάτων αποθήκευσης ενέργειας, τα οποία προβλέπεται πως διαμορφώσουν εκ νέου το τοπίο στη διαχείριση ενέργειας.

3.4.1 Μοντέλα Πρόβλεψης Φορτίου

Η πρόβλεψη του ηλεκτρικού φορτίου διαδραματίζει ζωτικό ρόλο στην ενεργειακή μετάβαση μέσω σύγχρονων συστημάτων ηλεκτρικής ενέργειας αποτελώντας τη βάση για πολλές καινοτόμες λύσεις, όπως τα έξυπνα δίκτυα, η βέλτιστη διαχείριση ενέργειας και ο σχεδιασμός ενεργειακών συστημάτων (Raza and Khosravi, 2015). Έτσι, τα τελευταία χρόνια μεγάλο μέρος της ενεργειακής έρευνας έχει εστιάσει στην ακριβή βραχυπρόθεσμη πρόβλεψη φορτίου λόγω της σημασίας της στην αξιόπιστη λειτουργία των συστημάτων ισχύος και συνεπώς στην οικονομία. Επιπλέον, σημαντικές λειτουργίες του συστήματος ηλεκτρικής ενέργειας, όπως ο προγραμματισμός, η συντήρηση και η προσαρμογή των τιμολογίων στηρίζονται σε μεγάλο βαθμό στις ακριβείς προβλέψεις φορτίου. Επομένως, γίνεται αντιληπτό πως η πρόβλεψη φορτίου μπορεί να επηρεάσει άμεσα την ενεργειακή πολιτική, αφού πλήθος αποφάσεων σε συστήματα διαχείρισης ενέργειας λαμβάνουν υπόψιν τις προβλέψεις ζήτησης ενέργειας.

Η πρόβλεψη φορτίου χωρίζεται σε τρεις κατηγορίες από τους περισσότερους ερευνητές με κριτήριο το χρονικό ορίζοντα της πρόβλεψης. Οι βραχυπρόθεσμες προβλέψεις αφορούν χρονικό διάστημα από μερικά λεπτά έως και μια μέρα ή μια εβδομάδα μπροστά. Η βραχυπρόθεσμη ζήτηση του φορτίου διαδραματίζει ζωτικό ρόλο στη βέλτιστη δέσμευση μονάδων, στον έλεγχο του αποθέματος ενέργειας και στην αξιολόγηση των συμβολαίων πωλήσεων και αγορών μεταξύ διαφόρων εταιρειών. Οι μεσοπρόθεσμες προβλέψεις εστιάζουν σε χρονικό διάστημα από μια εβδομάδα έως κι ένα χρόνο μπροστά και χρησιμοποιούνται για την αποτε-

Μελέτη	Έτος	Κατηγορία
Methaprayoon et al. (2003)	2003	Πρόβλεψη Φορτίου
Amarasinghe et al. (2017)	2017	Πρόβλεψη Φορτίου
Zheng et al. (2017)	2017	Πρόβλεψη Φορτίου
Alhussein et al. (2020)	2020	Πρόβλεψη Φορτίου
Raza et al. (2017)	2017	Πρόβλεψη Φορτίου
Zhang et al. (2010)	2010	Πρόβλεψη Φορτίου
Wen et al. (2015)	2015	Απόκριση Ζήτησης
Wang et al. (2020)	2020	Απόκριση Ζήτησης
Lu et al. (2019a)	2019	Απόκριση Ζήτησης
Jia and Tong (2016)	2016	Δυναμική Τιμολόγηση
Lu et al. (2018)	2018	Δυναμική Τιμολόγηση
Turner et al. (2015)	2015	Διαχείριση Ευέλικτων Φορτίων
Afzalan and Jazizadeh (2019)	2019	Διαχείριση Ευέλικτων Φορτίων
Favre and Peuportier (2014)	2014	Διαχείριση Ευέλικτων Φορτίων
He et al. (2022)	2022	Διαχείριση Ευέλικτων Φορτίων
Chapaloglou et al. (2019)	2019	Διαχείριση Ευέλικτων Φορτίων
Shirazi and Jadid (2017)	2017	Διαχείριση Ευέλικτων Φορτίων
Xiong et al. (2018)	2018	Συστήματα Αποθήκευσης
Duan et al. (2019)	2019	Συστήματα Αποθήκευσης
Zsembinszki et al. (2021)	2021	Συστήματα Αποθήκευσης
Oh and Wang (2020)	2020	Συστήματα Αποθήκευσης
Nyong-Bassey et al. (2020)	2020	Συστήματα Αποθήκευσης
Chong et al. (2018)	2018	Συστήματα Αποθήκευσης
Wang et al. (2023)	2023	Συστήματα Αποθήκευσης

Πίνακας 3.2: Ενδεικτικές μελέτες εφαρμογών TN στους καταναμημένους ενεργειακούς πόρους σε επίπεδο δικτύου.

λεσματική λειτουργία και συντήρηση του ηλεκτρικού συστήματος. Τέλος, οι μακροπρόθεσμες προβλέψεις συνδέονται με τη χάραξη πολιτικών και με τον μακροπρόθεσμο σχεδιασμό, έχοντας χρονικό ορίζοντα πρόβλεψης αρκετά χρόνια. Αξίζει να σημειωθεί πως η μακροπρόθεσμη πρόβλεψη φορτίου χρησιμοποιείται για τον μακροπρόθεσμο σχεδιασμό του συστήματος ηλεκτρικής ενέργειας σύμφωνα με τη μελλοντική ενεργειακή ζήτηση και την ενεργειακή πολιτική του εκάστοτε κράτους. Μάλιστα στην έρευνα των [Rahman and Hazim \(1993\)](#) γίνεται διαχωρισμός σε τέσσερις κατηγορίες, ωστόσο αυτή δεν είναι η συνήθης κατηγοριοποίηση.

Όπως αναφέρθηκε και παραπάνω, οι κυριότερες εργασίες που υποστηρίζονται από την πρόβλεψη φορτίου είναι ο προγραμματισμός της παραγωγής, η ασφαλής και συνεπής λειτουργία των μονάδων παραγωγής ηλεκτρισμού, η οικονομική κατανομή φορτίου (*economic dispatch*) και η διατήρηση της αξιοπιστίας. Πιο συγκεκριμένα, η αξιοπιστία του συστήματος ισχύος κυμαίνεται σε μεγάλο βαθμό λόγω των απότομων διακυμάνσεων της ζήτησης φορτίου. Για να γίνει πιο κατανοητό το πρόβλημα, ας θεωρήσουμε τα δύο πιθανά σενάρια αστοχίας κατά την πρόβλεψη της ζήτησης. Εάν η ζήτηση του φορτίου υποτιμηθεί, τότε το σύστημα μπορεί να αντιμετωπίσει έλλειψη τροφοδοσίας, ενώ εάν η ζήτηση φορτίου υπερεκτιμηθεί, τότε πολλοί διαθέσιμοι πόροι θα έχουν δαπανηθεί για την ικανοποίηση της υπερεκτιμημένης ζήτησης.

Γενικά, έχει παρατηρηθεί πως υπάρχει ισχυρή συσχέτιση μεταξύ των μεταβλητών του καιρού και της ζήτησης φορτίου ([Hernández et al., 2012](#)). Στις περισσότερες περιπτώσεις η ζήτηση αυξάνεται κατά τη θερινή περίοδο λόγω της αύξησης της θερμοκρασίας, ενώ είναι χαμηλότερη κατά τη χειμερινή περίοδο. Σε κάθε περίπτωση, οι μεταβλητές καιρού αποτελούν μία από τις βασικότερες εισόδους σε μοντέλα πρόβλεψης φορτίου. Επιπλέον, η ζήτηση φορτίου μεταβάλλεται με κυκλικό τρόπο κατά τη διάρκεια της ημέρας, λόγω της καθημερινής ρουτίνας που ακολουθείται από τους καταναλωτές και σταθερών εργασιών που πραγματοποιούνται συγκεκριμένες ώρες της ημέρας. Επομένως, και οι χρονικές μεταβλητές παίζουν σημαντικό ρόλο στην αύξηση της ακρίβειας πρόβλεψης.

Στη βιβλιογραφία μπορούν να εντοπιστούν πολλές μελέτες που έχουν ασχοληθεί με την ακριβή πρόβλεψη της ζήτησης φορτίου. Πιο συγκεκριμένα, στη μελέτη των [Amarasinghe et al.](#)

(2017) οι συγγραφείς παρουσιάζουν μια μεθοδολογία πρόβλεψης φορτίου που βασίζεται στη βαθιά μάθηση, χρησιμοποιώντας συνελκτικά νευρωνικά δίκτυα για την πρόβλεψη της ζήτησης ενός οικιακού κτιρίου και απέδειξαν πως το μοντέλο αυτό παρουσιάζει καλύτερη προβλεπτική ικανότητα από τους περισσότερους αλγορίθμους μηχανικής μάθησης. Μια άλλη έρευνα από τους [Zheng et al. \(2017\)](#) έκανε χρήση αναδρομικών νευρωνικών δικτύων με στόχο την πρόβλεψη της ζήτησης σε επίπεδο μικροδικτύου με ορίζοντα πρόβλεψης έως και μέρες μπροστά. Η έρευνα αυτή έδειξε πως τέτοια νευρωνικά δίκτυα παρουσιάζουν πολύ καλή δυνατότητα να προβλέπουν χρονοσειρές φορτίου παρά την εγγενή δυσκολία του προβλήματος. Ωστόσο, το πρόβλημα πρόβλεψης φορτίου μόνο εύκολο δε μπορεί να θεωρηθεί. Για αυτό το λόγο θεωρείται πως πλήθος ερευνητικών προσπαθειών θα εστιάσουν στην ανάπτυξη προβλεπτικών μοντέλων τα επόμενα χρόνια.

3.4.2 Απόκριση Ζήτησης και Αγορά Ενέργειας

Η απόκριση ζήτησης, ευρέως γνωστή με τον αγγλικό όρο *demand response*, μπορεί να οριστεί ως η αλλαγή στην κατανάλωση ηλεκτρικής ενέργειας από τους απλούς καταναλωτές, τις εμπορικές και τις βιομηχανικές επιχειρήσεις, προκειμένου να διατηρηθεί η ισορροπία της προσφοράς και της ζήτησης ηλεκτρικής ενέργειας. Τα συμβάντα απόκρισης ζήτησης συμβαίνουν σε ειδικά καθορισμένες ώρες κατά τις οποίες οι καταναλωτές καλούνται, εκ των προτέρων, να προσέχουν την κατανάλωση ενέργειας, λόγω υψηλής συμφόρησης του δικτύου. Τα οφέλη της απόκρισης ζήτησης περιλαμβάνουν την εξοικονόμηση ενέργειας, τη μείωση της ανάγκης για σταθμούς ηλεκτροπαραγωγής ορυκτών καυσίμων και την ενσωμάτωση των ΑΠΕ στο ηλεκτρικό δίκτυο παρέχοντας αυξημένη σταθερότητα και διαχείριση ([Bradley et al., 2013](#)). Επομένως, η απόκριση ζήτησης μπορεί να επιτρέψει στους καταναλωτές να μειώσουν την κατανάλωση ενέργειας μέσω περικοπής φορτίων, είτε μετατοπίζοντας χρονικά την κατανάλωση ενέργειας, είτε παράγοντας και αποθηκεύοντας ενέργεια σε συγκεκριμένες χρονικές στιγμές για να παρέχουν στο δίκτυο μεγαλύτερη ευελιξία. Σε αντάλλαγμα, οι καταναλωτές λαμβάνουν συνήθως μείωση του λογαριασμού ενέργειας είτε κάποιας άλλης μορφής ανταμοιβή ([Siano, 2014](#)).

Υπάρχουν δύο κύριες κατηγορίες προγραμμάτων απόκρισης ζήτησης σύμφωνα με τους [Vázquez-Canteli and Nagy \(2019\)](#). Η πρώτη κατηγορία αφορά προγράμματα βασισμένα σε κίνητρα (*incentive-based*), στα οποία οι καταναλωτές συμμετέχουν εθελοντικά σε ένα σύστημα στο οποίο ο διαχειριστής του συστήματος μπορεί να απενεργοποιήσει απευθείας ορισμένες συσκευές για να μειώσει την κατανάλωση ενέργειας κατά τις περιόδους αιχμής της ζήτησης. Αντίθετα, στη δεύτερη κατηγορία ανήκουν τα προγράμματα που βασίζονται στο χρόνο (*time-based*), τα οποία εστιάζουν στη δυναμική τιμολόγηση και στοχεύουν στην ισοπέδωση των καμπυλών ζήτησης προσφέροντας στον καταναλωτή τιμές ηλεκτρικής ενέργειας που ποικίλλουν χρονικά ανάλογα με τη συμφόρηση του δικτύου ([Shariatzadeh et al., 2015](#)). Η διαφορά τους με τα πρώτα είναι πως σε αυτή την κατηγορία προγραμμάτων ο διαχειριστής δε μπορεί να επέμβει απευθείας σε κάποια φορτία.

Αν και τα προγράμματα απόκρισης ζήτησης αποτελούν μια πολλά υποσχόμενη προσέγγιση για την αύξηση της ευελιξίας στα σύγχρονα μικροδίκτυα, θεωρείται πως τα προγράμματα αυτά δεν έχουν φτάσει το μέγιστο των δυνατοτήτων τους, όπως άλλωστε δείχνει έρευνα που πραγματοποιήθηκε στις ΗΠΑ ([Commission et al., 2008](#)). Μια από τις κυριότερες αιτίες για αυτό είναι πως η αξία της ηλεκτρικής ενέργειας είναι μεγαλύτερη από την τιμή της για τους καταναλωτές, οι οποίοι δεν είναι διατεθειμένοι να τροποποιήσουν τα συνηθισμένα τους πρότυπα κατανάλωσης ηλεκτρικής ενέργειας. Ένας ακόμη λόγος είναι η δυσκολία που αντιμετωπίζουν οι καταναλωτές να λάβουν πληροφορίες σχετικά με τις τιμές ηλεκτρικής ενέργειας και να κατανοήσουν τα οικονομικά οφέλη από τη συμμετοχή σε προγράμματα απόκρισης ζήτησης ([Vázquez-Canteli and Nagy, 2019](#)). Τα παραπάνω προβλήματα οδηγούν στην ανάγκη διαμόρφωσης σύγχρονων τεχνικών πλαισίων για την εφαρμογή αποτελεσματικών προγραμμάτων απόκρισης ζήτησης. Τα κυριότερα χαρακτηριστικά τέτοιων προγραμμάτων είναι η αυτοματοποίηση των αποφάσεων και η ικανότητα να αντιλαμβάνεται τις συνθήκες του περιβάλ-

λοντος και να εμπλέκει ενεργά τον καταναλωτή στη διαδικασία ελαχιστοποιώντας παράλληλα τα επίπεδα δυσφορίας του.

Η TN επιτυγχάνει τα παραπάνω σε μεγάλο βαθμό και έχει μεγάλη συμβολή στην ενσωμάτωση και βελτίωση προγραμμάτων απόκρισης ζήτησης. Κομβικό ρόλο ανάμεσα στους αλγόριθμους TN διαδραματίζει η ενισχυτική μάθηση, με πολλές έρευνες να έχουν αναπτυχθεί τα τελευταία χρόνια. Για παράδειγμα, οι [O'Neill et al. \(2010\)](#) παρουσίασαν ένα νέο σύστημα διαχείρισης ενέργειας για την ανταπόκριση της οικιακής ζήτησης, το οποίο βασίζεται σε έναν αλγόριθμο που εκτιμά έμμεσα τον αντίκτυπο των μελλοντικών τιμών ενέργειας και των αποφάσεων των καταναλωτών στο μακροπρόθεσμο κόστος και προγραμματίζει τη χρήση οικιακών συσκευών. Μια παρόμοια έρευνα από τους [Wen et al. \(2015\)](#) παρουσιάζει ένα σύστημα διαχείρισης ενέργειας για οικιακά και μικρά εμπορικά κτίρια. Το σύστημα βασίζεται σε έναν πολύ γνωστό αλγόριθμο ενισχυτικής μάθησης (*Q-learning*), ο οποίος δίνει στο χρήστη τη δυνατότητα να εισάγει τις προτιμήσεις του και να αυτο-εκκινεί εργασίες μέσω ευέλικτων αιτημάτων.

Όπως παρουσιάστηκε στις προηγούμενες παραγράφους, η απόκριση ζήτησης είναι ένα πρόβλημα με σαφείς συμπεριφορικές προεκτάσεις, αφού η προσφορά κατάλληλων κινήτρων έχει βασικό ρόλο στην επιτυχημένη εφαρμογή τέτοιων προγραμμάτων. Συνεπώς, προκύπτει μια άμεση σύνδεση με την αγορά ενέργειας και την ενεργειακή τιμολογιακή πολιτική ως κίνητρο για την επίτευξη του στόχου. Πιο συγκεκριμένα, το πρόβλημα που διαπιστώνεται είναι η δυναμική τιμολόγηση της ενέργειας, προσαρμόζοντας έγκαιρα την τιμή της ενέργειας, παρέχοντας κίνητρο στον καταναλωτή να διαμορφώσει κατάλληλα τις ανάγκες του σε ενέργεια. Ένα χαρακτηριστικό παράδειγμα είναι η έρευνα των [Lu et al. \(2018\)](#), οι οποίοι χρησιμοποιούν έναν αλγόριθμο ενισχυτικής μάθησης για να επιτύχουν τη δυναμική τιμολόγηση της ενέργειας στα πλαίσια προγραμμάτων απόκρισης ζήτησης. Τα αποτελέσματα της προσομοίωσης που πραγματοποιήθηκε έδειξαν πως ο προτεινόμενος αλγόριθμος δυναμικής τιμολόγησης, μπορεί να αυξήσει την κερδοφορία του παρόχου, να μειώσει το ενεργειακό κόστος για τους πελάτες και να εξισορροπήσει την προσφορά και τη ζήτηση ενέργειας στην αγορά ηλεκτρικής ενέργειας, επιφέροντας βελτίωση της αξιοπιστίας του συστήματος ηλεκτρικής ενέργειας.

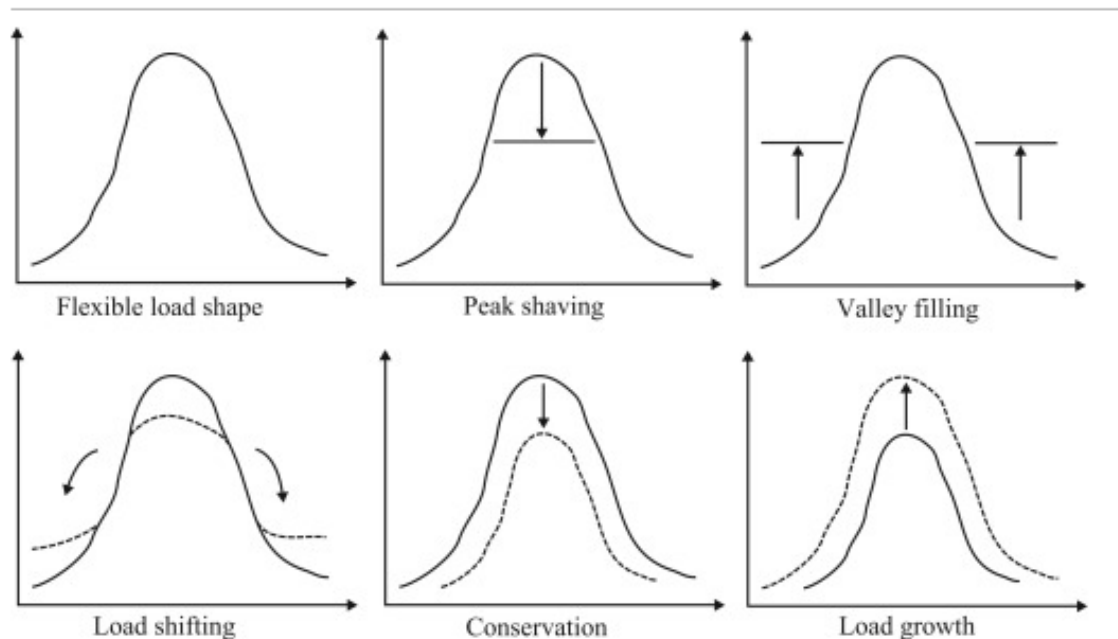
3.4.3 Βελτιστοποίηση Ευέλικτων Φορτίων και Διαχείριση Ζήτησης

Στην προηγούμενη ενότητα παρουσιάστηκαν τα προγράμματα απόκρισης ζήτησης, που έχουν ως στόχο να προσφέρουν κίνητρα στους καταναλωτές να μεταπίσουν ορισμένο μέρος της κατανάλωσης τους από τις ώρες αιχμής προς άλλες ώρες. Ωστόσο, η απόκριση ζήτησης αποτελεί μια μόνο διάσταση του προβλήματος ευελιξίας στο δίκτυο. Το γενικότερο πρόβλημα μπορεί να διατυπωθεί ως πρόβλημα βελτιστοποίησης για την βέλτιστη δυνατή τοποθέτηση των ευέλικτων φορτίων, το οποίο παρουσιάζεται αναλυτικότερα σε αυτή την ενότητα.

Τα ενεργειακά συστήματα χρειάζονται ευελιξία για να ικανοποιήσουν την ενεργειακή ζήτηση που ποικίλλει με την πάροδο του χρόνου. Υπάρχει μια σειρά διαφορετικών προσεγγίσεων για την αύξηση της ευελιξίας του ενεργειακού συστήματος είτε από την πλευρά της προσφοράς, είτε από την πλευρά της ζήτησης. Από την πλευρά της προσφοράς, η ευελιξία επιτυγχάνεται μέσω σταθμών παραγωγής ενέργειας με διαφορετικό χρόνο απόκρισης. Ωστόσο, η χρήση πηγών μεταβλητής παραγωγής ενέργειας, όπως η αιολική και η ηλιακή ενέργεια, αυξάνει την ανάγκη ευελιξίας του ενεργειακού συστήματος ([Lund et al., 2015](#)). Βέβαια, υπάρχουν διαφορετικοί ακριβείς ορισμοί για την ευελιξία, με συνέπεια οι μετρικές για τον να μην είναι ίδιες σε κάθε περίπτωση ([Huber et al., 2014](#)).

Η διαχείριση από την πλευρά της ζήτησης (*demand-side management*) είναι ίσως το πιο ενδιαφέρον πρόβλημα στον τομέα της ευελιξίας δικτύου, περιλαμβάνοντας ένα ευρύ σύνολο μέσων αλλαγής της κατανάλωσης ηλεκτρικής ενέργειας. Σύμφωνα με τους [Gellings and Smith \(1989\)](#) υπάρχουν τρεις κύριες κατηγορίες: Η εξομάλυνση αιχμών (*peak shaving*), η γέμιση κοιλάδων (*valley filling*) και η μετατόπιση φορτίου (*load shifting*). Η μετατόπιση φορτίου απαιτεί κάποιο μέσο ενδιάμεσης αποθήκευσης και ποσοστό χρησιμοποίησης μικρότερο

από 100%, διότι εμπεριέχει και αύξηση και μείωση του φορτίου (Han et al., 2015). Ακόμη και αν η λειτουργικότητα της μετατόπισης φορτίου είναι παρόμοια με τη φιλοσοφία της αποθήκευσης ενέργειας, η διαφορά έγκειται στο ότι η διαχείριση της ζήτησης δεν απαιτεί μετατροπή ενέργειας από και προς κάποια άλλη μορφή.



Σχήμα 3.2: Διαφορετικοί τρόποι παροχής ευελιξίας μέσω της μετατόπισης ευέλικτων φορτίων.

Παρόλο που η ιδέα της διαχείρισης της ζήτησης έχει διατυπωθεί πολλές δεκαετίες πριν, η επιτυχής εφαρμογή της περιλαμβάνει αρκετά προβλήματα (Strbac, 2008). Η TN και γενικότερα η μαθηματική βελτιστοποίηση στοχεύει στην αντιμετώπιση μέρους αυτών των προβλημάτων μέσω αλγορίθμων που τοποθετούν τα ευέλικτα φορτία με βέλτιστο τρόπο. Για το λόγο αυτό έχουν αναπτυχθεί πολλές έρευνες που διερευνούν τα θέματα της εξομάλυνσης αιχμών, της γέμισης κοιλάδων και της μετατόπισης φορτίου (Uddin et al., 2018). Στην έρευνα των Chapaloglou et al. (2019) αναπτύχθηκε ένας αλγόριθμος βελτιστοποίησης για τη διαχείριση των ροών ισχύος ενός νησιωτικού συστήματος ισχύος. Ο αλγόριθμος αυτός οδηγεί στην επίτευξη σταθερότερης λειτουργίας του συστήματος ενώ ταυτόχρονα μειώνει τις τιμές αιχμής ζήτησης, για τις ημέρες του έτους που παρουσιάζουν νυχτερινή αιχμή στην καμπύλη φορτίου τους. Ο προτεινόμενος αλγόριθμος συνδυάζει τη χρήση μοντέλων βαθιάς μάθησης για την πρόβλεψη φορτίου, μια διαδικασία αναγνώρισης προτύπων και έναν προσαρμοσμένο αλγόριθμο προγραμματισμού βέλτιστης ροής ισχύος. Μια διαφορετική εφαρμογή αναπτύχθηκε από τους Shirazi and Jadid (2017), οι οποίοι πρότειναν ένα μοντέλο διαχείρισης ενέργειας έξυπνου σπιτιού που λαμβάνει υπόψη τόσο την κατανάλωση ενέργειας όσο και την παραγωγή. Το προτεινόμενο μοντέλο ρυθμίζει τις οικιακές ηλεκτρικές και θερμικές συσκευές για λειτουργία έτσι ώστε το χρηματικό κόστος ενός πελάτη να ελαχιστοποιείται με βάση το μοντέλο τιμολόγησης που μεταβάλλεται χρονικά.

3.4.4 Συστήματα Αποθήκευσης Ενέργειας

Οι τεχνολογίες αποθήκευσης ενέργειας διαδραματίζουν ενεργό ρόλο στην επίτευξη μεγαλύτερης ευελιξίας του δικτύου ενέργειας, στη βελτίωση των δυνατοτήτων κατανάλωσης ενέργειας, στη διασφάλιση της σταθερής και οικονομικής λειτουργίας των συστημάτων ηλεκτρικής ενέργειας και στην προώθηση της ευρείας εφαρμογής των τεχνολογιών ΑΠΕ. Πολλές καινοτόμες λύσεις, ιδέες και τεχνολογίες έχουν εισαχθεί πρόσφατα στον τομέα της απο-

θήκευσης ενέργειας από πολλές διαφορετικές οπτικές όπως ο τομέας των υλικών, η διαχείριση των συστημάτων και ο έλεγχός τους μέσα από αλγόριθμους TN με στόχο τη βελτιστοποίηση της λειτουργίας του δικτύου (Abdalla et al., 2021). Στο πλαίσιο αυτό, πολλές ερευνητικές προσπάθειες έχουν εισαγάγει διαφορετικούς αλγόριθμους και μεθόδους για την ενοποίηση της ανανεώσιμης ενέργειας και των συστημάτων αποθήκευσης, προσφέροντας λύσεις σε πολλά προβλήματα όπως η βελτιστοποίηση του συστήματος, η υποστήριξη στρατηγικών ελέγχου της ενέργειας και η διαστασιοποίηση συστημάτων αποθήκευσης ενέργειας.

Οι περισσότερες εφαρμογές TN εστιάζουν στη διαχείριση ενέργειας υβριδικών συστημάτων τα οποία αποτελούνται από συστήματα αποθήκευσης ενέργειας και πηγές παραγωγής ενέργειας, όπως Φ/Β συστήματα ή αιολικά πάρκα. Οι Xiong et al. (2018) ανέπτυξαν, για παράδειγμα, έναν αλγόριθμο ενισχυτικής μάθησης για τη διαχείριση ενέργειας σε πραγματικό χρόνο. Ο αλγόριθμος μπορεί να μαθαίνει τις τρέχουσες πληροφορίες για την κατανάλωση του συστήματος καθώς και την υγεία της μπαταρίας και στη συνέχεια να ενημερώνει τη στρατηγική. Τα αποτελέσματα της έρευνας έδειξαν πως η προτεινόμενη στρατηγική διαχείρισης ενέργειας μπορεί να περιορίσει το μέγιστο ρεύμα εκφόρτισης και να μειώσει τη συχνότητα φόρτισης της μπαταρίας, ενώ ταυτόχρονα μειώνει την απώλεια ενέργειας και βελτιστοποιεί την απόδοση του συστήματος. Μια παρόμοια έρευνα των Duan et al. (2019) προτείνει μια μέθοδο ελέγχου βασισμένη στην ενισχυτική μάθηση για ένα υβριδικό σύστημα αποθήκευσης ενέργειας σε μικροδίκτυα εναλλασσόμενου ρεύματος που περιλαμβάνουν Φ/Β συστήματα και γεννήτριες ντίζελ, αναδεικνύοντας την αποτελεσματικότητα των αλγόριθμων σε περίπλοκα συστήματα. Η συγκεκριμένη μέθοδος δοκιμάστηκε επιτυχώς τόσο σε διασυνδεδεμένο δίκτυο όσο και σε μη διασυνδεδεμένο νησιωτικό δίκτυο. Τα δύο αυτά παραδείγματα είναι μερικά μόνο από μια σειρά επιτυχημένων εφαρμογών της TN σε υβριδικά συστήματα αποθήκευσης ενέργειας, με τη βαθιά μάθηση να έχει κερδίσει πολύ έδαφος παρουσιάζοντας εξαιρετικά αποτελέσματα συγκριτικά με μεθόδους που βασίζονται σε απλούς κανόνες Zsembinski et al. (2021).

3.5 Τεχνητή Νοημοσύνη και Ενεργειακή Αποδοτικότητα Κτιρίων

Η επανάσταση στον χώρο των μεγάλων δεδομένων, η ανάπτυξη ισχυρών, προηγμένων αλγορίθμων και η πρόσβαση σε πλήθος υπολογιστικών πόρων έχουν αποτελέσει σημαντικούς παράγοντες για την κλιμάκωση εφαρμογών που βασίζονται στη μηχανική μάθηση για την έρευνα στον κτιριακό τομέα τις τελευταίες δεκαετίες, αποδεικνύοντας τις δυνατότητές της TN στη βελτίωση την απόδοσης του κτιρίου. Σε αυτή την ενότητα παρουσιάζεται ένας πλήθος προβλημάτων στον τομέα των κτιρίων για τα οποία έχουν εφαρμοστεί αλγόριθμοι μηχανικής μάθησης σε διαφορετικά στάδια του κύκλου ζωής του κτιρίου. Το βασικότερο συμπέρασμα που προκύπτει από την ανάλυση που θα ακολουθηθεί είναι πως η ανάλυση δεδομένων με μεθόδους TN ανοίγει νέους ορίζοντες στο σχεδιασμό, τη λειτουργία και τον έλεγχο των κτιρίων, καθώς μεγάλο πλήθος ερευνών γίνονται διαθέσιμες, οι οποίες αυξάνονται σημαντικά χρόνο με το χρόνο.

Ανάμεσα στις εφαρμογές που έχουν αναπτυχθεί τα τελευταία χρόνια, υπάρχουν αρκετές επιτυχημένες μελέτες που αποσκοπούν στην ανίχνευση και τον εντοπισμό σφαλμάτων εξοπλισμού σε διάφορα συστήματα του κτιρίου (π.χ. HVAC σύστημα), στην πρόβλεψη ή εκτίμηση της ενεργειακής κατανάλωσης του κτιρίου, στην κατάταξη των κτιρίων με κριτήριο την ενεργειακή τους αποδοτικότητα, στην εκμάθηση των συμπεριφορών των χρηστών του κτιρίου και στην βελτιστοποίηση της χρήσης των υποσυστημάτων ενός κτιρίου, μεταξύ άλλων. Ωστόσο ελάχιστες από τις έρευνες αυτές έχουν υιοθετηθεί σε ευρεία κλίμακα από την οικοδομική βιομηχανία, λόγω ενός μεγάλου πλήθους κοινών προκλήσεων, όπως η έλλειψη δεδομένων μεγάλης κλίμακας σε τυποποιημένη μορφή για την εκπαίδευση και επικύρωση των μοντέλων μηχανικής μάθησης, η έλλειψη δυνατότητας μεταφοράς ενός μοντέλου μηχανικής μάθησης από κτίριο σε κτίριο, η οποία περιορίζει ένα μοντέλο να μπορεί να χρησιμοποιηθεί συνολικά για μια ομάδα κτιρίων και η - συχνά δικαιολογημένη - δυσπιστία προς τα μοντέλα μηχανικής μάθησης, η απόδοση των οποίων μπορεί να μην είναι τόσο αξιόπιστη σε πολλές περιπτώσεις οδηγώντας σε λανθασμένες εκτιμήσεις που επιφέρουν αρνητικές συνέπειες για τους χρήστες του κτιρίου αλλά και για την ενεργειακή αποδοτικότητά του. Επομένως, είναι σημαντικό οι μελλοντικές μελέτες να εστιάζουν σε ορισμένους βασικούς πυλώνες όπως: (α) η βελτίωση της θερμικής άνεσης (*thermal comfort*) των χρηστών του κτιρίου, (β) η επίτευξη ενεργειακής αποδοτικότητας στο κτίριο, (γ) η ευελιξία ζήτησης (*demand flexibility*) και (δ) η ανθεκτικότητα των κτιρίων. Ασφαλώς για όλα τα παραπάνω είναι προαπαιτούμενο να υπάρχουν διαθέσιμα δεδομένα σε προτυποποιημένη μορφή ώστε τα μοντέλα που αναπτύσσονται να είναι γενικεύσιμα και επαναχρησιμοποιήσιμα.

Τα προβλήματα που σχετίζονται με τον τομέα της ενεργειακής αποδοτικότητας σε επίπεδο κτιρίου και άπτονται του τομέα της TN μπορούν να διαχωριστούν σε τέσσερις (4) βασικές κατηγορίες. Είναι δεδομένο πως κοινός στόχος σε όλες τις κατηγορίες είναι η δημιουργία πράσινων κτιρίων με όσο το δυνατόν μικρότερο αποτύπωμα άνθρακα, ή ακόμη και με θετικό αποτύπωμα άνθρακα σε περιπτώσεις που αυτό είναι δυνατόν (*positive-energy buildings*). Οι κατηγορίες αυτές είναι οι εξής:

- Σχεδιασμός Κτιρίου
- Κατασκευή Κτιρίου
- Λειτουργία Κτιρίου
- Ανακαίνιση Κτιρίου

3.5.1 Σχεδιασμός Κτιρίου

Το στάδιο του σχεδιασμού είναι ένα από τα βασικότερα στάδια κατά τον κύκλο ζωής ενός κτιρίου. Η πρόοδος που έχει επιτευχθεί στον τομέα της TN έχει αλλάξει ριζικά τον τρόπο με

Μελέτη	Έτος	Κατηγορία	Υποκατηγορία
Zhang et al. (2018)	2018	Σχεδιασμός	Παραμετρικός Σχεδιασμός
Fuhrmann et al. (2018)	2018	Σχεδιασμός	Παραμετρικός Σχεδιασμός
Brown and Mueller (2019)	2019	Σχεδιασμός	Παραμετρικός Σχεδιασμός
Tamke et al. (2018)	2018	Σχεδιασμός	Παραμετρικός Σχεδιασμός
Nagy et al. (2017)	2017	Σχεδιασμός	Γενετικός Σχεδιασμός
Chaillou (2022)	2022	Σχεδιασμός	Γενετικός Σχεδιασμός
Huang and Zheng (2018)	2018	Σχεδιασμός	Γενετικός Σχεδιασμός
Liu et al. (2017a)	2017	Σχεδιασμός	Γενετικός Σχεδιασμός
Kim et al. (2010)	2010	Σχεδιασμός	Αξιολόγηση Σχεδιασμού
Geyer and Singaravel (2018)	2018	Σχεδιασμός	Αξιολόγηση Σχεδιασμού
Phelan et al. (2017)	2017	Σχεδιασμός	Αξιολόγηση Σχεδιασμού
De Ruyck et al. (2018)	2018	Σχεδιασμός	Αξιολόγηση Σχεδιασμού
Chatzikonstantinou and Sariyildiz (2016)	2016	Σχεδιασμός	Αξιολόγηση Σχεδιασμού
Lorenz et al. (2018)	2018	Σχεδιασμός	Αξιολόγηση Σχεδιασμού
Liu et al. (2017b)	2017	Σχεδιασμός	Αξιολόγηση Σχεδιασμού
Cheng et al. (2010)	2010	Κατασκευή	Ανάλυση Κόστους
Kim et al. (2013)	2013	Κατασκευή	Ανάλυση Κόστους
Tian et al. (2009)	2009	Κατασκευή	Ανάλυση Κόστους
Huang et al. (2021)	2021	Κατασκευή	BIM
Tang et al. (2010)	2010	Κατασκευή	BIM
Braun and Borrmann (2019)	2019	Κατασκευή	BIM
Koo et al. (2021)	2021	Κατασκευή	BIM
Brilakis and Soibelman (2008)	2008	Κατασκευή	Διαχείριση Κατασκευής
Brilakis et al. (2005)	2005	Κατασκευή	Διαχείριση Κατασκευής
Zhu and Brilakis (2010a)	2010	Κατασκευή	Διαχείριση Κατασκευής
Akinci et al. (2006)	2006	Κατασκευή	Εντοπισμός Ελαττωμάτων
Zhu and Brilakis (2010b)	2010	Κατασκευή	Εντοπισμός Ελαττωμάτων
Yildiz and Arsan (2011)	2011	Λειτουργία	Ενεργειακή Αποδοτικότητα
Khayatian et al. (2016)	2016	Λειτουργία	Ενεργειακή Αποδοτικότητα
Fan et al. (2018)	2018	Λειτουργία	Ενεργειακή Αποδοτικότητα
Castilla et al. (2013)	2013	Λειτουργία	Θερμική Άνεση
Fan et al. (2018)	2018	Λειτουργία	Θερμική Άνεση
Lu et al. (2019b)	2019	Λειτουργία	Θερμική Άνεση
Ferreira et al. (2012)	2012	Λειτουργία	Θερμική Άνεση
Moon et al. (2013)	2013	Λειτουργία	Θερμική Άνεση
Moon and Jung (2016)	2016	Λειτουργία	Θερμική Άνεση
Kelly and Knottenbelt (2015)	2015	Λειτουργία	Συντήρηση
Yan et al. (2018)	2018	Λειτουργία	Συντήρηση
Fan et al. (2010)	2010	Λειτουργία	Συντήρηση
Wu and Sun (2011)	2011	Λειτουργία	Συντήρηση
Luo et al. (2017)	2017	Λειτουργία	Ευφυής Έλεγχος
Zakula et al. (2014)	2014	Λειτουργία	Ευφυής Έλεγχος
Ruelens et al. (2015)	2015	Λειτουργία	Ευφυής Έλεγχος
Park et al. (2019)	2019	Λειτουργία	Ευφυής Έλεγχος
Cecconi et al. (2019)	2019	Ανακαίνιση	Σχεδιασμός Μετασκευής
Gao and Malkawi (2014)	2014	Ανακαίνιση	Σχεδιασμός Μετασκευής
Yalcintas (2006)	2006	Ανακαίνιση	Σχεδιασμός Μετασκευής
Marasco and Kontokosta (2016)	2016	Ανακαίνιση	Σχεδιασμός Μετασκευής
Granderson et al. (2017)	2017	Ανακαίνιση	Εκτίμηση Εξοικονόμησης
Gallagher et al. (2018b)	2018	Ανακαίνιση	Εκτίμηση Εξοικονόμησης
Gallagher et al. (2018a)	2018	Ανακαίνιση	Εκτίμηση Εξοικονόμησης

Πίνακας 3.3: Ενδεικτικές μελέτες εφαρμογών TN για την ενεργειακή αποδοτικότητα στον κτιριακό τομέα.

τον οποίο οι αρχιτέκτονες σχεδιάζουν σύγχρονα κτίρια στις μέρες, με συνέπεια να έχει αλλάξει άρδην το τοπίο στον κτιριακό τομέα. Τα διαθέσιμα δεδομένα από κτίρια γίνονται πολύ πιο προσιτά πλέον, με συνέπεια να προσφέρονται ευκαιρίες για τη βελτιστοποίηση και το μετασχη-

ματισμό των παραδοσιακών ροών εργασίας σχετικά με το σχεδιασμό των κτιρίων. Σύμφωνα με μια πλήρη ανασκόπηση που δημοσιεύθηκε πρόσφατα, η μηχανική μάθηση έχει ενισχύσει το σχεδιασμό κτιρίων σε τρεις διαφορετικές συνιστώσες: με την προσομοίωση παραμετρικού σχεδιασμού (*parametric design emulation*), με τον γενετικό σχεδιασμό (*generative design*) και με την αξιολόγηση της σχεδίασης (*design evaluation*).

Στην κατηγορία του **παραμετρικού σχεδιασμού**, η εφαρμογή μοντέλων μηχανικής μάθησης σε συνδυασμό με τη χρήση στατιστικών μεθόδων, διευκολύνουν τις διαδικασίες που επιτελούνται κατά τη ροή των εργασιών του σχεδιασμού. Ειδικότερα, ο παραδοσιακός παραμετρικός σχεδιασμός απαιτεί τον καθορισμό κανόνων σχεδίασης και η έλευση της TN επιφέρει την ανάγκη κωδικοποίησης αυτών των κανόνων στο πρόγραμμα. Σαν αποτέλεσμα, η εξερεύνηση του χώρου σχεδιασμού εξακολουθούσε να περιορίζεται από τις ικανότητες των σχεδιαστών (Brown and Mueller, 2019). Ωστόσο, τα προηγούμενα χρόνια δοκιμάστηκαν με επιτυχία αρκετά εργαλεία παραμετρικού σχεδιασμού στον αρχιτεκτονικό και δομικό σχεδιασμό με στόχο τη βελτιστοποίηση του σχεδιασμού, επιτρέποντας στους σχεδιαστές όχι μόνο να ορίσουν μια τελική γεωμετρική λύση, αλλά και να περιγράψουν ολόκληρο το σύστημα και συγκεκριμένες παραμέτρους στο σύστημα που οδηγούν διαφορετικές παραλλαγές του σχεδίου. Οι τεχνικές μηχανικής μάθησης έχουν χρησιμοποιηθεί για την εξομοίωση των αυστηρά κωδικοποιημένων κανόνων και παραμέτρων, διευκολύνοντας την αυτοματοποίηση των σχετικών διαδικασιών (Tamke et al., 2018).

Χαρακτηριστικό παράδειγμα αποτελεί η μελέτη των Zhang et al. (2018) όπου παρουσιάζεται ένα πλαίσιο για την αξιολόγηση της μετασεισμικής δομικής ασφάλειας. Στη συγκεκριμένη έρευνα οι αλγόριθμοι μηχανικής μάθησης χρησιμοποιούνται για τη χαρτογράφηση των μοτίβων απόκρισης και ζημιών στην κατάσταση δομικής ασφάλειας του κτιρίου με βάση ένα αποδεκτό όριο υπολειπόμενης ικανότητας κατάρρευσης, ενώ τα μοντέλα πρόβλεψης χρησιμοποιούνται για τον πιθανολογικό προσδιορισμό της κατάστασης δομικής ασφάλειας ενός κτιρίου που έχει υποστεί ζημιά από σεισμό. Μια άλλη πρόσφατη έρευνα που αναπτύχθηκε από τους Fuhri-mann et al. (2018) έχει ως στόχο να εισάγει μια νέα διαδικασία δομικού σχεδιασμού που επιτρέπει στους αρχιτέκτονες και τους μηχανικούς να επεκτείνουν τον τυπικό σχεδιαστικό τους ορίζοντα. Πιο συγκεκριμένα, οι συγγραφείς προτείνουν μια υβριδική μέθοδο που βασίζεται στον συνδυασμό δομικών αλγορίθμων εύρεσης φόρμας κατασκευής (Combinatorial Equilibrium Modeling) και σύγχρονων αλγορίθμων μηχανικής μάθησης (Self Organizing Maps) για την ανάλυση του σχεδιαστικού χώρου και τον έλεγχο των αλληλεπιδράσεων μεταξύ των παραμέτρων εισόδου.

Στον τομέα του **γενετικού σχεδιασμού**, πολλές μελέτες έχουν αναπτυχθεί την τελευταία δεκαετία, έχοντας ως επίκεντρο τα *Generative Adversarial Networks*, τα οποία αποτελούν μια κατηγορία συστημάτων μηχανικής μάθησης που αυτοματοποιούν τη χρονοβόρα διαδικασία της μη αυτόματης εφαρμογής κανόνων σχεδιασμού. Μάλιστα αυτά τα μοντέλα έχουν εφαρμοστεί με επιτυχία για τη δημιουργία κάτοψης και τη μετατροπή στυλ (Nagy et al., 2017; Chaillou, 2022). Ένα πρόσφατο παράδειγμα είναι η έρευνα των Huang and Zheng (2018), οι οποίοι εφάρμοσαν μια παραλλαγή του GAN για την αναγνώριση αρχιτεκτονικών σχεδίων και τη σήμανση δωματίων με διαφορετικά χρώματα, με τελικό στόχο τη δημιουργία κατόψεων δι-αμερισμάτων. Επιπλέον, η μηχανική μάθηση μπορεί να βοηθήσει στην εκμείωση και μετατροπή αρχιτεκτονικών στυλ, μαθαίνοντας σε βάθος το νόημα των λειτουργικών κανόνων που ορίζουν την εσωτερική οργάνωση της διαδικασίας του σχεδιασμού. Τέλος, οι Liu et al. (2017a) αντιμετώπισαν το πρόβλημα της μετατροπής μιας εικόνας κάτοψης από μορφή *raster* σε αναπαράσταση διανυσματικών γραφικών, διευκολύνοντας την οπτικοποίηση εσωτερικών χώρων, τον άμεσο χειρισμό μοντέλων για αρχιτεκτονική αναδιαμόρφωση και άλλες υπολογιστικές εφαρμογές όπως η ανάλυση δεδομένων κατά το στάδιο του σχεδιασμού.

Τέλος, η χρήση της TN στη **διαδικασία αξιολόγησης του σχεδιασμού** είναι ένα ακόμη χρήσιμο εργαλείο για τους σχεδιαστές και τους αρχιτέκτονες (Kim et al., 2010). Στην περίπτωση αυτή οι αντικειμενικές επικεντρώνονται στη βέλτιστη χρήση των χώρων του κτιρίου, στην ασφάλεια, στην ευημερία των κατοίκων και στην ενεργειακή αποδοτικότητα (Geyer and Singaravel, 2018). Μάλιστα πολλές φορές η επίδοση των μοντέλων TN ξεπερνά

τις εκτιμήσεις επαγγελματιών σχεδιαστών, με χαρακτηριστικό παράδειγμα τη μελέτη των [Phelan et al. \(2017\)](#), οι οποίοι πρότειναν ένα νευρωνικό δίκτυο για την πρόβλεψη της χρήσης μιας αίθουσας συσκέψεων βασιζόμενοι σε ιστορικά δεδομένα από 56 άλλα κτίρια. Τα αποτελέσματα ήταν άκρως ενθαρρυντικά αφού το νευρωνικό δίκτυο υπέρσχυσε έναντι των προβλέψεων σχεδιαστών. Μια άλλη περίπτωση παρουσιάζεται στην έρευνα των [De Rycke et al. \(2018\)](#) όπου αναπτύχθηκε μοντέλο μηχανικής μάθησης για να ταξινομήσει τα λιγότερο επιθυμητά γραφεία με τη βοήθεια προσομοιώσεων σε εργαλείο Μοντελοποίησης Κατασκευαστικών Πληροφοριών (*Building Information Modeling - BIM*).

Βέβαια, η αξιολόγηση του σχεδιασμού περιλαμβάνει και την έννοια της άνεσης των χρηστών ή των κατοίκων και την εκμετάλλευση του φυσικού φωτός. Και για αυτούς τους τομείς έχουν αναπτυχθεί τεχνικές που βασίζονται στην TN ([Liu et al., 2017b](#); [Zhou and Liu, 2015](#); [Radziszewski and Waczyńska, 2018](#)). Για παράδειγμα, η μελέτη των [Chatzikonstantinou and Sariyildiz \(2016\)](#) συνέκρινε την ακρίβεια και το υπολογιστικό κόστος τριών μεθόδων μηχανικής μάθησης σε σχέση με τη δυνατότητα εφαρμογής τους στην προσέγγιση της αυτονομίας του φυσικού φωτός και της πιθανότητας αντανάκλασης του φωτός της ημέρας. Σε αυτή την έρευνα τα μοντέλα εκπαιδεύονταν επαγωγικά μέσω δεικτών οπτικής άνεσης που προέρχονται από προσομοιώσεις σε χώρους γραφείων. Παρόμοια, οι [Lorenz et al. \(2018\)](#) πρότειναν ένα νευρωνικό δίκτυο για την πρόβλεψη επιπέδων αυτονομίας φυσικού φωτός ημέρας με βάση το κλίμα σε εσωτερικούς χώρους. Τα αποτελέσματα ήταν άκρως ανταγωνιστικά σε σύγκριση με τις υπολογιστικά ακριβότερες προσομοιώσεις φυσικού φωτισμού.

3.5.2 Κατασκευή Κτιρίου

Η διαδικασία της κατασκευής του κτιρίου είναι το δεύτερο στάδιο στον κύκλο ζωής του και ακολουθεί τη διαδικασία του σχεδιασμού που αναλύθηκε στην προηγούμενη ενότητα. Η TN βρίσκει ευρεία πεδία εφαρμογής και στο στάδιο της κατασκευής του κτιρίου, και μάλιστα τα οφέλη αυτά μπορούν να κατηγοριοποιηθούν σε τέσσερις κατηγορίες προβλημάτων: την ανάλυση του κόστους κατασκευής, τη μοντελοποίηση δομικών πληροφοριών, τη διαχείριση της κατασκευής και τον εντοπισμό πιθανών ελαττωμάτων.

Αρχικά, όσον αφορά τη **ανάλυση του κόστους κατασκευής** η TN βρίσκει πλήθος εφαρμογών με κυριότερη την εκτίμηση του συνολικού κόστους με τη χρήση προβλεπτικών μεθόδων. Η πρόβλεψη του κόστους κατασκευής είναι απαραίτητη σε κάθε νέο έργο, αφού βοηθάει τους διαχειριστές έργων να εντοπίσουν πιθανά προβλήματα και να ελέγξουν το κόστος του έργου, ωστόσο ο ακριβής υπολογισμός του είναι δύσκολος στα αρχικά στάδια όταν οι πληροφορίες του έργου είναι περιορισμένες. Την τελευταία δεκαετία αρκετές μελέτες έχουν επικεντρωθεί σε αυτό το πρόβλημα. Για παράδειγμα, οι [Cheng et al. \(2010\)](#) πρότειναν ένα εξελικτικό μοντέλο συμπερασμάτων για την εκτίμηση του κόστους κατασκευής, βασισμένο στον αλγόριθμο των μηχανών διανυσμάτων υποστήριξης και στον γενετικό αλγόριθμο *fast messy genetic algorithm*. Αντίστοιχα, στην έρευνα των [Kim et al. \(2013\)](#) συγκρίθηκαν διαφορετικοί αλγόριθμοι μηχανικής μάθησης για τον υπολογισμό του κόστους κατασκευής και αποδείχθηκε πως ο ακριβέστερος αλγόριθμος βασίζεται στα νευρωνικά δίκτυα.

Η **μοντελοποίηση δομικών πληροφοριών** αποτελεί τον πλέον σύγχρονο τρόπο για τον τεχνικό σχεδιασμό και διαχείριση μιας κατασκευής. Το BIM αποτελεί μια σύγχρονη τεχνολογία που έχει ως στόχο να υποστηρίξει την ψηφιοποίηση στον κατασκευαστικό κλάδο μέσω ενός προτύπου αποθήκευσης και διαμοιρασμού πληροφοριών που σχετίζονται με το κτίριο. Και σε αυτό τον τομέα η TN διαδραματίζει ένα κομβικό ρόλο μέσω των πεδίων της επεξεργασίας εικόνας και της αναγνώρισης προτύπων ([Huang et al., 2021](#)). Μια από τις μεγαλύτερες προκλήσεις στον τομέα είναι πως το BIM δεν μπορεί να αποτυπώσει με ακρίβεια από ένα ψηφιακό σχέδιο CAD όλες τις λεπτομέρειες μιας εγκατάστασης όπως αυτή έχει κατασκευαστεί στην πραγματικότητα. Για την επίλυση αυτού του προβλήματος η TN μπορεί να προσφέρει μοντέλα αυτόματης μετατροπής 3D δεδομένων cloud σε BIM. Σημαντικά ευρήματα έχει προσφέρει η μελέτη των [Tang et al. \(2010\)](#) που συνέκρινε τεχνικές αυτοματοποίησης της διαδικασίας δημιουργίας BIM από ακατέργαστα δεδομένα. Σύμφωνα με αυτή την έρευνα

υπάρχουν τρεις βασικές λειτουργίες, η γεωμετρική μοντελοποίηση του κτιρίου, η αναγνώριση αντικειμένων και η μοντελοποίηση σχέσεων αντικειμένων. Παρόμοιες έρευνες που συνδυάζουν το BIM με την TN έχουν αναπτυχθεί επίσης από τους [Braun and Borrmann \(2019\)](#) και [Koo et al. \(2021\)](#).

Η τρίτη κατηγορία προβλημάτων επικεντρώνεται στη **διαχείριση της κατασκευής**, μια διαδικασία απαραίτητη για την επιτυχή και έγκαιρη διεκπεραίωση ενός κατασκευαστικού έργου. Ο ρόλος της TN σε αυτό τον τομέα εστιάζει στις τεχνικές όρασης υπολογιστών για την επεξεργασία, αποθήκευση, ερμηνεία και ανάλυση εικόνων που λαμβάνονται από εργοτάξια, οι οποίες πλέον σταδιακά αντικαθιστούν τις παραδοσιακές γραπτές αναφορές. Οι πληροφορίες που ανιχνεύονται σε τέτοιες εικόνες αξιοποιούνται για την αποτελεσματικότερη ταξινόμηση, ανάκτηση και διαχείριση εικόνων από εργοτάξια με στόχο την αυτοματοποίηση της παρακολούθησης της διαδικασίας κατασκευής. Αυτή η κατηγορία προβλημάτων ίσως είναι σπανιότερη από τις υπόλοιπες, ωστόσο αρκετές έρευνες έχουν χρησιμοποιήσει τεχνικές όρασης υπολογιστών για τον εντοπισμό δομικών αντικειμένων όπως δοκοί στήλες και τοίχοι ([Brilakis and Soibelman, 2008](#)) ή δομικών υλικών ([Brilakis et al., 2005](#)). Μια πιο πρόσφατη έρευνα τμηματοποιεί τη διαδικασία ανάλυσης της εικόνας σε δύο στάδια, τη διαίρεση των εικόνων σε μικρότερα υπο-πλαίσια και την ταξινόμηση των επιμέρους οπτικών χαρακτηριστικών κάθε πλαισίου για τον εντοπισμό της ύπαρξης κάποιου δομικού υλικού ([Zhu and Brilakis, 2010b](#)).

Τέλος, η μηχανική μάθηση βρίσκει πλήθος εφαρμογών στον **εντοπισμό ελαττωμάτων** και πάλι με τη χρήση αλγορίθμων όρασης υπολογιστών. Παράδειγμα εντοπισμού κατασκευαστικών ελαττωμάτων αποτελεί η μελέτη των [Akinici et al. \(2006\)](#), οι οποίοι πρότειναν μια μέθοδο ποιοτικού ελέγχου κατασκευής μέσω της αυτόματης ανίχνευσης κατασκευαστικών ελαττωμάτων. Η βασική ιδέα αυτής της προσέγγισης βασίζεται στην εφαρμογή ενός αλγορίθμου βαθιάς μάθησης για την ανάλυση εικόνων από σαρωτή λέιζερ και στη σύγκριση των αντικειμένων που ταυτοποιήθηκαν με πρότυπα αντικείμενα για να εντοπίσει τις αποκλίσεις και να αξιολογήσει εάν αυτές οι αποκλίσεις οφείλονται σε κατασκευαστικό ελάττωμα. Μια ακόμη έρευνα από τους [Zhu and Brilakis \(2010a\)](#) εστιάζει στην εφαρμογή τεχνικών όρασης υπολογιστών για να επιθεωρήσουν αυτόματα ελαττώματα, όπως θύλακες αέρα και αποχρωματισμό, στην επιφάνεια του σκυροδέματος.

3.5.3 Λειτουργία Κτιρίου

Έχοντας ολοκληρώσει τα στάδια του σχεδιασμού και της κατασκευής ο κύκλος ζωής του κτιρίου συνεχίζεται με τη λειτουργία του. Τα κτίρια πρέπει να λειτουργούν αποδοτικά και να συντηρούνται όταν είναι απαραίτητο προκειμένου να διατηρούν την υψηλή τους απόδοση. Οι καθημερινές λειτουργίες και η συντήρηση (γνωστές με τον όρο operation and maintenance ή O&M) επηρεάζουν την ενεργειακή αποδοτικότητα του κτιρίου, το επίπεδο άνεσης των χρηστών του και το κόστος χρήσης του. Βέβαια τα σύγχρονα κτίρια απαρτίζονται από σύγχρονες υποδομές και τεχνολογίες, έξυπνα μετρητικά συστήματα και προηγμένα πρωτόκολλα επικοινωνίας ανοίγοντας το δρόμο για την ανάπτυξη ευφυών συστημάτων ([Zheng et al., 2013](#)).

Στο στάδιο λειτουργίας των κτιρίων οι τεχνολογική πρόοδος υπόσχεται σημαντικές προόδους στην κεντρική λειτουργία και διαχείριση του κτιρίου, στη συντήρηση του κτιρίου μέσω της ανίχνευσης βλαβών και τη βελτιστοποίηση της άνεσης των χρηστών του κτιρίου μέσω του έξυπνου ελέγχου συγκεκριμένων συστημάτων του. Παράλληλα, οι έξυπνοι μετρητές (*Internet of Things - IoT*) αποτελούν πλέον ένα κρίσιμο εργαλείο των σύγχρονων κτιρίων, επιτρέποντας τη δυνατότητα συλλογής ιστορικών δεδομένων σε πραγματικό χρόνο, είτε για ολόκληρο το κτίριο είτε για κάποιο υποσύστημα του. Σαν αποτέλεσμα, μεγάλος όγκος κτιριακών δεδομένων συλλέγονται και αποθηκεύονται, παρέχοντας πλούσιες πληροφορίες για τη διερεύνηση και αξιολόγηση της πραγματικής ενεργειακής αποδοτικότητας του κτιρίου ([Yu et al., 2016](#)). Οι πρόσφατες έρευνες στο στάδιο της λειτουργίας και ελέγχου του κτιρίου επικεντρώνονται στην εφαρμογή τεχνικών μηχανικής μάθησης για την υποστήριξη της λήψης αποφάσεων

σε καθημερινό επίπεδο, αλλά και στο βέλτιστο έλεγχο των συστημάτων του κτιρίου. Στις επόμενες παραγράφους αναλύουμε τις μεθόδους αυτές κατηγοριοποιώντας τις εφαρμογές TN στα εξής προβλήματα: βελτίωση ενεργειακής αποδοτικότητας κτιρίου, θερμική άνεση χρηστών κτιρίου, διάγνωση ανωμαλιών για τη συντήρηση του κτιρίου και ευφυής έλεγχος συσκευών κτιρίου.

Αρχικά όσον αφορά στην **ενεργειακή αποδοτικότητα** των κτιρίων, σημαντική πρόοδος έχει σημειωθεί με τη χρήση της TN με το σχεδιασμό εργαλείων που υποστηρίζουν τη βελτίωση της ενεργειακής αποδοτικότητας κτιρίων σε όλο τον κόσμο. Οι μελέτες TN στον κατασκευαστικό τομέα επικεντρώνονται στον προσδιορισμό της ακριβούς κατανάλωσης ενέργειας των κτιρίων και στην παροχή βελτιστοποιήσεων στα ποσοστά χρήσης ενέργειας. Ενδεικτικά, η έρευνα των [Yildiz and Arsan \(2011\)](#) μελετάει τους πιο σημαντικούς παράγοντες που επηρεάζουν τα ενεργειακά φορτία θέρμανσης και ψύξης σε κτίρια, σε ζεστά και υγρά κλίματα, εξετάζοντας πειραματικά το σχεδιασμό ενός υπάρχοντος διαμερίσματος. Επίσης, η έρευνα των [Khayatian et al. \(2016\)](#) χρησιμοποιεί τεχνητά νευρωνικά δίκτυα με στόχο την πρόβλεψη της ζήτησης θερμικής ενέργειας των κτιρίων λαμβάνοντας υπόψιν ιστορικά δεδομένα κατανάλωσης ενέργειας των υπάρχοντων κτιρίων. Σε μια άλλη εφαρμογή, οι [Fan et al. \(2018\)](#) πρότειναν μια μέθοδο αναγνώρισης προτύπων για τον εντοπισμό χρήσιμων μοτίβων από την δεδομένα κατά τη λειτουργία του κτιρίου. Η μέθοδος αυτή εφαρμόστηκε για την αναγνώριση συσχέτισης του ανοίγματος των βαλβίδων κρύου και ζεστού νερού μιας μονάδας χειρισμού αέρα (*air handling unit*), του ανοίγματος της βαλβίδας ζεστού νερού και της διαφοράς θερμοκρασίας παροχής και επιστροφής ζεστού νερού στοχεύοντας στη βελτίωση της ενεργειακής απόδοσης του κτιρίου.

Στον τομέα της **θερμικής άνεσης των χρηστών** (εργαζομένων ή κατοίκων) του κτιρίου, έχουν χρησιμοποιηθεί αρκετοί αλγόριθμοι TN για την ανάπτυξη προγνωστικών μοντέλων, με χαρακτηριστικότερους τα νευρωνικά δίκτυα και μοντέλα δενδρικής δομής ([Ngarambe et al., 2020](#)). Οι μεθοδολογίες που έχουν αναπτυχθεί έχουν ως στόχο την άμεση εκτίμηση των επιπέδων θερμικής άνεσης ή τη βελτίωση των ήδη υπάρχοντων δεικτών θερμικής άνεσης, όπως ο *Predicted Mean Vote (PMV)* ([Ferreira et al., 2012](#)). Για παράδειγμα, όσον αφορά τις απλές μεταβλητές όπως η εσωτερική θερμοκρασία και η υγρασία πολλές μελέτες επικεντρώνονται στην πρόβλεψη της θερμοκρασίας του εσωτερικού αέρα χρησιμοποιώντας διάφορους παράγοντες, όπως φυσικά καιρικά στοιχεία, και συγκρίνοντας διαφορετικές τεχνικές βαθιάς μάθησης ([Moon et al., 2013](#); [Moon and Jung, 2016](#)). Ωστόσο, εκτός από τη θερμοκρασία και την υγρασία υπάρχουν πιο σύνθετοι δείκτες όπως ο δείκτης PMV. Επομένως, έχουν αναπτυχθεί πολλές έρευνες που αναπτύσσουν μοντέλα πρόβλεψης για την εκτίμηση του δείκτη PMV και προσπαθούν να αντιμετωπίσουν το πρόβλημα των περιορισμένων μεταβλητών, χρησιμοποιώντας προηγμένες τεχνικές μηχανικής μάθησης για να ερμηνεύσουν τη θερμική αίσθηση ως συνάρτηση τεσσάρων φυσικών παραγόντων (θερμοκρασία αέρα, σχετική υγρασία, ταχύτητα αέρα και μέση θερμοκρασία ακτινοβολίας) και δύο προσωπικών παραγόντων (ένδυση και δραστηριότητα) ([Castilla et al., 2013](#); [von Grabe, 2016](#); [Lu et al., 2019b](#)).

Ένα ακόμη πεδίο που η TN έχει χρησιμοποιηθεί ευρέως είναι η **συντήρηση κτιρίων** στο στάδιο της λειτουργίας τους. Διάφορες μέθοδοι έχουν αναπτυχθεί είτε για τη δημιουργία προφίλ ηλεκτρικών συσκευών του κτιρίου, είτε για τον εντοπισμό ανωμαλιών. Η κατανομή ενέργειας (*energy disaggregation*) υπολογίζει την κατανάλωση ηλεκτρικής ενέργειας συσκευή προς συσκευή από έναν μόνο μετρητή που μετρά τη ζήτηση ηλεκτρικής ενέργειας ολόκληρου του σπιτιού. Πρόσφατα, τα βαθιά νευρωνικά δίκτυα έχουν οδηγήσει σε αξιοσημείωτες βελτιώσεις στην απόδοση ταξινόμησης των προφίλ πολλών ηλεκτρικών συσκευών, με χαρακτηριστικό παράδειγμα την έρευνα των [Kelly and Knottenbelt \(2015\)](#) που χρησιμοποίησε δίκτυα LSTM και autoencoders. Επίσης, έχουν αναπτυχθεί προγνωστικά μοντέλα για τη λειτουργία των κτιρίων, τα οποία ελαχιστοποιούν τους χειροκίνητους ελέγχους και κατά συνέπεια τα γενικά έξοδα συντήρησης. Ενδεικτικά, μοντέλα μηχανικής μάθησης έχουν εφαρμοστεί για τον εντοπισμό και τη διάγνωση σφαλμάτων ψυκτικών συστημάτων ([Yan et al., 2018](#)), για την αυτοπροσαρμοζόμενη ανίχνευση και διάγνωση σφαλμάτων σε τοπικά συστήματα μονάδων

παροχής αέρα (Fan et al., 2010) και για την ανίχνευση ελαττωματικών μονάδων HVAC σε διαφορετικά επίπεδα (Wu and Sun, 2011), μεταξύ άλλων.

Τέλος, έχει σημειωθεί σημαντική πρόοδος όσον αφορά τον **ευφυή έλεγχο** των κτιρίων με μεθόδους νοημοσύνη του περιβάλλοντος (*ambient intelligence*) σε συνδυασμό με αλγορίθμους ενισχυτικής μάθησης. Συμβατικά ο έλεγχος κτιρίων πραγματοποιείται με κανόνες ανάδρασης που στηρίζονται σε προκαθορισμένα χρονοδιαγράμματα για την επιλογή των βέλτιστων σημείων (όπως θερμοκρασίες αέρα και νερού παροχής και θερμοκρασία θερμοστάτη) και στη συνέχεια εφαρμόζονται κλασικές τεχνικές ελέγχου για την παρακολούθηση αυτών των σημείων ρύθμισης. Ωστόσο, με την πρόοδο της μηχανικής μάθησης πλέον οι διαδικασίες ελέγχου στα κτίρια μπορούν να αυτοματοποιηθούν σε μεγάλο βαθμό. Η αυτοματοποίηση μπορεί να αφορά διάφορα υποσυστήματα του κτιρίου, όπως το σύστημα HVAC, τη λειτουργία των παραθύρων, το σύστημα φωτισμού, τον έλεγχο του ζεστού νερού και τον προγραμματισμό οικιακών συσκευών (Luo et al., 2017). Για παράδειγμα, στην έρευνα των Zakula et al. (2014) αναπτύχθηκε ένα μοντέλο προγνωστικού ελέγχου για δυναμική βελτιστοποίηση του συστήματος HVAC και εφαρμόστηκε σε δύο κτίρια με πολύ ενθαρρυντικά αποτελέσματα. Αντίστοιχα, οι Ruelens et al. (2015) πρότειναν έναν αλγόριθμο μάθησης για τον έλεγχο του θερμοστάτη με στρατηγική υποχώρησης, η οποία χαμηλώνει τη θερμοκρασία σε κατάλληλες στιγμές (π.χ. όταν οι κάτοικοι δεν είναι στο σπίτι). Μια ακόμη εφαρμογή προτάθηκε από τους Park et al. (2019), οι οποίοι πρότειναν το LightLearn, μια βιβλιοθήκη που εστιάζει στο βέλτιστο έλεγχο του φωτισμού κτιρίων. Αυτό το πακέτο ελέγχου μαθαίνει τις εξατομικευμένες συμπεριφορές των επιβατών και τις συνθήκες εσωτερικού περιβάλλοντος και προσαρμόζει τις παραμέτρους ελέγχου φωτισμού ανάλογα. Πολύ καλά αποτελέσματα είχε, επίσης, ο αλγόριθμος ταξινόμησης που προτάθηκε από τους Marasco and Kontokosta (2016) για την πρόβλεψη της καταλληλότητας μέτρων εξοικονόμησης ενέργειας δεδομένου ενός συγκεκριμένου συνόλου χαρακτηριστικών κτιρίου.

3.5.4 Ανακαίνιση Κτιρίου

Η ανακαίνιση κτιρίων αποτελεί κρίσιμο παράγοντα για τη μείωση της κατανάλωσης ενέργειας και των εκπομπών αερίων του θερμοκηπίου στον κτιριακό τομέα. Παρ' όλα αυτά, η διαδικασία ανακαίνισης κτιρίων είναι μια περίπλοκη διαδικασία καθώς συμπεριλαμβάνει μια σειρά από δράσεις που πρέπει να πραγματοποιηθούν πριν, κατά τη διάρκεια και μετά από τη διαδικασία της ανακαίνισης. Οι σημαντικότερες από αυτές τις δράσεις είναι η παρακολούθηση της τρέχουσας αποδοτικότητας του κτιρίου πριν την ανακαίνιση, ο εντοπισμός των καταλληλότερων μέτρων εξοικονόμησης ενέργειας (*Energy Conservation Measures - ECMs*) και η αξιολόγηση της εξοικονόμησης ενέργειας μετά την πραγματοποίηση των δράσεων ανακαίνισης. Γενικά, οι μέθοδοι μηχανικής μάθησης έχουν χρησιμοποιηθεί σε αυτές τις κατηγορίες για να διευκολύνουν όλη τη διαδικασία της ανακαίνισης. Η εκτίμηση μιας δράσης ανακαίνισης έχει δύο στάδια: (α) Την *a priori* αξιολόγηση της δράσης η οποία πραγματοποιείται πριν την ανακαίνιση και (β) την *ex ante* ανάλυση η οποία απαιτεί να έχει ολοκληρωθεί η δράση ανακαίνισης. Στην πρώτη κατηγορία κύριο ρόλο παίζει η τεχνοοικονομική αξιολόγηση της επένδυσης, λαμβάνοντας υπόψη τη σχέση μεταξύ του κόστους των δράσεων και της εκτιμώμενης ενεργειακής εξοικονόμησης. Στη δεύτερη κατηγορία οι ερευνητικές προσπάθειες επικεντρώνονται στην αξιολόγηση της εξοικονόμησης ενέργειας που επέφερε η δράση, προσπαθώντας να συγκρίνει την κατανάλωση πριν και μετά τη δράση κανονικοποιώντας τις καιρικές συνθήκες.

Η συνήθης διαδικασία για το **σχεδιασμό μετασκευής** κτιρίων απαιτεί λεπτομερείς ενεργειακούς ελέγχους (*energy audits*). Όμως αυτοί οι έλεγχοι είναι πολλές φορές χρονοβόροι και αρκετά ακριβοί. Βέβαια καθώς ο όγκος των δεδομένων από τέτοιους ενεργειακούς ελέγχους σε κτίρια αυξάνεται και οι πληροφορίες που συλλέγονται εμπλουτίζονται, η TN προσφέρει χρήσιμες μεθόδους για την ανάλυση και διερεύνηση των υποκείμενων μοτίβων των δεδομένων για την υποστήριξη του σχεδιασμού ανακαίνισης στον κτιριακό τομέα. Ένα παράδειγμα εφαρμογής τέτοιων μεθόδων είναι η έρευνα των Cecconi et al. (2019) για την αξιολόγηση των δυνατοτήτων εξοικονόμησης ενέργειας των δημόσιων σχολικών κτιρίων. Η

έρευνα βασίστηκε στην ανοιχτή βάση δεδομένων της Ιταλίας που διαθέτει ενεργειακά πιστοποιητικά κτιρίων (*building energy certification*). Τα σχολεία ομαδοποιήθηκαν ανάλογα με την ηλικία τους και τα χαρακτηριστικά τους και έπειτα για κάθε ομάδα κτιρίων σχεδιάστηκαν κατάλληλες στρατηγικές και πλάνα ανακαίνισης. Παρόμοια προσέγγιση ακολουθείται στην έρευνα των [Gao and Malkawi \(2014\)](#) οι οποίοι ταξινομούν τα κτίρια με βάση τα δομικά χαρακτηριστικά τους, ώστε να προτείνουν σε δεύτερο στάδιο τις κατάλληλες δράσεις ανακαίνισης. Ελαφρώς διαφοροποιημένη είναι η προσέγγιση των [Marasco and Kontokosta \(2016\)](#) οι οποίοι εκπαιδεύουν έναν μοντέλο ταξινόμησης για τον εντοπισμό ευκαιριών ανακαίνισης. Πιο συγκεκριμένα, το μοντέλο εκπαιδεύεται σε δεδομένα ενεργειακών ελέγχων για περισσότερα από 1100 κτίρια στη Νέα Υόρκη και χρησιμοποιείται για να προβλέψει ευκαιρίες ανακαίνισης σε διάφορες κατηγορίες, όπως συστήματα ψύξης, συστήματα διανομής ζεστού νερού και συστήματα φωτισμού.

Η διαδικασία της μέτρησης και επαλήθευσης (*Measurement & Verification - M&V*) είναι μία από τις πιο σημαντικές διαδικασίες που χρησιμοποιούνται για την **αξιολόγηση της αποτελεσματικότητας των μέτρων εξοικονόμησης ενέργειας**. Πιο συγκεκριμένα, ο όρος M&V χρησιμοποιείται για να περιγράψει αυτοματοποιημένες προσεγγίσεις και μεθοδολογίες που βασίζονται σε μεγάλα σύνολα δεδομένων και σε στατιστικά υπολογιστικά μοντέλα για την εκτίμηση της εξοικονόμησης ενέργειας. Είναι προφανές πως με την πρόοδο στον τομέα της μηχανικής μάθησης, τα απλά στατιστικά μοντέλα σταδιακά αντικαθίστανται από πιο περίπλοκα προβλεπτικά μοντέλα μηχανικής μάθησης που προσφέρουν αυξημένη ακρίβεια ([Granderson et al., 2017](#)). Μια αναλυτική μεθοδολογία για το πρόβλημα αυτό αναπτύχθηκε στην έρευνα των [Gallagher et al. \(2018b\)](#), οι οποίοι χρησιμοποιούν διαφορετικά μοντέλα TN, όπως τεχνητά νευρωνικά δίκτυα, μηχανές υποστήριξης διανυσμάτων, τον αλγόριθμο k-πλησιέστερων γειτόνων και παλινδρόμηση πολλών μεταβλητών για την μοντελοποίηση της κατανάλωσης ενέργειας της περιόδου πριν την ανακαίνιση. Μια ακόμη σημαντική εφαρμογή παρουσιάστηκε από τους [Gallagher et al. \(2018a\)](#) όπου αποδείχθηκε πως οι προσεγγίσεις που βασίζονται σε μοντέλα μηχανικής μάθησης είναι πιο επωφελείς σε περιπτώσεις όπου η έλλειψη δεδομένων περιορίζει τη διάρκεια της περιόδου εκπαίδευσης του μοντέλου.

3.6 Συμπεράσματα

Η ανάλυση που προηγήθηκε στο κεφάλαιο αυτό ανέδειξε τη δυνατότητα της TN να περιγράφει περίπλοκα συστήματα και να προσφέρει λύσεις σε μεγάλο πλήθος ενεργειακών προβλημάτων, περιλαμβάνοντας προβλήματα διαχείρισης ΑΠΕ, θέματα κατανομημένων ενεργειακών πόρων και δικτύου, καθώς και ζητήματα ενεργειακής αποδοτικότητας κτιρίων. Ωστόσο, η υιοθέτηση μιας νέας τεχνολογίας επιφέρει επίσης πολλές προκλήσεις, όπως η έλλειψη αξιόπιστων συνόλων δεδομένων που συχνά οδηγούν σε ανακριβείς προβλέψεις των μοντέλων. Συνεπώς, η ποιότητα και η ποσότητα των δεδομένων είναι βασικά χαρακτηριστικά που πρέπει να ικανοποιούνται στα χρησιμοποιούμενα σύνολα δεδομένων, προκειμένου να εξασφαλιστεί η δυνατότητα γενίκευσης των διαφόρων μοντέλων μηχανικής και βαθιάς μάθησης.

Μια ακόμη κοινή ανησυχία που σχετίζεται με τα δεδομένα είναι η έλλειψη τυποποίησης των δεδομένων, γεγονός που θα επέτρεπε τη γενίκευση των εφαρμογών. Αυτή η κρίσιμη πτυχή έχει επισημανθεί ως σημαντικό εμπόδιο για την εφαρμογή της TN στον τομέα της ενέργειας. Μια ασφαλής, ταξινομημένη και τυποποιημένη παραγωγή δεδομένων στους τομείς της ενέργειας μπορεί να προσφέρει οφέλη που περιλαμβάνουν την ανταλλαγή πληροφοριών μεταξύ εταιρειών, κυβερνητικών υπηρεσιών και ακαδημαϊκών ιδρυμάτων, την πρόσβαση σε δεδομένα υψηλής ποιότητας για την έρευνα και την ανάπτυξη νέων εξειδικευμένων εργαλείων TN. Για την επίτευξη αυτού του γενικού στόχου, θα χρειαστεί η ανάπτυξη πολιτικών προστασίας που θα διασφαλίζουν την ασφάλη και δίκαιη διαχείριση των πληροφοριών.

Βιβλιογραφία

- Abdalla, A. N., Nazir, M. S., Tao, H., Cao, S., Ji, R., Jiang, M., and Yao, L. (2021). Integration of energy storage system and renewable energy sources based on artificial intelligence: An overview. *Journal of Energy Storage*, 40:102811.
- Abdel-Basset, M., Hawash, H., Chakraborty, R. K., and Ryan, M. (2021). Pv-net: An innovative deep learning approach for efficient forecasting of short-term photovoltaic energy production. *Journal of Cleaner Production*, 303:127037.
- Afzalan, M. and Jazizadeh, F. (2019). Residential loads flexibility potential for demand response using energy consumption patterns and user segments. *Applied Energy*, 254:113693.
- Agga, A., Abbou, A., Labbadi, M., El Houm, Y., and Ali, I. H. O. (2022). Cnn-lstm: An efficient hybrid deep learning architecture for predicting short-term photovoltaic power production. *Electric Power Systems Research*, 208:107908.
- Ahmed, R., Sreeram, V., Mishra, Y., and Arif, M. (2020). A review and evaluation of the state-of-the-art in pv solar power forecasting: Techniques and optimization. *Renewable and Sustainable Energy Reviews*, 124:109792.
- Akinci, B., Boukamp, F., Gordon, C., Huber, D., Lyons, C., and Park, K. (2006). A formalism for utilization of sensor systems and integrated project models for active construction quality control. *Automation in construction*, 15(2):124–138.
- Al-Dahidi, S., Ayadi, O., Alrbai, M., and Adeeb, J. (2019). Ensemble approach of optimized artificial neural networks for solar photovoltaic power prediction. *IEEE Access*, 7:81741–81758.
- Al-Salim, A. M., Lawey, A. Q., El-Gorashi, T. E., and Elmirghani, J. M. (2017). Energy efficient big data networks: Impact of volume and variety. *IEEE Transactions on Network and Service Management*, 15(1):458–474.
- Alam, M. K., Khan, F., Johnson, J., and Flicker, J. (2015). A comprehensive review of catastrophic faults in pv arrays: types, detection, and mitigation techniques. *IEEE Journal of Photovoltaics*, 5(3):982–997.
- Alhussein, M., Aurangzeb, K., and Haider, S. I. (2020). Hybrid cnn-lstm model for short-term individual household load forecasting. *Ieee Access*, 8:180544–180557.
- Ali, M. U., Khan, H. F., Masud, M., Kallu, K. D., and Zafar, A. (2020). A machine learning framework to identify the hotspot in photovoltaic module using infrared thermography. *Solar Energy*, 208:643–651.
- AlKandari, M. and Ahmad, I. (2020). Solar power generation forecasting using ensemble approach based on deep learning and statistical methods. *Applied Computing and Informatics*.
- Almonacid, F., Rus, C., Hontoria, L., and Munoz, F. (2010). Characterisation of pv cis module by artificial neural networks. a comparative study with other methods. *Renewable Energy*, 35(5):973–980.
- Amarasinghe, K., Marino, D. L., and Manic, M. (2017). Deep neural networks for energy load forecasting. In *2017 IEEE 26th international symposium on industrial electronics (ISIE)*, pages 1483–1488. IEEE.

- Amin, M. (2008). Challenges in reliability, security, efficiency, and resilience of energy infrastructure: Toward smart self-healing electric power grid. In *2008 IEEE Power and energy society general meeting-conversion and delivery of electrical energy in the 21st century*, pages 1–5. IEEE.
- Amin, S. M. and Wollenberg, B. F. (2005). Toward a smart grid: power delivery for the 21st century. *IEEE power and energy magazine*, 3(5):34–41.
- Amral, N., Ozveren, C., and King, D. (2007). Short term load forecasting using multiple linear regression. In *2007 42nd International universities power engineering conference*, pages 1192–1198. IEEE.
- Baruque, B., Porras, S., Jove, E., and Calvo-Rolle, J. L. (2019). Geothermal heat exchanger energy prediction based on time series and monitoring sensors optimization. *Energy*, 171:49–60.
- Bazilian, M., Onyeji, I., Liebreich, M., MacGill, I., Chase, J., Shah, J., Gielen, D., Arent, D., Landfear, D., and Zhengrong, S. (2013). Re-considering the economics of photovoltaic power. *Renewable Energy*, 53:329–338.
- Behera, M. K., Majumder, I., and Nayak, N. (2018). Solar photovoltaic power forecasting using optimized modified extreme learning machine technique. *Engineering Science and Technology, an International Journal*, 21(3):428–438.
- Berghout, T., Benbouzid, M., Bentrucia, T., Ma, X., Djurović, S., and Mouss, L.-H. (2021). Machine learning-based condition monitoring for pv systems: State of the art and future prospects. *Energies*, 14(19):6316.
- Bradley, P., Leach, M., and Torriti, J. (2013). A review of the costs and benefits of demand response for electricity in the uk. *Energy Policy*, 52:312–327.
- Braun, A. and Borrmann, A. (2019). Combining inverse photogrammetry and bim for automated labeling of construction site images for machine learning. *Automation in Construction*, 106:102879.
- Brilakis, I., Soibelman, L., and Shinagawa, Y. (2005). Material-based construction site image retrieval. *Journal of computing in civil engineering*, 19(4):341–355.
- Brilakis, I. K. and Soibelman, L. (2008). Shape-based retrieval of construction site photographs. *Journal of Computing in Civil Engineering*, 22(1):14–20.
- Brown, N. C. and Mueller, C. T. (2019). Design variable analysis and generation for performance-based parametric modeling in architecture. *International Journal of Architectural Computing*, 17(1):36–52.
- Castilla, M., Álvarez, J., Ortega, M., and Arahall, M. (2013). Neural network and polynomial approximated thermal comfort models for hvac systems. *Building and Environment*, 59:107–115.
- Cecconi, F. R., Moretti, N., and Tagliabue, L. C. (2019). Application of artificial neural network and geographic information system to evaluate retrofit potential in public school buildings. *Renewable and Sustainable Energy Reviews*, 110:266–277.
- Chaillou, S. (2022). *Artificial Intelligence and Architecture: From Research to Practice*. Birkhäuser.

- Chapaloglou, S., Nesiadis, A., Iliadis, P., Atsonios, K., Nikolopoulos, N., Grammelis, P., Yiakopoulos, C., Antoniadis, I., and Kakaras, E. (2019). Smart energy management algorithm for load smoothing and peak shaving based on load forecasting of an island's power system. *Applied energy*, 238:627–642.
- Chatzikonstantinou, I. and Sariyildiz, S. (2016). Approximation of simulation-derived visual comfort indicators in office spaces: a comparative study in machine learning. *Architectural Science Review*, 59(4):307–322.
- Chen, F., Fu, Z., and Yang, Z. (2019). Wind power generation fault diagnosis based on deep learning model in internet of things (iot) with clusters. *Cluster Computing*, 22(6):14013–14025.
- Cheng, M.-Y., Peng, H.-S., Wu, Y.-W., and Chen, T.-L. (2010). Estimate at completion for construction projects using evolutionary support vector machine inference model. *Automation in Construction*, 19(5):619–629.
- Chong, L. W., Wong, Y. W., Rajkumar, R. K., and Isa, D. (2018). An adaptive learning control strategy for standalone pv system with battery-supercapacitor hybrid energy storage system. *Journal of Power Sources*, 394:35–49.
- Commission, F. E. R. et al. (2008). Assessment of demand response and advanced metering.
- Cordeiro-Costas, M., Villanueva, D., Eguía-Oller, P., and Granada-Álvarez, E. (2022). Machine learning and deep learning models applied to photovoltaic production forecasting. *Applied Sciences*, 12(17):8769.
- Council, E. (2020). Fit for 55: The eu's plan for a green transition.
- Dairi, A., Harrou, F., Sun, Y., and Khadraoui, S. (2020). Short-term forecasting of photovoltaic solar power production using variational auto-encoder driven deep learning approach. *Applied Sciences*, 10(23):8400.
- Damousis, I. G. and Dokopoulos, P. (2001). A fuzzy expert system for the forecasting of wind speed and power generation in wind farms. In *PICA 2001. Innovative Computing for Power-Electric Energy Meets the Market. 22nd IEEE Power Engineering Society. International Conference on Power Industry Computer Applications (Cat. No. 01CH37195)*, pages 63–69. IEEE.
- Das, U. K., Tey, K. S., Seyedmahmoudian, M., Idna Idris, M. Y., Mekhilef, S., Horan, B., and Stojcevski, A. (2017). Svr-based model to forecast pv power generation under different weather conditions. *Energies*, 10(7):876.
- Das, U. K., Tey, K. S., Seyedmahmoudian, M., Mekhilef, S., Idris, M. Y. I., Van Deventer, W., Horan, B., and Stojcevski, A. (2018). Forecasting of photovoltaic power generation and model optimization: A review. *Renewable and Sustainable Energy Reviews*, 81:912–928.
- De Benedetti, M., Leonardi, F., Messina, F., Santoro, C., and Vasilakos, A. (2018). Anomaly detection and predictive maintenance for photovoltaic systems. *Neurocomputing*, 310:59–68.
- De Giorgi, M. G., Congedo, P. M., and Malvoni, M. (2014). Photovoltaic power forecasting using statistical methods: impact of weather data. *IET Science, Measurement & Technology*, 8(3):90–97.

- de Marcos, R. A., Bello, A., and Reneses, J. (2019). Electricity price forecasting in the short term hybridising fundamental and econometric modelling. *Electric Power Systems Research*, 167:240–251.
- De Rycke, K., Gengnagel, C., Baverel, O., Burry, J., Mueller, C., Nguyen, M. M., Rahm, P., and Thomsen, M. R. (2018). Humanizing digital reality. *Stone Morphologies: Erosion-Based Digital Fabrication Through Event-Driven Control*, Steve De Micoli, Katja Rinderspacher, Achim Menges, pages 113–124.
- Demolli, H., Dokuz, A. S., Ecemis, A., and Gokcek, M. (2019). Wind power forecasting based on daily wind speed data using machine learning algorithms. *Energy Conversion and Management*, 198:111823.
- Diagne, M., David, M., Lauret, P., Boland, J., and Schmutz, N. (2013). Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. *Renewable and Sustainable Energy Reviews*, 27:65–76.
- Duan, J., Yi, Z., Shi, D., Lin, C., Lu, X., and Wang, Z. (2019). Reinforcement-learning-based optimal control of hybrid energy storage systems in hybrid ac–dc microgrids. *IEEE Transactions on Industrial Informatics*, 15(9):5355–5364.
- Eftekharijad, S., Vittal, V., Heydt, G. T., Keel, B., and Loehr, J. (2012). Impact of increased penetration of photovoltaic generation on power systems. *IEEE transactions on power systems*, 28(2):893–901.
- Eskandari, A., Milimonfared, J., Aghaei, M., and Reinders, A. H. (2020). Autonomous monitoring of line-to-line faults in photovoltaic systems by feature selection and parameter optimization of support vector machine using genetic algorithms. *Applied Sciences*, 10(16):5527.
- Fadlullah, Z. M., Fouda, M. M., Kato, N., Takeuchi, A., Iwasaki, N., and Nozaki, Y. (2011). Toward intelligent machine-to-machine communications in smart grid. *IEEE Communications Magazine*, 49(4):60–65.
- Fan, B., Du, Z., Jin, X., Yang, X., and Guo, Y. (2010). A hybrid fdd strategy for local system of ahu based on artificial neural network and wavelet analysis. *Building and environment*, 45(12):2698–2708.
- Fan, C., Sun, Y., Shan, K., Xiao, F., and Wang, J. (2018). Discovering gradual patterns in building operations for improving building energy efficiency. *Applied energy*, 224:116–123.
- Fan, S. and Hyndman, R. J. (2011). Short-term load forecasting based on a semi-parametric additive model. *IEEE transactions on power systems*, 27(1):134–141.
- Favre, B. and Peuportier, B. (2014). Application of dynamic programming to study load shifting in buildings. *Energy and Buildings*, 82:57–64.
- Fazai, R., Abodayeh, K., Mansouri, M., Trabelsi, M., Nounou, H., Nounou, M., and Georghiou, G. E. (2019). Machine learning-based statistical testing hypothesis for fault detection in photovoltaic systems. *Solar Energy*, 190:405–413.
- Ferreira, P. M., Silva, S. M., Ruano, A. E., Negrier, A. T., and Conceicao, E. Z. (2012). Neural network pmv estimation for model-based predictive control of hvac systems. In *The 2012 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8. IEEE.

- Fischetti, M. and Pisinger, D. (2019). Mathematical optimization and algorithms for offshore wind farm design: An overview. *Business & Information Systems Engineering*, 61(4):469–485.
- Foley, A. M., Leahy, P. G., Marvuglia, A., and McKeogh, E. J. (2012). Current methods and advances in forecasting of wind power generation. *Renewable energy*, 37(1):1–8.
- Fuhrimann, L., Moosavi, V., Ohlbrock, P. O., and D’acunto, P. (2018). Data-driven design: Exploring new structural forms using machine learning and graphic statics. In *Proceedings of IASS Annual Symposia*, number 2 in 1, pages 1–8. International Association for Shell and Spatial Structures (IASS).
- Gallagher, C. V., Bruton, K., Leahy, K., and O’Sullivan, D. T. (2018a). The suitability of machine learning to minimise uncertainty in the measurement and verification of energy savings. *Energy and Buildings*, 158:647–655.
- Gallagher, C. V., Leahy, K., O’Donovan, P., Bruton, K., and O’Sullivan, D. T. (2018b). Development and application of a machine learning supported methodology for measurement and verification (m&v) 2.0. *Energy and Buildings*, 167:8–22.
- Gangwani, P., Soni, J., Upadhyay, H., and Joshi, S. (2020). A deep learning approach for modeling of geothermal energy prediction. *International Journal of Computer Science and Information Security (IJCSIS)*, 18(1).
- Gao, X. and Malkawi, A. (2014). A new methodology for building energy performance benchmarking: An approach based on intelligent clustering algorithm. *Energy and Buildings*, 84:607–616.
- Gellings, C. W. and Smith, W. M. (1989). Integrating demand-side management into utility planning. *Proceedings of the IEEE*, 77(6):908–918.
- Geyer, P. and Singaravel, S. (2018). Component-based machine learning for performance prediction in building design. *Applied energy*, 228:1439–1453.
- Granderson, J., Touzani, S., Fernandes, S., and Taylor, C. (2017). Application of automated measurement and verification to utility energy efficiency program data. *Energy and Buildings*, 142:191–199.
- Han, X., Ji, T., Zhao, Z., and Zhang, H. (2015). Economic evaluation of batteries planning in energy storage power stations for load shifting. *Renewable Energy*, 78:643–647.
- Hare, J., Shi, X., Gupta, S., and Bazzi, A. (2016). Fault diagnostics in smart micro-grids: A survey. *Renewable and Sustainable Energy Reviews*, 60:1114–1124.
- He, S., Gao, H., Liu, J., Zhang, X., and Chen, Z. (2022). Distribution system planning considering peak shaving of energy station. *Applied Energy*, 312:118692.
- Heck, S. and Rogers, M. (2014). Are you ready for the resource revolution. *McKinsey Quarterly*, 2:32–45.
- Helbing, G. and Ritter, M. (2018). Deep learning for fault detection in wind turbines. *Renewable and Sustainable Energy Reviews*, 98:189–198.
- Hernández, L., Baladrón, C., Aguiar, J. M., Calavia, L., Carro, B., Sánchez-Esguevillas, A., Cook, D. J., Chinarro, D., and Gómez, J. (2012). A study of the relationship between weather variables and electric power demand inside a smart grid/smart world framework. *Sensors*, 12(9):11571–11591.

- Hong, T., Wilson, J., and Xie, J. (2013). Long term probabilistic load forecasting and normalization with hourly information. *IEEE Transactions on Smart Grid*, 5(1):456–462.
- Hong, Y.-Y. and Rioflorido, C. L. P. P. (2019). A hybrid deep learning-based neural network for 24-h ahead wind power forecasting. *Applied Energy*, 250:530–539.
- Hsu, J.-Y., Wang, Y.-F., Lin, K.-C., Chen, M.-Y., and Hsu, J. H.-Y. (2020). Wind turbine fault diagnosis and predictive maintenance through statistical process control and machine learning. *Ieee Access*, 8:23427–23439.
- Hu, J. and Vasilakos, A. V. (2016). Energy big data analytics and security: challenges and opportunities. *IEEE Transactions on Smart Grid*, 7(5):2423–2436.
- Huang, M., Ninić, J., and Zhang, Q. (2021). Bim, machine learning and computer vision techniques in underground construction: Current status and future perspectives. *Tunnelling and Underground Space Technology*, 108:103677.
- Huang, W. and Zheng, H. (2018). Architectural drawings recognition and generation through machine learning.
- Huber, M., Dimkova, D., and Hamacher, T. (2014). Integration of wind and solar power in europe: Assessment of flexibility requirements. *Energy*, 69:236–246.
- Hussain, M., Al-Aqrabi, H., and Hill, R. (2022). Statistical analysis and development of an ensemble-based machine learning model for photovoltaic fault detection. *Energies*, 15(15):5492.
- IEA (2021). Renewables 2021: Analysis and forecasts to 2026.
- Jha, S. K., Bilalovic, J., Jha, A., Patel, N., and Zhang, H. (2017). Renewable energy: Present research and future scope of artificial intelligence. *Renewable and Sustainable Energy Reviews*, 77:297–317.
- Jia, L. and Tong, L. (2016). Dynamic pricing and distributed energy management for demand response. *IEEE Transactions on Smart Grid*, 7(2):1128–1136.
- Jiang, H., Wang, K., Wang, Y., Gao, M., and Zhang, Y. (2016). Energy big data: A survey. *IEEE Access*, 4:3844–3861.
- Kalyan, S. and Sun, Q. (2022). Interrogating the installation gap and potential of solar photovoltaic systems using gis and deep learning. *Energies*, 15(10):3740.
- Kasten, F. and Czeplak, G. (1980). Solar and terrestrial radiation dependent on the amount and type of cloud. *Solar energy*, 24(2):177–189.
- Kelly, J. and Knottenbelt, W. (2015). Neural nilm: Deep neural networks applied to energy disaggregation. In *Proceedings of the 2nd ACM international conference on embedded systems for energy-efficient built environments*, pages 55–64.
- Khayatian, F., Sarto, L., et al. (2016). Application of neural networks for evaluating energy performance certificates of residential buildings. *Energy and Buildings*, 125:45–54.
- Kim, G.-H., Shin, J.-M., Kim, S., and Shin, Y. (2013). Comparison of school building construction costs estimation methods using regression analysis, neural network, and support vector machine. *Journal of Building Construction and Planning Research*.
- Kim, H., Stumpf, A. L., and Schneider, R. L. (2010). *Developing energy efficient building design in machine learning*. Tribun EU.

- Koo, B., Jung, R., and Yu, Y. (2021). Automatic classification of wall and door bim element subtypes using 3d geometric deep neural networks. *Advanced Engineering Informatics*, 47:101200.
- Landberg, L. (1998). A mathematical look at a physical power prediction model. *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology*, 1(1):23–28.
- Landberg, L. (1999). Short-term prediction of the power production from wind farms. *Journal of Wind Engineering and Industrial Aerodynamics*, 80(1-2):207–220.
- Landberg, L., Myllerup, L., Rathmann, O., Petersen, E. L., Jørgensen, B. H., Badger, J., and Mortensen, N. G. (2003). Wind resource estimation—an overview. *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology*, 6(3):261–271.
- Lee, K.-H., Jun, S.-O., Pak, K.-H., Lee, D.-H., Lee, K.-W., and Park, J.-P. (2010). Numerical optimization of site selection for offshore wind turbine installation using genetic algorithm. *Current Applied Physics*, 10(2):S302–S306.
- Lei, M., Shiyang, L., Chuanwen, J., Hongling, L., and Yan, Z. (2009). A review on the forecasting of wind speed and generated power. *Renewable and sustainable energy reviews*, 13(4):915–920.
- Li, P., Zhou, K., Lu, X., and Yang, S. (2020). A hybrid deep learning model for short-term pv power forecasting. *Applied Energy*, 259:114216.
- Lin, W.-H., Wang, P., Chao, K.-M., Lin, H.-C., Yang, Z.-Y., and Lai, Y.-H. (2021). Wind power forecasting with deep learning networks: Time-series forecasting. *Applied Sciences*, 11(21):10335.
- Liu, B., Zhao, S., Yu, X., Zhang, L., and Wang, Q. (2020). A novel deep learning approach for wind power forecasting based on wd-lstm model. *Energies*, 13(18):4964.
- Liu, C., Wu, J., Kohli, P., and Furukawa, Y. (2017a). Raster-to-vector: Revisiting floor-plan transformation. In *Proceedings of the IEEE International Conference on Computer Vision*, pages 2195–2203.
- Liu, L., Silva, E. A., Wu, C., and Wang, H. (2017b). A machine learning-based method for the large-scale evaluation of the qualities of the urban environment. *Computers, environment and urban systems*, 65:113–125.
- Lorenz, C.-L., Packianather, M., Spaeth, A., and Bleil De Souza, C. (2018). Artificial neural network-based modelling for daylight evaluations. *Society for Modeling & Simulation International*.
- Lu, R., Hong, S. H., and Yu, M. (2019a). Demand response for home energy management using reinforcement learning and artificial neural network. *IEEE Transactions on Smart Grid*, 10(6):6629–6639.
- Lu, R., Hong, S. H., and Zhang, X. (2018). A dynamic pricing demand response algorithm for smart grid: reinforcement learning approach. *Applied Energy*, 220:220–230.
- Lu, S., Wang, W., Lin, C., and Hameen, E. C. (2019b). Data-driven simulation of a thermal comfort-based temperature set-point control with ashrae rp884. *Building and Environment*, 156:137–146.

- Lund, P. D., Lindgren, J., Mikkola, J., and Salpakari, J. (2015). Review of energy system flexibility measures to enable high levels of variable renewable electricity. *Renewable and sustainable energy reviews*, 45:785–807.
- Luo, N., Hong, T., Li, H., Jia, R., and Weng, W. (2017). Data analytics and optimization of an ice-based energy storage system for commercial buildings. *Applied Energy*, 204:459–475.
- Luo, X., Zhang, D., and Zhu, X. (2021). Deep learning based forecasting of photovoltaic power generation by incorporating domain knowledge. *Energy*, 225:120240.
- Marasco, D. E. and Kontokosta, C. E. (2016). Applications of machine learning methods to identifying and predicting building retrofit opportunities. *Energy and Buildings*, 128:431–441.
- Martínez-Chico, M., Batlles, F., and Bosch, J. (2011). Cloud classification in a mediterranean location using radiation data and sky images. *Energy*, 36(7):4055–4062.
- Mayer, M. J. and Gróf, G. (2021). Extensive comparison of physical models for photovoltaic power forecasting. *Applied Energy*, 283:116239.
- Mayer-Schönberger, V. and Cukier, K. (2013). *Big data: A revolution that will transform how we live, work, and think*. Houghton Mifflin Harcourt.
- Mellit, A., Pavan, A. M., and Lughì, V. (2021). Deep learning neural networks for short-term photovoltaic power forecasting. *Renewable Energy*, 172:276–288.
- Methaprayoon, K., Lee, W., Didsayabutra, P., Liao, J., and Ross, R. (2003). Neural network-based short term load forecasting for unit commitment scheduling. In *IEEE Technical Conference on Industrial and Commercial Power Systems, 2003.*, pages 138–143. IEEE.
- Mishra, M., Dash, P. B., Nayak, J., Naik, B., and Swain, S. K. (2020). Deep learning and wavelet transform integrated approach for short-term solar pv power prediction. *Measurement*, 166:108250.
- Mohammadi, K. and Goudarzi, N. (2018). Study of inter-correlations of solar radiation, wind speed and precipitation under the influence of el niño southern oscillation (enso) in california. *Renewable energy*, 120:190–200.
- Momoh, J. A. (2009). Smart grid design for efficient and flexible power networks operation and control. In *2009 IEEE/PES Power Systems Conference and Exposition*, pages 1–8. IEEE.
- Moon, J. W. and Jung, S. K. (2016). Algorithm for optimal application of the setback moment in the heating season using an artificial neural network model. *Energy and Buildings*, 127:859–869.
- Moon, J. W., Yoon, S.-H., and Kim, S. (2013). Development of an artificial neural network model based thermal control logic for double skin envelopes in winter. *Building and Environment*, 61:149–159.
- Moyano, C. F. and Lopes, J. A. P. (2009). An optimization approach for wind turbine commitment and dispatch in a wind park. *Electric power systems research*, 79(1):71–79.
- Mustafa, Z., Awad, A. S., Azzouz, M., and Azab, A. (2023). Fault identification for photovoltaic systems using a multi-output deep learning approach. *Expert Systems with Applications*, 211:118551.

- Nagy, D., Lau, D., Locke, J., Stoddart, J., Villaggi, L., Wang, R., Zhao, D., and Benjamin, D. (2017). Project discover: An application of generative design for architectural space planning. In *Proceedings of the Symposium on Simulation for Architecture and Urban Design*, pages 1–8.
- Nespoli, A., Ogliari, E., Leva, S., Massi Pavan, A., Mellit, A., Lughi, V., and Dolara, A. (2019). Day-ahead photovoltaic forecasting: A comparison of the most effective techniques. *Energies*, 12(9):1621.
- Ngarambe, J., Yun, G. Y., and Santamouris, M. (2020). The use of artificial intelligence (ai) methods in the prediction of thermal comfort in buildings: Energy implications of ai-based thermal comfort controls. *Energy and Buildings*, 211:109807.
- Nielsen, H. A., Nielsen, T. S., Madsen, H., Pindado, M. J. S. I., and Marti, I. (2007). Optimal combination of wind power forecasts. *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology*, 10(5):471–482.
- Normandeu, K. (2013). Beyond volume, variety and velocity is the issue of big data veracity. *Inside big data*.
- Nyong-Bassey, B. E., Giaouris, D., Patsios, C., Papadopoulou, S., Papadopoulos, A. I., Walker, S., Voutetakis, S., Seferlis, P., and Gadoue, S. (2020). Reinforcement learning based adaptive power pinch analysis for energy management of stand-alone hybrid energy storage systems considering uncertainty. *Energy*, 193:116622.
- Oh, E. and Wang, H. (2020). Reinforcement-learning-based energy storage system operation strategies to manage wind power forecast uncertainty. *IEEE Access*, 8:20965–20976.
- Omran, A. H., Said, D. M., Hussin, S. M., Ahmad, N., and Samet, H. (2020). A novel intelligent detection schema of series arc fault in photovoltaic (pv) system based convolutional neural network. *Periodicals of Engineering and Natural Sciences (PEN)*, 8(3):1641–1653.
- O’Neill, D., Levorato, M., Goldsmith, A., and Mitra, U. (2010). Residential demand response using reinforcement learning. In *2010 First IEEE international conference on smart grid communications*, pages 409–414. IEEE.
- Oudjana, S., Hellal, A., and Mahammed, I. H. (2013). Power forecasting of photovoltaic generation. *International Journal of Electrical and Computer Engineering*, 7(6):627–631.
- Park, J. Y., Dougherty, T., Fritz, H., and Nagy, Z. (2019). Lightlearn: An adaptive and occupant centered controller for lighting based on reinforcement learning. *Building and Environment*, 147:397–414.
- Petersen, E. L., Mortensen, N. G., Landberg, L., Højstrup, J., and Frank, H. P. (1997). Wind power meteorology. *Risø National Laboratory, Roskilde, Denmark*.
- Petrov, A. N. and Wessling, J. M. (2015). Utilization of machine-learning algorithms for wind turbine site suitability modeling in iowa, usa. *Wind Energy*, 18(4):713–727.
- Phelan, N., Davis, D., and Anderson, C. (2017). Evaluating architectural layouts with neural networks. In *Proceedings of the Symposium on Simulation for Architecture and Urban Design*, pages 1–7.
- Pillai, D. S. and Rajasekar, N. (2018). A comprehensive review on protection challenges and fault diagnosis in pv systems. *Renewable and Sustainable Energy Reviews*, 91:18–40.

- Radziszewski, K. and Waczyńska, M. (2018). Machine learning algorithm-based tool and digital framework for substituting daylight simulations in early-stage architectural design evaluation. In *Proceedings of the Symposium on Simulation for Architecture and Urban Design*, pages 1–7.
- Rahman, S. and Hazim, O. (1993). A generalized knowledge-based short-term load-forecasting technique. *IEEE Transactions on power systems*, 8(2):508–514.
- Raza, M. Q. and Khosravi, A. (2015). A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. *Renewable and Sustainable Energy Reviews*, 50:1352–1372.
- Raza, M. Q., Nadarajah, M., and Ekanayake, C. (2016). On recent advances in pv output power forecast. *Solar Energy*, 136:125–144.
- Raza, M. Q., Nadarajah, M., Hung, D. Q., and Baharudin, Z. (2017). An intelligent hybrid short-term load forecasting model for smart power grids. *Sustainable Cities and Society*, 31:264–275.
- Reddy, S. S. (2017). Optimal scheduling of thermal-wind-solar power system with storage. *Renewable energy*, 101:1357–1368.
- Reddy, S. S. and Bijwe, P. (2015). Real time economic dispatch considering renewable energy resources. *Renewable Energy*, 83:1215–1226.
- Ren, H., Xu, C., Ma, Z., and Sun, Y. (2022). A novel 3d-geographic information system and deep learning integrated approach for high-accuracy building rooftop solar energy potential characterization of high-density cities. *Applied Energy*, 306:117985.
- Ren, Y., Suganthan, P., and Srikanth, N. (2015). Ensemble methods for wind and solar power forecasting—a state-of-the-art review. *Renewable and Sustainable Energy Reviews*, 50:82–91.
- Ruelens, F., Iacovella, S., Claessens, B. J., and Belmans, R. (2015). Learning agent for a heat-pump thermostat with a set-back strategy using model-free reinforcement learning. *Energies*, 8(8):8300–8318.
- Sagiroglu, S. and Sinanc, D. (2013). Big data: A review. In *2013 international conference on collaboration technologies and systems (CTS)*, pages 42–47. IEEE.
- Sapitang, M., M. Ridwan, W., Faizal Kushiar, K., Najah Ahmed, A., and El-Shafie, A. (2020). Machine learning application in reservoir water level forecasting for sustainable hydropower generation strategy. *Sustainability*, 12(15):6121.
- Sengupta, M., Habte, A., Wilbert, S., Gueymard, C., and Remund, J. (2021). Best practices handbook for the collection and use of solar resource data for solar energy applications. Technical report, National Renewable Energy Lab.(NREL), Golden, CO (United States).
- Shahzad, U. (2021). Application of machine learning for optimal wind farm location. *Journal of Electrical Engineering, Electronics, Control and Computer Science*, 8(3):9–20.
- Shariatzadeh, F., Mandal, P., and Srivastava, A. K. (2015). Demand response for sustainable energy systems: A review, application and implementation strategy. *Renewable and Sustainable Energy Reviews*, 45:343–350.

- Shayeghi, H., Shahryari, E., Moradzadeh, M., and Siano, P. (2019). A survey on microgrid energy management considering flexible energy sources. *Energies*, 12(11):2156.
- Shimakage, T., Nishioka, K., Yamane, H., Nagura, M., and Kudo, M. (2011). Development of fault detection system in pv system. In *2011 IEEE 33rd International Telecommunications Energy Conference (INTELEC)*, pages 1–5. IEEE.
- Shirazi, E. and Jadid, S. (2017). Cost reduction and peak shaving through domestic load shifting and ders. *Energy*, 124:146–159.
- Shivashankar, S., Mekhilef, S., Mokhlis, H., and Karimi, M. (2016). Mitigating methods of power fluctuation of photovoltaic (pv) sources—a review. *Renewable and Sustainable Energy Reviews*, 59:1170–1184.
- Siano, P. (2014). Demand response and smart grids—a survey. *Renewable and sustainable energy reviews*, 30:461–478.
- Sobri, S., Koochi-Kamali, S., and Rahim, N. A. (2018). Solar photovoltaic generation forecasting methods: A review. *Energy conversion and management*, 156:459–497.
- Strbac, G. (2008). Demand side management: Benefits and challenges. *Energy policy*, 36(12):4419–4426.
- Sun, Y., Wang, F., Zhen, Z., Mi, Z., Liu, C., Wang, B., and Lu, J. (2015). Research on short-term module temperature prediction model based on bp neural network for photovoltaic power forecasting. In *2015 IEEE power & energy society general meeting*, pages 1–5. IEEE.
- Sweeney, C., Bessa, R. J., Browell, J., and Pinson, P. (2020). The future of forecasting for renewable energy. *Wiley Interdisciplinary Reviews: Energy and Environment*, 9(2):e365.
- Tamke, M., Nicholas, P., and Zwierzycki, M. (2018). Machine learning for architectural design: Practices and infrastructure. *International Journal of Architectural Computing*, 16(2):123–143.
- Tang, P., Huber, D., Akinci, B., Lipman, R., and Lytle, A. (2010). Automatic reconstruction of as-built building information models from laser-scanned point clouds: A review of related techniques. *Automation in construction*, 19(7):829–843.
- Taylor, J. W. and Buizza, R. (2003). Using weather ensemble predictions in electricity demand forecasting. *International Journal of forecasting*, 19(1):57–70.
- Tian, J., Gao, M., and Zhou, S. (2009). The research of building logistics cost forecast based on regression support vector machine. In *2009 International Conference on Computational Intelligence and Security*, volume 1, pages 648–652. IEEE.
- Torres, J. L., Garcia, A., De Blas, M., and De Francisco, A. (2005). Forecast of hourly average wind speed with arma models in navarre (spain). *Solar energy*, 79(1):65–77.
- Triki-Lahiani, A., Abdelghani, A. B.-B., and Slama-Belkhodja, I. (2018). Fault detection and monitoring systems for photovoltaic installations: A review. *Renewable and Sustainable Energy Reviews*, 82:2680–2692.
- Turner, W., Walker, I., and Roux, J. (2015). Peak load reductions: Electric load shifting with mechanical pre-cooling of residential buildings with low thermal mass. *Energy*, 82:1057–1067.

- Uddin, M., Romlie, M. F., Abdullah, M. F., Abd Halim, S., Kwang, T. C., et al. (2018). A review on peak load shaving strategies. *Renewable and Sustainable Energy Reviews*, 82:3323–3332.
- Van Gompel, J., Spina, D., and Develder, C. (2022). Satellite based fault diagnosis of photovoltaic systems using recurrent neural networks. *Applied Energy*, 305:117874.
- Vázquez-Canteli, J. R. and Nagy, Z. (2019). Reinforcement learning for demand response: A review of algorithms and modeling techniques. *Applied energy*, 235:1072–1089.
- Veerasingam, V., Wahab, N. I. A., Othman, M. L., Padmanaban, S., Sekar, K., Ramachandran, R., Hizam, H., Vinayagam, A., and Islam, M. Z. (2021). Lstm recurrent neural network classifier for high impedance fault detection in solar pv integrated power system. *IEEE Access*, 9:32672–32687.
- Vehviläinen, I. and Pyykkönen, T. (2005). Stochastic factor model for electricity spot price—the case of the nordic market. *Energy Economics*, 27(2):351–367.
- von Grabe, J. (2016). Potential of artificial neural networks to predict thermal sensation votes. *Applied energy*, 161:412–424.
- Voyant, C., Nottton, G., Kalogirou, S., Nivet, M.-L., Paoli, C., Motte, F., and Fouilloy, A. (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable Energy*, 105:569–582.
- Wang, B., Li, Y., Ming, W., and Wang, S. (2020). Deep reinforcement learning method for demand response management of interruptible load. *IEEE Transactions on Smart Grid*, 11(4):3146–3155.
- Wang, F., Zhen, Z., Mi, Z., Sun, H., Su, S., and Yang, G. (2015). Solar irradiance feature extraction and support vector machines based weather status pattern recognition model for short-term photovoltaic power forecasting. *Energy and Buildings*, 86:427–438.
- Wang, F., Zhen, Z., Wang, B., and Mi, Z. (2017a). Comparative study on knn and svm based weather classification models for day ahead short term solar pv power forecasting. *Applied Sciences*, 8(1):28.
- Wang, H.-z., Li, G.-q., Wang, G.-b., Peng, J.-c., Jiang, H., and Liu, Y.-t. (2017b). Deep learning based ensemble approach for probabilistic wind power forecasting. *Applied energy*, 188:56–70.
- Wang, K., Qi, X., and Liu, H. (2019). A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network. *Applied Energy*, 251:113315.
- Wang, X., Zhou, J., Qin, B., and Guo, L. (2023). Coordinated control of wind turbine and hybrid energy storage system based on multi-agent deep reinforcement learning for wind power smoothing. *Journal of Energy Storage*, 57:106297.
- Wang, Z., Wang, F., and Su, S. (2011). Solar irradiance short-term prediction model based on bp neural network. *Energy Procedia*, 12:488–494.
- Wen, Z., O’Neill, D., and Maei, H. (2015). Optimal demand response using device-based reinforcement learning. *IEEE Transactions on Smart Grid*, 6(5):2312–2324.
- Whaley, C. (2016). Best practices in photovoltaic system operations and maintenance. Technical report, National Renewable Energy Lab.(NREL), Golden, CO (United States).

- Wilcox, T., Jin, N., Flach, P., and Thumim, J. (2019). A big data platform for smart meter data analytics. *Computers in Industry*, 105:250–259.
- Williges, K., Van der Gaast, W., de Bruyn-Szendrei, K., Tuerk, A., and Bachner, G. (2022). The potential for successful climate policy in national energy and climate plans: highlighting key gaps and ways forward. *Sustainable Earth*, 5(1):1–17.
- Wu, S. and Sun, J. (2011). A top-down strategy with temporal and spatial partition for fault detection and diagnosis of building hvac systems. *Energy and Buildings*, 43(9):2134–2139.
- Wu, Y.-K., Lee, C.-Y., Chen, C.-R., Hsu, K.-W., and Tseng, H.-T. (2013). Optimization of the wind turbine layout and transmission system planning for a large-scale offshore windfarm by ai technology. *IEEE Transactions on Industry Applications*, 50(3):2071–2080.
- Xiong, R., Cao, J., and Yu, Q. (2018). Reinforcement learning-based real-time power management for hybrid energy storage system in the plug-in hybrid electric vehicle. *Applied energy*, 211:538–548.
- Yalcintas, M. (2006). An energy benchmarking model based on artificial neural network method with a case example for tropical climates. *International Journal of energy research*, 30(14):1158–1174.
- Yan, K., Ma, L., Dai, Y., Shen, W., Ji, Z., and Xie, D. (2018). Cost-sensitive and sequential feature selection for chiller fault detection and diagnosis. *International Journal of Refrigeration*, 86:401–409.
- Yang, D., Wu, E., and Kleissl, J. (2019). Operational solar forecasting for the real-time market. *International Journal of Forecasting*, 35(4):1499–1519.
- Yıldız, Y. and Arsan, Z. D. (2011). Identification of the building parameters that influence heating and cooling energy loads for apartment buildings in hot-humid climates. *Energy*, 36(7):4287–4296.
- Yu, Z. J., Haghghat, F., and Fung, B. C. (2016). Advances and challenges in building engineering and data mining applications for energy-efficient communities. *Sustainable Cities and Society*, 25:33–38.
- Zakula, T., Armstrong, P. R., and Norford, L. (2014). Modeling environment for model predictive control of buildings. *Energy and buildings*, 85:549–559.
- Zambrano-Asanza, S., Quiros-Tortos, J., and Franco, J. F. (2021). Optimal site selection for photovoltaic power plants using a gis-based multi-criteria decision making and spatial overlay with electric load. *Renewable and Sustainable Energy Reviews*, 143:110853.
- Zameer, A., Arshad, J., Khan, A., and Raja, M. A. Z. (2017). Intelligent and robust prediction of short term wind power using genetic programming based ensemble of neural networks. *Energy conversion and management*, 134:361–372.
- Zhang, H.-T., Xu, F.-Y., and Zhou, L. (2010). Artificial neural network for load forecasting in smart grid. In *2010 international conference on machine learning and cybernetics*, volume 6, pages 3200–3205. IEEE.
- Zhang, Y., Burton, H. V., Sun, H., and Shokrabadi, M. (2018). A machine learning framework for assessing post-earthquake structural safety. *Structural safety*, 72:1–16.

- Zhao, H., Liu, H., Hu, W., and Yan, X. (2018). Anomaly detection and fault analysis of wind turbine components based on deep learning network. *Renewable energy*, 127:825–834.
- Zhao, J., Guo, Z.-H., Su, Z.-Y., Zhao, Z.-Y., Xiao, X., and Liu, F. (2016). An improved multi-step forecasting model based on wrf ensembles and creative fuzzy systems for wind speed. *Applied Energy*, 162:808–826.
- Zhao, Y., Lehman, B., Ball, R., Mosesian, J., and de Palma, J.-F. (2013). Outlier detection rules for fault detection in solar photovoltaic arrays. In *2013 twenty-eighth annual IEEE applied power electronics conference and exposition (APEC)*, pages 2913–2920. IEEE.
- Zheng, J., Gao, D. W., and Lin, L. (2013). Smart meters in smart grid: An overview. In *2013 IEEE Green Technologies Conference (GreenTech)*, pages 57–64. IEEE.
- Zheng, J., Xu, C., Zhang, Z., and Li, X. (2017). Electric load forecasting in smart grids using long-short-term-memory based recurrent neural network. In *2017 51st Annual conference on information sciences and systems (CISS)*, pages 1–6. IEEE.
- Zhong, T., Zhang, Z., Chen, M., Zhang, K., Zhou, Z., Zhu, R., Wang, Y., Lü, G., and Yan, J. (2021). A city-scale estimation of rooftop solar photovoltaic potential based on deep learning. *Applied Energy*, 298:117132.
- Zhou, K., Fu, C., and Yang, S. (2016). Big data driven smart energy management: From big data to big insights. *Renewable and Sustainable Energy Reviews*, 56:215–225.
- Zhou, K., Yang, S., Chen, Z., and Ding, S. (2014). Optimal load distribution model of microgrid in the smart grid environment. *Renewable and Sustainable Energy Reviews*, 35:304–310.
- Zhou, S. and Liu, D. (2015). Prediction of daylighting and energy performance using artificial neural network and support vector machine. *American Journal of Civil Engineering and Architecture*, 3(3A):1–8.
- Zhu, Z. and Brilakis, I. (2010a). Machine vision-based concrete surface quality assessment. *Journal of Construction Engineering and Management*, 136(2):210–218.
- Zhu, Z. and Brilakis, I. (2010b). Parameter optimization for automated concrete detection in image data. *Automation in Construction*, 19(7):944–953.
- Zsembinszki, G., Fernández, C., Vérez, D., and Cabeza, L. F. (2021). Deep learning optimal control for a complex hybrid energy storage system. *Buildings*, 11(5):194.

Κεφάλαιο 4

Περιγραφή Επιμέρους Προβλημάτων, Στάδια Ανάπτυξης Μοντέλων & Προτεινόμενη Αρχιτεκτονική

4.1 Εισαγωγή

Όπως παρουσιάστηκε στο Κεφάλαιο 3, ο τομέας της ενέργειας αποτελεί ένα κρίσιμο τομέα της σύγχρονης κοινωνίας, καθώς σχετίζεται με την ομαλή λειτουργία ενός μεγάλου μέρους της τροφοδοτώντας με ενέργεια σπίτια, επιχειρήσεις και υποδομές. Ωστόσο, παράλληλα αντιμετωπίζει πολυάριθμες προκλήσεις, όπως η μείωση των εκπομπών διοξειδίου του άνθρακα, η αύξηση της αποδοτικότητας και η εξασφάλιση αξιόπιστου ενεργειακού εφοδιασμού (Papidis and Tsatsaronis, 2020). Ως αποτέλεσμα, αναζητούνται διαρκώς νέες λύσεις σε αυτά τα πολύπλοκα προβλήματα.

Επίσης, όπως παρουσιάστηκε στο Κεφάλαιο 2, η TN έχει αναδειχθεί ως ένας πολλά υποσχόμενος και καινοτόμος κλάδος για την αντιμετώπιση τέτοιων προκλήσεων. Οι λύσεις που βασίζονται στην TN μπορούν να συμβάλουν στη βελτιστοποίηση της παραγωγής ενέργειας, στη μείωση της κατανάλωσης ενέργειας και στη βελτίωση της αξιοπιστίας των ενεργειακών συστημάτων (Ahmad et al., 2021). Η TN μπορεί επίσης να χρησιμοποιηθεί για την πρόβλεψη της ζήτησης και της προσφοράς ενέργειας, τον εντοπισμό ανωμαλιών και βλαβών στα ενεργειακά συστήματα και τη διαχείριση των συστημάτων αποθήκευσης ενέργειας, μεταξύ πολλών άλλων προβλημάτων (Abdalla et al., 2021).

Ως απόρροια των ανωτέρω, στο πλαίσιο της παρούσας Διατριβής έχει προσδιοριστεί ένα σύνολο προβλημάτων τα οποία χρήζουν περαιτέρω διερεύνησης μέσω λύσεων TN. Αυτά τα προβλήματα αποτελούν υποσύνολο των προβλημάτων που παρουσιάστηκαν στο Κεφάλαιο 3 και ο στόχος του παρόντος Κεφαλαίου είναι να διατυπωθούν συνοπτικά, να αντιστοιχιστούν με τα ενδιαφερόμενα μέρη ανά πρόβλημα και να περιγραφούν τα αντίστοιχα δεδομένα που απαιτούνται για την επίλυση τους.

Επίσης στο Κεφάλαιο αυτό, παρουσιάζονται τα στάδια ανάπτυξης μοντέλων και αλγορίθμων μάθησης όπως αυτά ακολουθήθηκαν προκειμένου να θεραπευθούν τα προβλήματα που παρουσιάζονται σε αυτή τη Διατριβή. Το προτεινόμενο μεθοδολογικό πλαίσιο ανάπτυξης αλγορίθμων έχει σχεδιαστεί με σκοπό να υποστηρίξει διαφορετικά ενδιαφερόμενα μέρη στον ενεργειακό τομέα κατά τη διαδικασία ανάπτυξης αποτελεσματικών αλγορίθμων και μοντέλων, καλύπτοντας τα στάδια ανάπτυξης μοντέλων και αλγορίθμων μάθησης και την αρχιτεκτονική των μοντέλων TN, η οποία περιλαμβάνει όλα τα απαραίτητα επίπεδα όπως η διαχείριση των δεδομένων, των μοντέλων και των αποτελεσμάτων.

Το Κεφάλαιο είναι διαρθρωμένο ως εξής. Η ενότητα 4.2 παρέχει μια επισκόπηση των προβλημάτων που αντιμετωπίζονται με τις μεθόδους TN που έχουν αναπτυχθεί στο πλαίσιο

της Διατριβής, των κύριων ενδιαφερόμενων μερών, καθώς και των αντίστοιχων δεδομένων. Στην ενότητα 4.3 παρουσιάζονται τα στάδια για την ανάπτυξη μοντέλων TN. Στην ενότητα 4.4 περιγράφεται η αρχιτεκτονική της προτεινόμενης λύσης, η οποία περιλαμβάνει τρία διαφορετικά επίπεδα: το επίπεδο δεδομένων, το οποίο καλύπτει τη διαχείριση των δεδομένων, συμπεριλαμβανομένης της εισαγωγής, αποθήκευσης και οπτικοποίησης, το επίπεδο μοντέλων, το οποίο καλύπτει την ανάπτυξη, την παρακολούθηση και τη διαχείριση των μοντέλων MM και το επίπεδο εφαρμογών, το οποίο καλύπτει την ερμηνεία, την επεξηγηματικότητα και την επεκτασιμότητα των αποτελεσμάτων που παράγονται από τα μοντέλα καθώς και τον τρόπο παρουσίασης τους στον τελικό ενδιαφερόμενο. Τέλος, στην ενότητα 4.5 παρουσιάζονται τα συμπεράσματα του Κεφαλαίου και παρέχονται μελλοντικές κατευθύνσεις.

4.2 Προδιαγραφή Ενδιαφερομένων Μερών, Διατύπωση Επιμέρους Προβλημάτων & Καθορισμός Δεδομένων

Η TN έχει αναδειχθεί σε ένα ισχυρό εργαλείο για την αντιμετώπιση ενός ευρέος φάσματος προβλημάτων που σχετίζονται με την ενέργεια, από την πρόβλεψη της ζήτησης ηλεκτρικής ενέργειας και της παραγωγής ενέργειας από ανανεώσιμες πηγές έως τη βελτιστοποίηση της λειτουργίας των συστημάτων αποθήκευσης και διανομής ενέργειας. Ως αποτέλεσμα, ένας αυξανόμενος αριθμός ενδιαφερομένων, συμπεριλαμβανομένων των επιχειρήσεων κοινής ωφέλειας, των ρυθμιστικών αρχών, ακόμη και των νοικοκυριών, στρέφονται σε λύσεις που βασίζονται στην TN για να βελτιώσουν τη διαχείριση της ενέργειας και να μειώσουν το αποτύπωμα άνθρακα (Ahmad et al., 2022).

Επιπλέον, για την ανάπτυξη αποτελεσματικών λύσεων TN, είναι μεγάλης σημασίας ο εντοπισμός των σχετικών πηγών δεδομένων και των συγκεκριμένων προβλημάτων που πρέπει να αντιμετωπιστούν. Η διαθεσιμότητα και η ποιότητα των δεδομένων ποικίλλουν σε μεγάλο βαθμό ανάλογα με τον τομέα εφαρμογής (Nastasi et al., 2020) και μπορεί να περιλαμβάνουν χρονοσειρές κατανάλωσης και παραγωγής ενέργειας, προβλέψεις καιρού, χαρακτηριστικά κτιρίων και υποδομών, κοινωνικοοικονομικούς δείκτες και άλλους σχετικούς παράγοντες (Hu and Vasilakos, 2016).

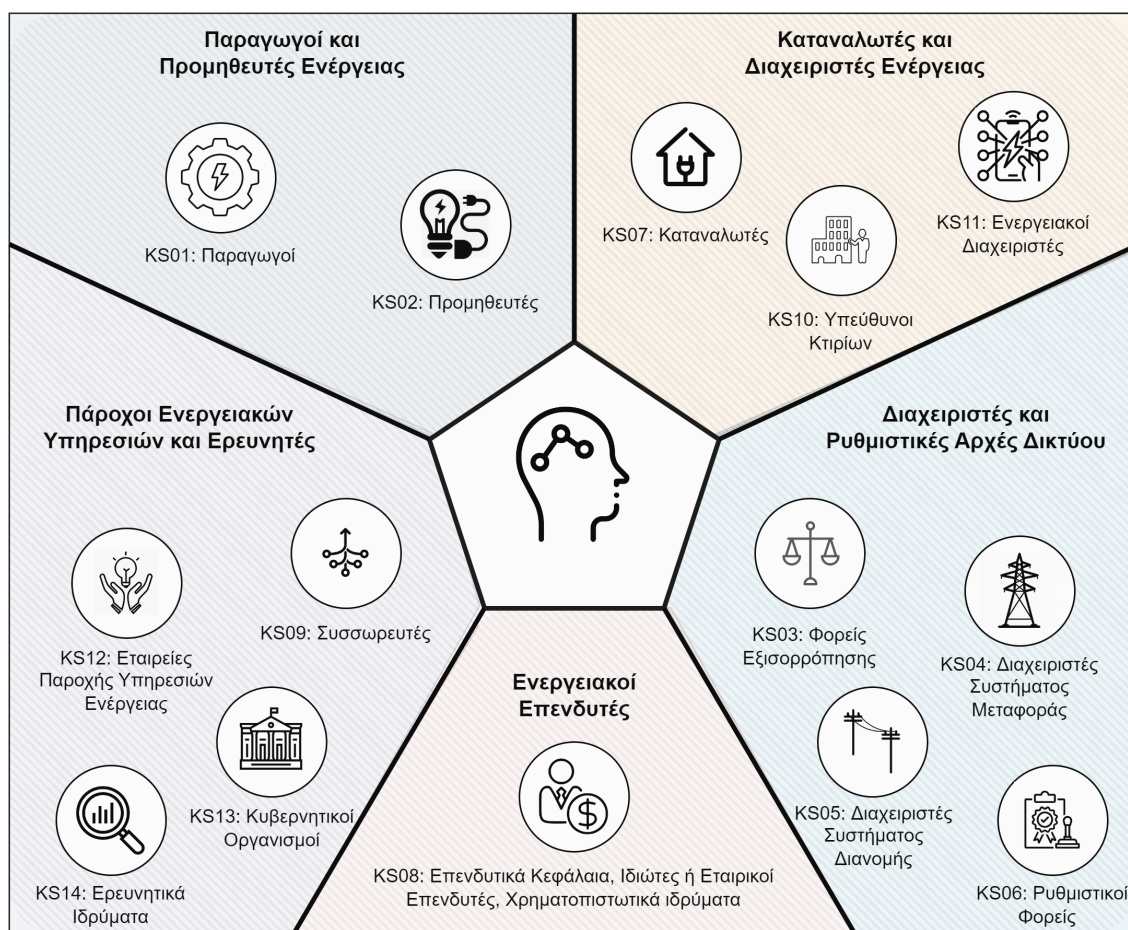
Σε αυτή την ενότητα περιγράφουμε το σύνολο προβλημάτων που σχετίζονται με τη διαχείριση ενέργειας και αντιμετωπίζονται από τα μοντέλα TN της παρούσας Διατριβής, μαζί με τους σχετικούς ενδιαφερόμενους φορείς και τις πηγές δεδομένων. Εστιάζουμε σε προβλήματα που είναι σχετικά με τον σχεδιασμό αλγορίθμων και μοντέλων TN τα οποία μπορούν να προσεγγιστούν με μια κοινή μεθοδολογία με μικρές παραλλαγές μεταξύ τους.

4.2.1 Ενδιαφερόμενα Μέρη

Σύμφωνα με το γενικό ορισμό, τα ενδιαφερόμενα μέρη (*stakeholders*) είναι άτομα ή ομάδες που έχουν συμφέροντα ή επηρεάζονται από ένα συγκεκριμένο ζήτημα ή σύστημα (Friedman and Miles, 2006). Στο πλαίσιο των ενεργειακών συστημάτων, τα ενδιαφερόμενα μέρη μπορεί να περιλαμβάνουν άτομα, επιχειρήσεις, οργανισμούς και κυβερνητικούς φορείς που εμπλέκονται στην παραγωγή, διανομή και κατανάλωση ενέργειας. Τα εν λόγω ενδιαφερόμενα μέρη έχουν συχνά διαφορετικές προοπτικές, συμφέροντα και στόχους, γεγονός που μπορεί να οδηγήσει σε συγκρούσεις και προκλήσεις κατά την ανάπτυξη και εφαρμογή ενεργειακών πολιτικών και έργων (Nasr et al., 2020).

Ο προσδιορισμός και η κατανόηση των διαφόρων ενδιαφερομένων μερών που εμπλέκονται σε ένα ενεργειακό σύστημα είναι ζωτικής σημασίας για την αποτελεσματική λήψη αποφάσεων και την επίλυση προβλημάτων. Η ανάλυση των ενδιαφερομένων μερών είναι ένα χρήσιμο εργαλείο για τον εντοπισμό και την αξιολόγηση των συμφερόντων, των αναγκών και των ανησυχιών των διαφόρων ενδιαφερομένων μερών και των πιθανών επιπτώσεών τους σε ένα ενεργειακό έργο ή πολιτική. Με τη συμμετοχή των ενδιαφερομένων μερών στη διαδικασία

λήψης αποφάσεων, μπορούν να αντιμετωπιστούν οι ανησυχίες και τα συμφέροντά τους και η συμμετοχή τους μπορεί να συμβάλει στην ανάπτυξη υποστήριξης και οικειοποίησης των ενεργειακών έργων και πολιτικών. Έτσι, στηριζόμενοι σε υπάρχουσες μελέτες και συνθέτοντας τα ευρήματά τους (Martin and Rice, 2015; Widya Yudha and Tjahjono, 2019; Franzò et al., 2019; Liu et al., 2017), θα ορίσουμε τα ενδιαφερόμενα μέρη που εμπλέκονται σε ένα σύγχρονο ενεργειακό σύστημα και θα παρουσιάσουμε τους ρόλους και τα συμφέροντά τους στην ανάπτυξη και την εφαρμογή ενεργειακών πολιτικών και έργων, με απώτερο σκοπό να τα συνδέσουμε με τα προβλήματα που παρουσιάζονται σε αυτή τη Διατριβή. Τα ενδιαφερόμενα μέρη (**Key Stakeholders - KS**) παρουσιάζονται παρακάτω και συνοψίζονται στο Σχήμα 4.1:



Σχήμα 4.1: Ενδιαφερόμενα Μέρη

KS01 - Producers (PD): Οι παραγωγοί ενέργειας είναι υπεύθυνοι για την παραγωγή της ηλεκτρικής ενέργειας που καταναλώνεται από τα νοικοκυριά και τις επιχειρήσεις. Μπορούν να χρησιμοποιήσουν διάφορες μεθόδους για την παραγωγή ηλεκτρικής ενέργειας, όπως πυρηνική ενέργεια, σταθμούς ηλεκτροπαραγωγής με καύση άνθρακα, σταθμούς ηλεκτροπαραγωγής με καύση φυσικού αερίου, αιολικά πάρκα και ηλιακά πάρκα. Έχουν σημαντικό αντίκτυπο στο περιβάλλον, καθώς οι δραστηριότητές τους μπορεί να συμβάλλουν στις εκπομπές αερίων του θερμοκηπίου και άλλων ρύπων. Σε αυτή την κατηγορία περιλαμβάνονται μεμονωμένοι ιδιοκτήτες πάρκων.

KS02 - Suppliers (SP): Οι προμηθευτές ενέργειας είναι υπεύθυνοι για την παροχή ενέργειας σε νοικοκυριά και επιχειρήσεις. Αγοράζουν ενέργεια από τους παραγωγούς και την πωλούν στους καταναλωτές. Η αγορά ενέργειας έχει ανοίξει στον ανταγωνισμό, πράγμα που σημαίνει ότι οι καταναλωτές μπορούν να επιλέξουν από μια ποικιλία προμηθευτών. Αυτό έχει οδηγήσει σε αυξημένο ανταγωνισμό και ενδεχομένως σε χαμηλότερες τιμές για τους καταναλωτές.

KS03 - Balance Responsible Party (BRP): Οι οντότητες με ευθύνη εξισορρόπησης είναι υπεύθυνες για τη διασφάλιση της ισορροπίας του ενεργειακού δικτύου. Επιβλέπουν ένα ή περισσότερα σημεία πρόσβασης στο δίκτυο μεταφοράς και ο ρόλος του είναι η συνεχής εξισορρόπηση της παραγωγής και της κατανάλωσης. Αυτό συμβάλλει στη διασφάλιση ότι υπάρχει πάντα αρκετή διαθέσιμη ενέργεια για την κάλυψη της ζήτησης.

KS04 - Transmission System Operator (TSO): Οι διαχειριστές του συστήματος μεταφοράς είναι υπεύθυνοι για τη μεταφορά ηλεκτρικής ενέργειας από τους σταθμούς παραγωγής ηλεκτρικής ενέργειας στους βιομηχανικούς πελάτες ή στο δίκτυο διανομής. Είναι επίσης υπεύθυνοι για τη διασφάλιση της συνολικής ισορροπίας του δικτύου με την εξισορρόπηση της παραγωγής και της κατανάλωσης. Πρόκειται για επιχειρήσεις υψηλής εντάσεως κεφαλαίου, γεγονός που καθιστά δύσκολο το άνοιγμά τους στον ανταγωνισμό.

KS05 - Distribution System Operators (DSO): Οι διαχειριστές του συστήματος διανομής είναι υπεύθυνοι για την κατασκευή και διαχείριση των δικτύων μέσης και χαμηλής τάσης που συνδέουν τα δίκτυα μεταφοράς με τις ιδιωτικές κατοικίες. Βοηθούν επίσης στη διαχείριση των διακοπών ρεύματος και των προβλημάτων των μετρητών ενέργειας. Ο ρόλος τους είναι μεγάλης σημασίας για τη διασφάλιση της ασφαλούς και αποτελεσματικής παροχής ενέργειας στους καταναλωτές.

KS06 - Regulatory Bodies (REG): Οι ρυθμιστικοί φορείς είναι υπεύθυνοι για τη διασφάλιση της διαφάνειας και της ανταγωνιστικότητας της αγοράς ενέργειας. Εποπτεύουν τις δραστηριότητες των παραγωγών, των προμηθευτών και άλλων ενδιαφερομένων μερών για να διασφαλίσουν ότι ενεργούν προς το συμφέρον των καταναλωτών. Πιστοποιούν επίσης τη λειτουργία των ενεργειακών αγορών και συμβουλεύουν τις αρχές για ενεργειακά θέματα.

KS07 - Electricity Customers, Consumers, Residents of Buildings, Occupants (BUI): Αυτοί οι ενδιαφερόμενοι είναι οι τελικοί χρήστες της ενέργειας. Καταναλώνουν ενέργεια σε διάφορες κλίμακες, από μεμονωμένα νοικοκυριά έως μεγάλους βιομηχανικούς πελάτες. Έχουν σημαντικό αντίκτυπο στη ζήτηση ενέργειας και μπορούν να συμβάλουν στη μείωση της κατανάλωσης ενέργειας μέσω μέτρων ενεργειακής αποδοτικότητας.

KS08 - Project Developers, Investing Funds, Governmental Institutions (INV): Αυτοί οι ενδιαφερόμενοι φορείς αναζητούν ευκαιρίες χρηματοδότησης για να επενδύσουν σε έργα ενεργειακής αποδοτικότητας. Μπορούν να επενδύσουν σε ανακαινίσεις κτιρίων σε επίπεδο κτιρίου, περιοχής ή πόλης, διαδραματίζοντας σημαντικό ρόλο στην προώθηση των ανανεώσιμων πηγών ενέργειας και στη μείωση της κατανάλωσης ενέργειας. Οι επενδυτές είναι άτομα ή οργανισμοί που παρέχουν χρηματοδότηση για έργα και πρωτοβουλίες που σχετίζονται με την ενέργεια. Αυτό μπορεί να περιλαμβάνει μεμονωμένους επενδυτές, εταιρικούς επενδυτές και χρηματοπιστωτικά ιδρύματα, όπως τράπεζες και εταιρείες επιχειρηματικών κεφαλαίων. Σε αυτή την κατηγορία περιλαμβάνονται προγραμματιστές έργων, επενδυτικά κεφάλαια, ιδιώτες επενδυτές, εταιρικοί επενδυτές καθώς και χρηματοπιστωτικά ιδρύματα.

KS09 - Aggregators (AGG): Οι συσσωρευτές είναι ένας νέος τύπος παρόχου ενεργειακών υπηρεσιών που μπορεί να αυξήσει ή να μετριάσει την κατανάλωση ηλεκτρικής ενέργειας μιας ομάδας καταναλωτών ανάλογα με τη συνολική ζήτηση ηλεκτρικής ενέργειας στο δίκτυο. Συγκεντρώνουν ευελιξία από τις συσκευές των παραγωγών-καταναλωτών (prosumers) και την πωλούν σε DSOs, BRPs και TSOs.

KS10 - Facility Managers, Building Operators (FMB): Οι διαχειριστές κτιρίων είναι υπεύθυνοι για τη διασφάλιση της αποτελεσματικής λειτουργίας της θέρμανσης, της ψύξης, του μηχανολογικού και του ηλεκτρικού εξοπλισμού ενός κτιρίου. Εξασφαλίζουν ότι η εγκατάσταση λειτουργεί με επιτυχία και με τον πιο αποδοτικό τρόπο, γεγονός που μπορεί να συμβάλει στη μείωση της κατανάλωσης ενέργειας και του κόστους.

KS11 - Energy Managers (ENM): Οι διαχειριστές ενέργειας είναι επαγγελματίες που είναι υπεύθυνοι για την επίβλεψη της χρήσης ενέργειας και της ενεργειακής αποδοτικότητας σε έναν οργανισμό. Πρωταρχικός τους στόχος είναι η μείωση της κατανάλωσης ενέργειας και του κόστους, διατηρώντας ή βελτιώνοντας παράλληλα την παραγωγικότητα. Μπορούν να αναπτύξουν και να εφαρμόζουν σχέδια ενεργειακής διαχείρισης, να διενεργούν ενεργειακούς ελέγχους και να εντοπίζουν και να εφαρμόζουν μέτρα εξοικονόμησης ενέργειας.

KS12 - Energy Service Companies (ESCOs): Οι εταιρείες υπηρεσιών ενέργειας είναι εταιρείες που παρέχουν ενεργειακά αποδοτικές λύσεις και υπηρεσίες σε πελάτες. Οι λύσεις αυτές μπορεί να περιλαμβάνουν ενεργειακούς ελέγχους, μέτρα εξοικονόμησης ενέργειας και την εφαρμογή ενεργειακά αποδοτικών τεχνολογιών. Λειτουργούν συνήθως με βάση ένα μοντέλο σύμβασης βάσει επιδόσεων, όπου λαμβάνουν πληρωμή με βάση την ποσότητα ενέργειας που εξοικονομείται από τις λύσεις τους.

KS13 - Government Agencies (GA): Οι κυβερνητικοί οργανισμοί είναι φορείς αρμόδιοι για την εποπτεία και τη ρύθμιση της ενεργειακής και περιβαλλοντικής πολιτικής. Αυτό μπορεί να περιλαμβάνει τμήματα ενέργειας, περιβαλλοντικές υπηρεσίες και άλλους κυβερνητικούς φορείς σε τοπικό, πολιτειακό και εθνικό επίπεδο. Μπορούν να αναπτύσσουν και να επιβάλλουν κανονισμούς, να παρέχουν χρηματοδότηση για έρευνα και ανάπτυξη και να εφαρμόζουν προγράμματα για την ενθάρρυνση της υιοθέτησης ανανεώσιμων πηγών ενέργειας και τεχνολογιών ενεργειακής αποδοτικότητας. Στην κατηγορία αυτή περιλαμβάνονται ενεργειακά τμήματα, περιβαλλοντικοί οργανισμοί καθώς και άλλοι κυβερνητικοί φορείς.

KS14 - Research Institutions (RI): Τα ερευνητικά ιδρύματα είναι οργανισμοί αφιερωμένοι στην προώθηση της επιστημονικής γνώσης μέσω της έρευνας και της ανάπτυξης. Στο πλαίσιο της ενέργειας, τα ερευνητικά ιδρύματα μπορούν να διεξάγουν έρευνα σχετικά με την ενεργειακή αποδοτικότητα, τις τεχνολογίες ανανεώσιμων πηγών ενέργειας και την ενεργειακή πολιτική, μεταξύ άλλων θεμάτων. Παραδείγματα τέτοιων ιδρυμάτων περιλαμβάνουν πανεπιστήμια, εθνικά εργαστήρια και άλλους ερευνητικούς οργανισμούς.

Οι παραπάνω δεκατέσσερις κατηγορίες μπορούν να δώσουν μια πλήρη εικόνα των ενδιαιφερόμενων. Παρ' όλα αυτά η ομαδοποίηση τους σε έξι ευρύτερες κατηγορίες μπορεί να κάνει την ανάλυση πιο κατανοητή. Οι έξι ευρύτερες κατηγορίες παρουσιάζονται παρακάτω.

- **Παραγωγοί και προμηθευτές ενέργειας:** Η κατηγορία αυτή περιλαμβάνει τους παραγωγούς (KS01) και τους προμηθευτές (KS02), οι οποίοι είναι υπεύθυνοι για την παραγωγή και την παράδοση ενέργειας στους τελικούς χρήστες.
- **Διαχειριστές και ρυθμιστικές αρχές δικτύου:** Η κατηγορία αυτή περιλαμβάνει τους υπεύθυνους φορείς εξισορρόπησης (KS03), τους διαχειριστές του συστήματος μεταφοράς (KS04) και διανομής (KS05), καθώς και τους ρυθμιστικούς φορείς (KS06), οι οποίοι είναι υπεύθυνοι για τη διαχείριση του ενεργειακού δικτύου και τη διασφάλιση της αποτελεσματικής και δίκαιης λειτουργίας του.
- **Καταναλωτές και διαχειριστές ενέργειας:** Η κατηγορία αυτή περιλαμβάνει τους καταναλωτές ηλεκτρικής ενέργειας (KS07), τους διαχειριστές εγκαταστάσεων (KS10) και τους διαχειριστές ενέργειας (KS11), οι οποίοι είναι υπεύθυνοι για την κατανάλωση ενέργειας και την αποτελεσματική διαχείρισή της.
- **Ενεργειακοί Επενδυτές:** Η κατηγορία αυτή περιλαμβάνει επενδυτικά ταμεία και χρηματοπιστωτικά ιδρύματα (KS08), τα οποία επενδύουν σε έργα και πρωτοβουλίες που σχετίζονται με την ενέργεια για την προώθηση των ανανεώσιμων πηγών ενέργειας και τη μείωση της κατανάλωσης ενέργειας.
- **Πάροχοι ενεργειακών υπηρεσιών και ερευνητές:** Η κατηγορία αυτή περιλαμβάνει τους συσσωρευτές (KS09), εταιρείες παροχής ενεργειακών υπηρεσιών (KS12), κυβερνητικούς οργανισμούς (KS13) και ερευνητικά ιδρύματα (KS14). Όλοι αυτοί οι φορείς παρέχουν αποδοτικές λύσεις και υπηρεσίες, διεξάγουν έρευνα σε θέματα που σχετίζονται με την ενέργεια και εφαρμόζουν πολιτικές και προγράμματα για την προώθηση βιώσιμων ενεργειακών πρακτικών.

4.2.2 Προβλήματα

Οι αλγόριθμοι και τα μοντέλα TN που προδιαγράφουμε σε αυτό το Κεφάλαιο μπορούν να χρησιμοποιηθούν για την αντιμετώπιση διαφόρων προβλημάτων που σχετίζονται με την

ενέργεια, όπως η πρόβλεψη της ενεργειακής ζήτησης και παραγωγής ενέργειας, η ενεργειακή αποδοτικότητα και η ενεργειακή διαχείριση. Για παράδειγμα, η πρόβλεψη της ενεργειακής ζήτησης περιλαμβάνει την πρόβλεψη της ποσότητας ενέργειας που θα χρειαστεί σε μια συγκεκριμένη χρονική στιγμή και τοποθεσία, ενώ η ενεργειακή αποδοτικότητα περιλαμβάνει την εξεύρεση τρόπων μείωσης της κατανάλωσης ενέργειας χωρίς να επηρεάζεται η απόδοση.

Τα προβλήματα αυτά μπορούν να χωριστούν σε τρεις κύριες κατηγορίες όπως παρουσιάστηκε στο Κεφάλαιο 1: α) προβλήματα που σχετίζονται με την κατανομημένη παραγωγή ενέργειας (**RES**), β) προβλήματα που σχετίζονται με την επίτευξη ευελιξίας μικροδικτύων (**FLEX**) και γ) προβλήματα που σχετίζονται με την ενεργειακή αποδοτικότητα κτιρίων (**ENEF**).

Η πρώτη κατηγορία, RES, ασχολείται με τη μεταβλητότητα και την αβεβαιότητα των ανανεώσιμων πηγών ενέργειας, όπως η ηλιακή και η αιολική ενέργεια. Η ενσωμάτωση αυτών των πηγών στο δίκτυο ηλεκτρικής ενέργειας δημιουργεί προκλήσεις, συμπεριλαμβανομένης της ακριβούς πρόβλεψης της παραγωγής τους, της βελτιστοποίησης της χρήσης τους και της διαχείρισης της μεταβλητότητάς τους για τη διασφάλιση της σταθερότητας και της αξιοπιστίας του δικτύου.

Η δεύτερη κατηγορία, FLEX, περιλαμβάνει κατανομημένους ενεργειακούς πόρους, όπως συστήματα αποθήκευσης ενέργειας, ευέλικτα φορτία και προγράμματα απόκρισης ζήτησης. Οι πόροι αυτοί μπορούν να συμβάλουν στη μείωση της ζήτησης ηλεκτρικής ενέργειας κατά τις περιόδους αιχμής και μπορούν επίσης να συμβάλουν στη σταθερότητα του δικτύου. Ωστόσο, ο βέλτιστος προγραμματισμός και η διαστασιολόγηση αυτών των πόρων απαιτούν ακριβή πρόβλεψη της ζήτησης ενέργειας, των τιμών ενέργειας και των καιρικών συνθηκών.

Η τρίτη κατηγορία, ENEF, επικεντρώνεται στη μείωση της κατανάλωσης ενέργειας στα κτίρια χωρίς να θυσιάζεται η άνεση ή η αποδοτικότητα. Αυτό περιλαμβάνει τη χρήση προηγμένων ελέγχων, συστημάτων αυτοματισμού κτιρίων και ανάλυσης δεδομένων για τη βελτιστοποίηση της κατανάλωσης ενέργειας και τη μείωση της σπατάλης. Τα προβλήματα της κατηγορίας αυτής μπορεί να περιλαμβάνουν την πρόβλεψη της κατανάλωσης ενέργειας, τη βελτιστοποίηση των συστημάτων κλιματισμού κτιρίων και την εκτίμηση της εξοικονόμησης ενέργειας που προκύπτει από μετασκευές και ανακαινίσεις.

Στην παρούσα Διατριβή εξετάζονται τα ακόλουθα προβλήματα τα οποία αντιμετωπίζονται μέσω της ανάπτυξης μικρο-υπηρεσιών (**Analytics Services - AS**) που βασίζονται σε μοντέλα TN και αλγορίθμους βελτιστοποίησης:

- **AS01 - Photovoltaic (PV) Production Forecasting:** Το πρόβλημα της εκτίμησης της ενεργειακής παραγωγής ενός φωτοβολταϊκού βραχυπρόθεσμα (π.χ. μια ώρα μπροστά) ή μεσοπρόθεσμα (π.χ. μια εβδομάδα μπροστά) χρησιμοποιώντας χρονοσειρές παραγωγής φωτοβολταϊκών, ιστορικά δεδομένα καιρού και αριθμητικές προβλέψεις καιρού (Sarmas et al., 2022a).
- **AS02 - Consumption Forecasting at the Building Level:** Το πρόβλημα της εκτίμησης της μελλοντικής ενεργειακής κατανάλωσης ενός κτιρίου χρησιμοποιώντας χρονοσειρές κατανάλωσης κτιρίου (Sarmas et al., 2022b).
- **AS03 - Load Forecasting of the Grid:** Το πρόβλημα της εκτίμησης του μελλοντικού φορτίου του δικτύου χρησιμοποιώντας χρονοσειρές κατανάλωσης, ιστορικά δεδομένα καιρού και αριθμητικές προβλέψεις καιρού (Sarmas et al., 2022e).
- **AS04 - Estimation of Energy Savings as a Result of Renovations:** Το πρόβλημα της εκτίμησης της πραγματικής εξοικονόμησης ενέργειας από ανακαινίσεις με τη χρήση ιστορικών χρονοσειρών κατανάλωσης του κτιρίου, ιστορικών μετεωρολογικών δεδομένων και μετρήσεων μετά τις ενέργειες ανακαινίσης (Sarmas et al., 2023).
- **AS05 - Financing of Energy Conservation Measures:** Το πρόβλημα του προσδιορισμού της κατηγορίας ανακαινίσης (A, B ή Γ) με βάση τις δυνατότητες της

ανακαίνισης όσον αφορά την εξοικονόμηση ενέργειας έναντι του κόστους, χρησιμοποιώντας ιστορικά αρχεία χρηματοδοτικών έργων και χαρακτηριστικά του κτιρίου (Sarmas et al., 2022c).

- **AS06 - Optimization of DERs in micro-grids:** Το πρόβλημα της εύρεσης του βέλτιστου χρονοπρογραμματισμού των ευέλικτων φορτίων και της βέλτιστης διαστασιολόγησης του συστήματος αποθήκευσης, χρησιμοποιώντας προβλέψεις της παραγωγής φωτοβολταϊκών, της κατανάλωσης του κτιρίου και άλλων φορτίων, προφίλ των ευέλικτων φορτίων και των συστημάτων αποθήκευσης. Η υπηρεσία αυτή συνδέεται άμεσα με τις υπηρεσίες AS01 και AS02.
- **AS07 - Scheduling of flexible loads for peak shaving at the grid level:** Το πρόβλημα της εύρεσης του βέλτιστου χρονοπρογραμματισμού των ευέλικτων φορτίων για την ελαχιστοποίηση της αιχμής των φορτίων χρησιμοποιώντας προβλέψεις για τη φωτοβολταϊκή παραγωγή, προβλέψεις για το φορτίο του δικτύου και προφίλ των ευέλικτων φορτίων. Η υπηρεσία αυτή συνδέεται άμεσα με τις υπηρεσίες AS01 και AS03 (Sarmas et al., 2022d).
- **AS08 - Thermal Comfort with Dynamic Energy Management:** Το πρόβλημα του προγραμματισμού του συστήματος HVAC για την εξασφάλιση της θερμικής άνεσης των ενοίκων, χρησιμοποιώντας την κατανάλωση ανά δωμάτιο του κτιρίου, την υγρασία και τη θερμοκρασία. Η υπηρεσία αυτή συνδέεται άμεσα με την υπηρεσία AS02.

Ο πίνακας παρουσιάζει μια αντιστοίχιση των υπηρεσιών προς τους ενδιαφερόμενους φορείς που προδιαγράφηκαν στην προηγούμενη ενότητα. Οι υπηρεσίες καλύπτουν ένα ευρύ φάσμα προβλημάτων, όπως πρόβλεψη, διαχείριση φορτίου και βελτιστοποίηση, και αποσκοπούν στη βελτίωση της ενεργειακής αποδοτικότητας και τη μείωση του ενεργειακού κόστους. Τα ενδιαφερόμενα μέρη χωρίζονται σε δεκατέσσερις ομάδες, συνεπώς ο κάθε ενδιαφερόμενος έχει διαφορετικό σύνολο συμφερόντων, και ο Πίνακας 4.1 υπογραμμίζει ποιες υπηρεσίες είναι πιο σημαντικές για κάθε ομάδα. Για παράδειγμα, η υπηρεσία πρόβλεψης φορτίου (AS03) είναι ιδιαίτερα χρήσιμη για τους διαχειριστές συστημάτων μεταφοράς και τους διαχειριστές συστημάτων διανομής, καθώς τους βοηθά να διαχειρίζονται το δίκτυο πιο αποτελεσματικά. Αντίστοιχα, η υπηρεσία χρηματοδότησης (AS05) είναι πιο σχετική με τους ιδιοκτήτες κτιρίων και τις εταιρείες ενεργειακών υπηρεσιών, οι οποίες είναι υπεύθυνες για την εφαρμογή μέτρων εξοικονόμησης ενέργειας. Με την αντιστοίχιση των υπηρεσιών με τους ενδιαφερόμενους φορείς, παρέχεται μια χρήσιμη επισκόπηση των υπηρεσιών που είναι πιο πολύτιμες για τις διάφορες ομάδες του ενεργειακού κλάδου.

Πίνακας 4.1: Stakeholders and Analytics Services

Stakeholders	AS01	AS02	AS03	AS04	AS05	AS06	AS07	AS08
KS01 - PD	X					X	X	
KS02 - SP	X		X	X				
KS03 - BRP		X	X					
KS04 - TSO	X		X			X		
KS05 - DSO		X	X			X	X	
KS06 - REG					X			
KS07 - BUI		X		X				X
KS08 - INV	X			X	X			
KS09 - AGG	X							
KS10 - FMB		X		X				
KS11 - ENM		X		X				X
KS12 - ESCOs		X		X	X	X		
KS13 - GA						X		X
KS14 - RI	X	X	X	X	X	X	X	X

4.2.3 Δεδομένα

Τα δεδομένα που χρησιμοποιούνται σε ενεργειακές εφαρμογές όπως αυτές που περιγράφθηκαν παραπάνω μπορούν να συλλεχθούν από ένα ευρύ φάσμα ετερογενών πηγών, συμπεριλαμβανομένων αισθητήρων, έξυπνων μετρητών και διαδικτυακών πλατφορμών (Marinakos et al., 2020). Αυτές οι πηγές μπορεί να παρέχουν δεδομένα σε διαφορετικές μορφές και δομές, γεγονός που μπορεί να δημιουργήσει προκλήσεις για την ενσωμάτωση και την επεξεργασία δεδομένων (Obitko et al., 2013). Επιπλέον, τα δεδομένα μπορεί να προέρχονται από διαφορετικούς τομείς, όπως δεδομένα καιρού, δεδομένα κατανάλωσης ενέργειας και δεδομένα κτιρίων, αυξάνοντας περαιτέρω την ετερογένεια των δεδομένων. Ως εκ τούτου, είναι σημαντικό να γίνεται προσεκτική προεπεξεργασία και επιμέλεια των δεδομένων, ώστε να διασφαλιστεί η ποιότητα, η πληρότητα και η συνοχή τους πριν από τη χρήση τους για την ανάπτυξη αλγορίθμων και μοντέλων TN.

Στην παρούσα Διατριβή, για την ανάπτυξη μοντέλων TN για προβλήματα που σχετίζονται με την ενέργεια, χρησιμοποιήθηκαν διάφορες πηγές δεδομένων. Οι πηγές δεδομένων περιλάμβαναν δημόσια διαθέσιμα σύνολα δεδομένων, όπως δεδομένα καιρού, αλλά και δεδομένα κατανάλωσης ενέργειας και δεδομένα παραγωγής ενέργειας. Επιπλέον, συλλέχθηκαν δεδομένα από διάφορους ενδιαφερόμενους φορείς, όπως ιδιοκτήτες κτιρίων, ενεργειακές εταιρείες και εταιρείες διαχείρισης ενέργειας. Τα δεδομένα που συλλέχθηκαν από τους ενδιαφερόμενους φορείς περιλάμβαναν χαρακτηριστικά του κτιρίου, πρότυπα ενεργειακής κατανάλωσης, δεδομένα παραγωγής ενέργειας και καιρικά δεδομένα ειδικά για την τοποθεσία του κτιρίου. Όλα τα δεδομένα ανωνυμοποιήθηκαν και αποθηκεύτηκαν σε ασφαλή τοποθεσία για να διασφαλιστεί το απόρρητο και η ασφάλεια των δεδομένων. Στα δεδομένα πραγματοποιήθηκε προεπεξεργασία και καθαρισμός για να αφαιρεθούν τυχόν ακραίες τιμές, ελλείπουσες τιμές ή σφάλματα που θα μπορούσαν να επηρεάσουν την απόδοση των αλγορίθμων και των μοντέλων. Το τελικό σύνολο δεδομένων που χρησιμοποιήθηκε για την ανάπτυξη των μοντέλων ήταν ένας συνδυασμός δημοσίως διαθέσιμων συνόλων δεδομένων και δεδομένων των ενδιαφερομένων μερών, εξασφαλίζοντας μια πλούσια και ποικιλόμορφη δεξαμενή δεδομένων για την εκπαίδευση των αλγορίθμων και των μοντέλων.

Όσον αφορά τα προβλήματα που μελετούνται στην παρούσα Διατριβή, παρακάτω παρουσιάζονται τα σχετικότερα δεδομένα που μπορούν να χρησιμοποιηθούν ανά πρόβλημα:

- **AS01 - Πρόβλεψη παραγωγής Φ/B :** Τα δεδομένα που απαιτούνται για την πρόβλεψη της φωτοβολταϊκής παραγωγής περιλαμβάνουν ιστορικά δεδομένα παραγωγής, μετεωρολογικά δεδομένα και πληροφορίες σχετικά με την εγκατάσταση (π.χ. τύπος πάνελ, προσανατολισμός).
- **AS02 - Πρόβλεψη κατανάλωσης σε επίπεδο κτιρίου:** Τα δεδομένα που απαιτούνται για την πρόβλεψη της κατανάλωσης σε επίπεδο κτιρίου περιλαμβάνουν ιστορικά δεδομένα κατανάλωσης, μετεωρολογικά δεδομένα, δεδομένα κατοίκησης και χαρακτηριστικά του κτιρίου (π.χ. επιφάνεια, αριθμός κατοίκων).
- **AS03 - Πρόβλεψη φορτίου του δικτύου:** Τα δεδομένα που απαιτούνται για την πρόβλεψη φορτίου του δικτύου περιλαμβάνουν ιστορικά δεδομένα φορτίου, δεδομένα καιρού και ενδεχομένως πληροφορίες σχετικά με το δίκτυο ηλεκτρικής ενέργειας (π.χ. τοπολογία, δεδομένα ροής ισχύος κ.λπ.).
- **AS04 - Εκτίμηση της εξοικονόμησης ενέργειας ως αποτέλεσμα ανακαινίσεων:** Τα δεδομένα που απαιτούνται για την εκτίμηση της εξοικονόμησης ενέργειας από τις ανακαινίσεις περιλαμβάνουν ιστορικά δεδομένα κατανάλωσης πριν και μετά τις ανακαινίσεις, καθώς και πληροφορίες σχετικά με τις ίδιες τις ανακαινίσεις (π.χ. τύπος μόνωσης που έχει τοποθετηθεί, αποδοτικότητα των νέων συσκευών).
- **AS05 - Χρηματοδότηση μέτρων εξοικονόμησης ενέργειας:** Τα δεδομένα που απαιτούνται για τη χρηματοδότηση των μέτρων εξοικονόμησης ενέργειας περιλα-

βάνουν πληροφορίες σχετικά με το κόστος των μέτρων εξοικονόμησης ενέργειας, τις διαθέσιμες επιλογές χρηματοδότησης και την αναμενόμενη απόδοση της επένδυσης.

- **AS06 - Βελτιστοποίηση των DERs σε μικροδίκτυα:** Τα δεδομένα που απαιτούνται για τη βελτιστοποίηση των ενεργειακών πόρων σε μικροδίκτυα περιλαμβάνουν πληροφορίες σχετικά με την τοπική ζήτηση ενέργειας, τη χωρητικότητα των διαθέσιμων πόρων (π.χ. ηλιακά πάνελ, μπαταρίες κ.λπ.) και τα χαρακτηριστικά του ίδιου του μικροδικτύου (π.χ. τοπολογία δικτύου, υποδομή επικοινωνίας κ.λπ.).
- **AS07 - Προγραμματισμός ευέλικτων φορτίων για εξοικονόμηση αιχμής σε επίπεδο δικτύου:** Τα δεδομένα που απαιτούνται για τον προγραμματισμό των ευέλικτων φορτίων για την εξοικονόμηση αιχμής περιλαμβάνουν ιστορικά δεδομένα φορτίου, δεδομένα καιρού και πληροφορίες σχετικά με το ηλεκτρικό δίκτυο (π.χ. τοπολογία, δεδομένα ροής ισχύος κ.λπ.), καθώς και δεδομένα σχετικά με τα ίδια τα ευέλικτα φορτία (π.χ. τη χωρητικότητά τους, την ευελιξία τους κ.λπ.).
- **AS08 - Θερμική άνεση με δυναμική διαχείριση ενέργειας:** Τα δεδομένα που απαιτούνται για τη δυναμική διαχείριση της θερμικής άνεσης περιλαμβάνουν πληροφορίες σχετικά με τα συστήματα θέρμανσης και ψύξης του κτιρίου, τα μετεωρολογικά δεδομένα, τα δεδομένα χρήσης και τις προτιμήσεις των χρηστών του κτιρίου. Μπορεί επίσης να περιλαμβάνουν δεδομένα από αισθητήρες που παρακολουθούν τη θερμοκρασία, την υγρασία και άλλους περιβαλλοντικούς παράγοντες.

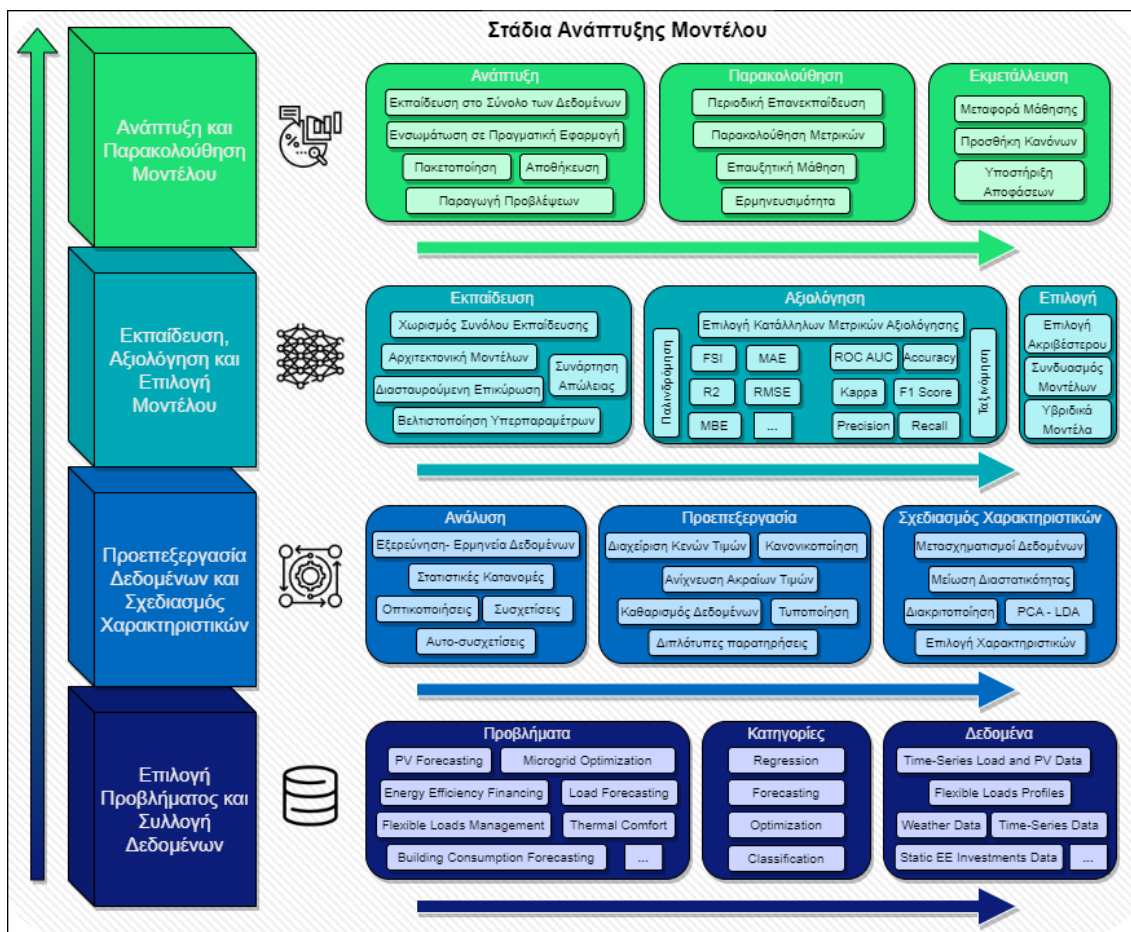
4.3 Στάδια Ανάπτυξης Μοντέλων και Αλγορίθμων

Η ανάπτυξη ενός μοντέλου MM περιλαμβάνει διάφορα στάδια, από την επιλογή του προβλήματος έως την ανάπτυξη και την παρακολούθηση του μοντέλου. Κάθε στάδιο είναι πολύ σημαντικό για τη διασφάλιση της ακρίβειας, της αξιοπιστίας και της αποτελεσματικότητας του μοντέλου στην επίλυση του αντίστοιχου προβλήματος. Σε αυτή την ενότητα, παρουσιάζονται τα τέσσερα στάδια ανάπτυξης ενός μοντέλου MM: επιλογή προβλήματος και συλλογή δεδομένων, προεπεξεργασία δεδομένων και σχεδιασμός χαρακτηριστικών, εκπαίδευση μοντέλου, αξιολόγηση και επιλογή, και ανάπτυξη και παρακολούθηση μοντέλου. Ένα αναλυτικό διάγραμμα που περιγράφει τα τέσσερα στάδια απεικονίζεται στο Σχήμα 4.2

4.3.1 Επιλογή Προβλήματος και Συλλογή Δεδομένων

Το πρώτο βήμα για την ανάπτυξη ενός μοντέλου MM είναι η επιλογή ενός προβλήματος προς επίλυση και η συλλογή σχετικών δεδομένων (**Problem Selection and Data Collection**). Αρχικά, ο χρήστης πρέπει να επιλέξει ένα από αυτά τα προβλήματα και να εισάγει τα απαραίτητα δεδομένα που το αφορούν. Η επιλογή του προβλήματος θα πρέπει να περιλαμβάνει τον ορισμό του προβλήματος, τον προσδιορισμό των επιχειρηματικών ή ερευνητικών στόχων και τον προσδιορισμό της μεταβλητής-στόχου. Είναι σημαντικό να υπάρχει σαφής κατανόηση του προβλήματος που πρόκειται να επιλυθεί, προκειμένου να εντοπιστούν οι σχετικές πηγές δεδομένων και να συλλεχθούν τα απαραίτητα δεδομένα. Το στάδιο αυτό μπορεί να απαιτεί συνεργασία με εμπειρογνώμονες του τομέα ή ενδιαφερόμενους φορείς για να διασφαλιστεί ότι το πρόβλημα και η μεταβλητή-στόχος είναι σαφώς καθορισμένα και αντιπροσωπευτικά του πραγματικού προβλήματος. Στην περίπτωση μας, ο χρήστης καλείται να επιλέξει ένα από τα 8 προβλήματα που παρουσιάστηκαν στην προηγούμενη ενότητα.

Τα προβλήματα που θεραπεύονται μέσω των μοντέλων της παρούσας Διατριβής μπορεί να ανήκουν σε μία ή περισσότερες από τις ακόλουθες κατηγορίες: ταξινόμηση, παλινδρόμηση, πρόβλεψη και βελτιστοποίηση. Για παράδειγμα, η πρόβλεψη φορτίου του δικτύου μπορεί να απαιτεί ανάλυση παλινδρόμησης, ενώ ο προγραμματισμός ευέλικτων φορτίων για εξοικονόμηση



Σχήμα 4.2: Μεθοδολογία

αιχμής σε επίπεδο δικτύου μπορεί να απαιτεί τεχνικές βελτιστοποίησης. Κάθε κατηγορία προβλήματος μπορεί να απαιτεί διαφορετική προσέγγιση για τη συλλογή, την προετοιμασία και την ανάπτυξη μοντέλων δεδομένων. Αυτές οι διαφορετικές κατηγορίες προβλημάτων μπορεί να έχουν διακριτά χαρακτηριστικά και να απαιτούν μοναδικές εκτιμήσεις, όπως η διαθεσιμότητα και η ποιότητα των πηγών δεδομένων, η πολυπλοκότητα του συστήματος που μοντελοποιείται και το επιθυμητό επίπεδο ακρίβειας και ακρίβειας. Ως εκ τούτου, είναι σημαντικό οι χρήστες να εξετάζουν προσεκτικά την κατηγορία του προβλήματος που προσπαθούν να επιλύσουν και να επιλέγουν την κατάλληλη προσέγγιση για τη συλλογή, την προετοιμασία και την ανάπτυξη των αντίστοιχων μοντέλων.

Μόλις καθοριστεί το πρόβλημα, η συλλογή δεδομένων περιλαμβάνει τον προσδιορισμό των πηγών δεδομένων, τη συλλογή και προετοιμασία των δεδομένων και τη διασφάλιση ότι τα δεδομένα είναι αντιπροσωπευτικά του προβλήματος και της μεταβλητής-στόχου. Ο χρήστης πρέπει να εισάγει τα απαραίτητα δεδομένα που σχετίζονται με το επιλεγμένο πρόβλημα. Τα δεδομένα μπορούν να συλλεχθούν από διάφορες πηγές, συμπεριλαμβανομένων αισθητήρων, έξυπνων μετρητών και διαδικτυακών πλατφορμών. Είναι σημαντικό να σημειωθεί ότι η ποιότητα και η ποσότητα των δεδομένων μπορεί να επηρεάσει σημαντικά την ακρίβεια και την αξιοπιστία του μοντέλου, καθιστώντας το στάδιο της συλλογής και προετοιμασίας των δεδομένων κρίσιμο για την επιτυχή ανάπτυξη του μοντέλου.

4.3.2 Προεπεξεργασία Δεδομένων και Σχεδιασμός Χαρακτηριστικών

Το δεύτερο στάδιο στην ανάπτυξη ενός μοντέλου MM είναι η προεπεξεργασία των δεδομένων και ο σχεδιασμός των χαρακτηριστικών (**Data Preprocessing and Feature**

Engineering). Το στάδιο αυτό περιλαμβάνει τον καθαρισμό των δεδομένων, τη μετατροπή τους σε μορφή που να επιτρέπει την άμεση χρήση τους ως είσοδο σε κάποιο μοντέλο, καθώς και τη δημιουργία χαρακτηριστικών που θα χρησιμοποιηθούν για την εκπαίδευση του μοντέλου.

Ειδικότερα στον ενεργειακό τομέα, η προεπεξεργασία δεδομένων και ο σχεδιασμός χαρακτηριστικών παίζουν καθοριστικό ρόλο στη διασφάλιση ότι τα δεδομένα είναι υψηλής ποιότητας και ότι τα χαρακτηριστικά που επιλέγονται είναι συναφή με το συγκεκριμένο πρόβλημα που επιλύεται. Για παράδειγμα, στην περίπτωση της πρόβλεψης του φορτίου του δικτύου (AS03), η προεπεξεργασία δεδομένων μπορεί να περιλαμβάνει τον εντοπισμό και τη διόρθωση τυχόν σφαλμάτων ή ακραίων τιμών στα δεδομένα, καθώς και τον υπολογισμό τυχόν ελλιπών τιμών. Ο σχεδιασμός των χαρακτηριστικών σε αυτή την περίπτωση μπορεί να περιλαμβάνει τη δημιουργία μεταβλητών με χρονική υστέρηση, χαρακτηριστικών με βάση το χρόνο, όπως η ώρα της ημέρας ή η ημέρα της εβδομάδας, και χαρακτηριστικά που σχετίζονται με τις καιρικές συνθήκες, όπως η θερμοκρασία και η υγρασία. Ομοίως, στην περίπτωση του μοντέλου θερμοικής άνεσης με δυναμική διαχείριση ενέργειας (AS08), η προεπεξεργασία δεδομένων μπορεί να περιλαμβάνει τον καθαρισμό και το φιλτράρισμα των δεδομένων αισθητήρων, ενώ ο σχεδιασμός χαρακτηριστικών μπορεί να περιλαμβάνει τη δημιουργία χαρακτηριστικών που αποτυπώνουν τη σχέση μεταξύ των προτύπων χρήσης και του ελέγχου της θερμοκρασίας. Είναι σημαντικό να σημειωθεί ότι η επιλογή των τεχνικών προεπεξεργασίας και σχεδιασμού χαρακτηριστικών μπορεί να έχει σημαντικό αντίκτυπο στην απόδοση του μοντέλου και θα πρέπει να λαμβάνονται προσεκτικά υπόψη τα συγκεκριμένα χαρακτηριστικά των δεδομένων και του προβλήματος που εξετάζεται.

Η προεπεξεργασία δεδομένων περιλαμβάνει εργασίες όπως ο καθαρισμός δεδομένων, ο υπολογισμός ελλιπών τιμών και η κανονικοποίηση δεδομένων. Στο πλαίσιο των προβλημάτων που σχετίζονται με την ενέργεια, τα δεδομένα μπορεί να συλλέγονται από διάφορες πηγές, όπως αισθητήρες ή έξυπνους μετρητές. Συνεπώς, ο καθαρισμός δεδομένων μπορεί να περιλαμβάνει την αφαίρεση ή τη διόρθωση λανθασμένων ή άσχετων δεδομένων. Για παράδειγμα, τα δεδομένα που συλλέγονται από αισθητήρες μπορεί να περιέχουν θόρυβο ή ακραίες τιμές λόγω σφαλμάτων υλικού ή εξωτερικών παραγόντων όπως οι καιρικές συνθήκες. Σε τέτοιες περιπτώσεις, μπορούν να χρησιμοποιηθούν τεχνικές καθαρισμού δεδομένων, όπως η εξομάλυνση ή το φιλτράρισμα, για την απομάκρυνση του θορύβου ή των ακραίων τιμών. Η αντιμετώπιση των δεδομένων που λείπουν αποτελεί, επίσης, ένα πολύ σημαντικό στάδιο της προεπεξεργασίας δεδομένων. Στο πλαίσιο των προβλημάτων που σχετίζονται με την ενέργεια, η έλλειψη δεδομένων μπορεί να οφείλεται σε διάφορους λόγους, όπως δυσλειτουργία του εξοπλισμού ή αποτυχία επικοινωνίας. Για την αντιμετώπιση των ελλειπόντων δεδομένων μπορούν να χρησιμοποιηθούν διάφορες τεχνικές, όπως ο μέσος όρος, η παλινδρόμηση ή η επαύξηση δεδομένων, καθώς και η συμπλήρωση με τιμές προηγούμενων ημερών. Η κανονικοποίηση δεδομένων περιλαμβάνει τον μετασχηματισμό των δεδομένων σε μια τυπική κλίμακα για την αποφυγή μεροληψιών λόγω διαφορών στις μονάδες μέτρησης ή στις κλίμακες. Αυτό είναι ιδιαίτερα σημαντικό όταν τα δεδομένα συλλέγονται από διαφορετικές πηγές ή σε διαφορετικές χρονικές περιόδους. Οι συνήθεις τεχνικές για την κανονικοποίηση δεδομένων περιλαμβάνουν την κλιμάκωση $\min\max$, την κανονικοποίηση Z-score ή τον λογαριθμικό μετασχηματισμό, μεταξύ άλλων.

Ο σχεδιασμός των χαρακτηριστικών διαδραματίζει καθοριστικό ρόλο στη δημιουργία ακριβών και αποτελεσματικών μοντέλων MM για προβλήματα που σχετίζονται με την ενέργεια. Περιλαμβάνει τη δημιουργία νέων χαρακτηριστικών από τα ακατέργαστα δεδομένα, την επιλογή των πιο σχετικών χαρακτηριστικών και τη μείωση της διαστατικότητας των δεδομένων. Στο πλαίσιο των ενεργειακών προβλημάτων, ο σχεδιασμός χαρακτηριστικών μπορεί να περιλαμβάνει την εξαγωγή σχετικών πληροφοριών από δεδομένα χρονοσειρών, όπως μοτίβα, τάσεις, εποχικότητα και πληροφορίες για τις καιρικές συνθήκες. Για παράδειγμα, στην περίπτωση της πρόβλεψης της παραγωγής φωτοβολταϊκών, η ώρα της ημέρας, η εποχή, οι καιρικές συνθήκες και τα ιστορικά δεδομένα παραγωγής μπορούν να χρησιμοποιηθούν ως χαρακτηριστικά για την εκπαίδευση του μοντέλου. Επίσης, κατά τη δημιουργία ενός μοντέλου πρόβλεψης κατανάλωσης σε επίπεδο κτιρίου, μπορούν να ληφθούν υπόψη σχετικά χαρακτηριστικά, όπως

τα πρότυπα χρήσης, τα ιστορικά δεδομένα κατανάλωσης και οι καιρικές συνθήκες. Επομένως, ο σχεδιασμός των κατάλληλων χαρακτηριστικών μπορεί να επηρεάσει σημαντικά την απόδοση και την ακρίβεια. Υπάρχουν διάφορες τεχνικές που μπορούν να χρησιμοποιηθούν για το σχεδιασμό των χαρακτηριστικών, συμπεριλαμβανομένης της εμπειρικής γνώσης του τομέα, των στατιστικών μεθόδων και των μεθόδων που βασίζονται σε μοντέλα TN. Η εμπειρική γνώση του τομέα περιλαμβάνει την κατανόηση του τομέα του προβλήματος και τη χρήση προηγούμενης γνώσης για την επιλογή χαρακτηριστικών. Οι στατιστικές μέθοδοι κάνουν χρήση στατιστικών τεχνικών όπως η ανάλυση συσχέτισης, η ανάλυση κύριων συνιστωσών (*Principal Component Analysis - PCA*) και αλγορίθμων επιλογής χαρακτηριστικών για τον εντοπισμό των πιο σχετικών χαρακτηριστικών. Τέλος, οι μέθοδοι που βασίζονται σε μοντέλα χρησιμοποιούν αλγορίθμους MM, όπως δέντρα αποφάσεων και τυχαία δάση, για τον εντοπισμό των πιο σημαντικών χαρακτηριστικών. Ο συνδυασμός των παραπάνω βοηθά στον εντοπισμό των πιο σχετικών χαρακτηριστικών για κάθε δεδομένο πρόβλημα.

4.3.3 Εκπαίδευση, Αξιολόγηση και Επιλογή Μοντέλου

Το επόμενο στάδιο στην ανάπτυξη ενός μοντέλου MM περιλαμβάνει την επιλογή ενός αλγορίθμου, την εκπαίδευση του μοντέλου σε δεδομένα και την αξιολόγηση της απόδοσής του (**Model Training, Evaluation and Selection**). Ο απώτερος στόχος είναι η ανάπτυξη ενός μοντέλου που γενικεύει καλά σε νέα, αθέατα δεδομένα, ενώ παράλληλα είναι ακριβές και ερμηνεύσιμο. Αυτό το στάδιο είναι συνήθως επαναληπτικό, με προσαρμογές στο μοντέλο, όπως απαιτείται, βάσει των αποτελεσμάτων αξιολόγησης.

Η εκπαίδευση του μοντέλου περιλαμβάνει την προσαρμογή του επιλεγμένου αλγορίθμου στα δεδομένα για την εκμάθηση των υποκείμενων μοτίβων και σχέσεων. Το στάδιο αυτό περιλαμβάνει το διαχωρισμό των διαθέσιμων δεδομένων σε σύνολα εκπαίδευσης, επικύρωσης και δοκιμής. Το σύνολο εκπαίδευσης (*train set*) χρησιμοποιείται για την προσαρμογή του μοντέλου, ενώ το σύνολο επικύρωσης (*validation set*) χρησιμοποιείται για τη ρύθμιση των υπερπαραμέτρων και την αποφυγή της υπερπροσαρμογής. Αφού εκπαιδευτεί το μοντέλο, δοκιμάζεται στο σύνολο αξιολόγησης (*test set*) για να αξιολογηθεί η απόδοσή του.

Η αξιολόγηση του μοντέλου είναι η διαδικασία μέτρησης της απόδοσης του εκπαιδευμένου μοντέλου στο σύνολο δοκιμής. Η επιλογή της μετρικής αξιολόγησης εξαρτάται από τον τύπο του προβλήματος, όπως η ταξινόμηση ή η παλινδρόμηση. Σε προβλήματα ταξινόμησης, οι συνήθεις μετρικές περιλαμβάνουν μετρικές όπως οι *accuracy*, *precision*, *recall*, *F1-Score* και την περιοχή κάτω από την καμπύλη *AUC-ROC*. Η μετρική *accuracy* μετρά το ποσοστό των σωστών προβλέψεων, ενώ η μετρικές *precision* και *recall* ποσοτικοποιούν το ποσοστό των αληθώς θετικών μεταξύ όλων των θετικών προβλέψεων και το ποσοστό των αληθώς θετικών μεταξύ όλων των πραγματικών θετικών δειγμάτων, αντίστοιχα. Η καμπύλη *AUC-ROC* απεικονίζει το αληθώς θετικό ποσοστό έναντι του ψευδώς θετικού ποσοστού και παρέχει ένα μέτρο της ικανότητας του μοντέλου να διακρίνει μεταξύ θετικών και αρνητικών δειγμάτων. Σε προβλήματα παλινδρόμησης, μετρικές όπως το μέσο απόλυτο σφάλμα (*Mean Absolute Error - MAE*), το μέσο τετραγωνικό σφάλμα (*Mean Squared Error - MSE*) και το *R2* χρησιμοποιούνται συνήθως για την αξιολόγηση της απόδοσης ενός μοντέλου. Τα *MAE* και *MSE* μετρούν τις μέσες απόλυτες και τετραγωνικές διαφορές μεταξύ των προβλεπόμενων και των πραγματικών τιμών, αντίστοιχα, ενώ το *R2* μετρά το ποσοστό της διακύμανσης της μεταβλητής-στόχου που μπορεί να επεξηγηθεί από το μοντέλο. Στα παρακάτω Κεφάλαια που παρουσιάζονται οι πειραματικές εφαρμογές πραγματοποιείται μια λεπτομερέστερη περιγραφή των χρησιμοποιούμενων μετρικών κατά περίπτωση.

Η επιλογή μοντέλου περιλαμβάνει τη σύγκριση διαφορετικών αλγορίθμων και τη βελτιστοποίηση των υπερπαραμέτρων για την επιλογή του μοντέλου με την καλύτερη απόδοση. Οι υπερπαραμέτροι προσαρμόζονται για τη λεπτομερή ρύθμιση της απόδοσης του επιλεγμένου μοντέλου. Συνήθως, η επιλογή μοντέλου γίνεται κατά τη διάρκεια ή μετά την εκπαίδευση και την αξιολόγηση του μοντέλου. Περιλαμβάνει τη σύγκριση των επιδόσεων διαφορετικών αλγορίθμων ή παραλλαγών του ίδιου αλγορίθμου και την επιλογή του μοντέλου με τις καλύτερες

επιδόσεις βάσει ορισμένων μετρικών. Μόλις επιλεγεί το καλύτερο μοντέλο, μπορεί να ρυθμιστεί και να βελτιστοποιηθεί περαιτέρω. Ωστόσο, είναι σημαντικό να σημειωθεί ότι η διαδικασία της επιλογής μοντέλου είναι επαναληπτική και μπορεί να περιλαμβάνει αναδράσεις μεταξύ της εκπαίδευσης, της αξιολόγησης και της επιλογής μέχρι να επιτευχθεί ένα ικανοποιητικό μοντέλο.

4.3.4 Ανάπτυξη και Παρακολούθηση Μοντέλου

Το τελικό στάδιο της δημιουργίας ενός μοντέλου MM είναι η ανάπτυξη και η παρακολούθηση του μοντέλου (**Model Deployment and Monitoring**). Μόλις το μοντέλο επιλεγεί, εκπαιδευτεί και αξιολογηθεί, είναι έτοιμο να αναπτυχθεί σε περιβάλλον παραγωγής. Αυτό περιλαμβάνει την ενσωμάτωση του μοντέλου σε υπάρχοντα συστήματα και υποδομές, καθώς και τη δημιουργία διαδικασιών για την εισαγωγή δεδομένων, την προεπεξεργασία και την πρόβλεψη. Εκτός από την ανάπτυξη του μοντέλου, είναι σημαντικό να δημιουργηθεί ένα πλαίσιο παρακολούθησης για τον έλεγχο της απόδοσης του μοντέλου με την πάροδο του χρόνου. Αυτό περιλαμβάνει τη δημιουργία αυτοματοποιημένων διαδικασιών για την παρακολούθηση της ακρίβειας του μοντέλου, τον εντοπισμό τυχόν ανωμαλιών ή σφαλμάτων στις προβλέψεις και την ενεργοποίηση ειδοποιήσεων όπου κριθεί απαραίτητο.

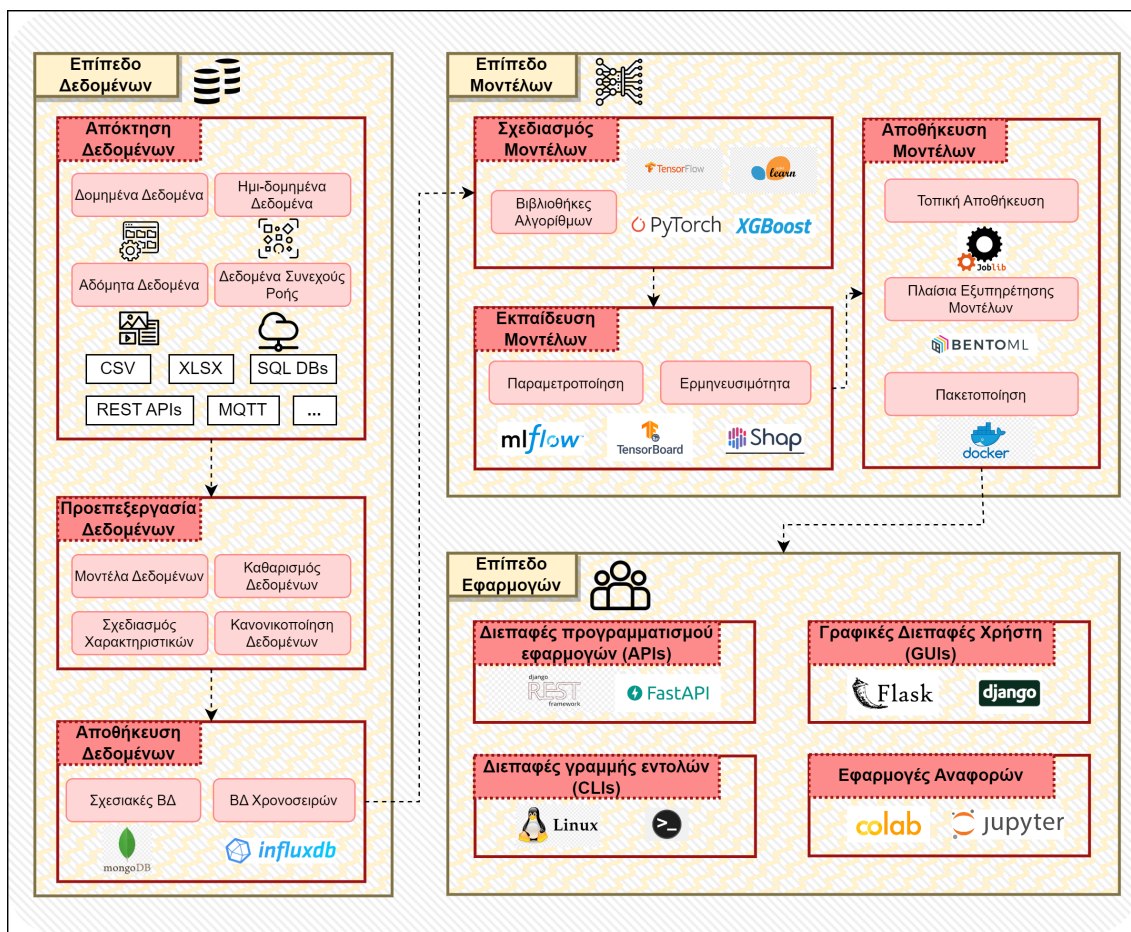
Τέλος, είναι απαραίτητο να επανεκπαιδευτεί συνεχώς το μοντέλο με νέα δεδομένα, ώστε να διασφαλίζεται ότι παραμένει ενημερωμένο και συνεχίζει να παρέχει ακριβείς προβλέψεις. Αυτό απαιτεί τη δημιουργία μιας συνεχούς ροής δεδομένων για την τροφοδοσία νέων δεδομένων στο μοντέλο, την επανεκπαίδευσή του σε τακτική βάση και την ανάπτυξη του ενημερωμένου μοντέλου στην παραγωγή. Συνολικά, ο στόχος της ανάπτυξης και παρακολούθησης του μοντέλου είναι να διασφαλιστεί ότι το μοντέλο παραμένει ακριβές και αξιόπιστο με την πάροδο του χρόνου και ότι συνεχίζει να συμβάλλει στην επιτυχία της επιχείρησης ή του ερευνητικού έργου.

4.4 Προτεινόμενη Αρχιτεκτονική

Στον τομέα της TN, η ανάπτυξη μοντέλων που προβλέπουν με ακρίβεια τα αντίστοιχα ενεργειακά μεγέθη είναι μόνο ένα μέρος της διαδικασίας και σε καμία περίπτωση δεν εγγυάται την προσφορά αξιόλογων υπηρεσιών στα ενδιαφερόμενα μέρη. Για να αξιοποιηθούν πραγματικά αυτά τα μοντέλα, πρέπει να ενσωματωθούν σε μια ευρύτερη αρχιτεκτονική η οποία θα μπορεί να χειρίζεται την απόκτηση, την προεπεξεργασία και την αποθήκευση δεδομένων, καθώς και την εξυπηρέτηση των αποτελεσμάτων στους τελικούς χρήστες μέσω διαφόρων καναλιών. Σε αυτό το σημείο χρειάζεται να επιστρατευτεί μια ολοκληρωμένη αρχιτεκτονική για τη διαχείριση των δεδομένων, των μοντέλων MM και των αποτελεσμάτων. Υπάρχουν πολλοί διαφορετικοί τρόποι δόμησης μιας τέτοιας αρχιτεκτονικής, ανάλογα με τις συγκεκριμένες ανάγκες της εφαρμογής και τους διαθέσιμους πόρους (Mehmood et al., 2019; Linder et al., 2017; Marinakis et al., 2020). Σε αυτή την ενότητα, παρουσιάζεται μια αρχιτεκτονική τριών επιπέδων που περιλαμβάνει το επίπεδο δεδομένων, το επίπεδο μοντέλων και το επίπεδο εφαρμογών και εξετάζονται ορισμένα από τα κοινά εργαλεία και τεχνικές που χρησιμοποιούνται σε κάθε επίπεδο. Η προτεινόμενη αρχιτεκτονική παρουσιάζεται στο Σχήμα 10.2.

Τα επιμέρους επίπεδα αυτής τη αρχιτεκτονικής παρουσιάζονται συνοπτικά παρακάτω:

- **Επίπεδο Δεδομένων:** Το επίπεδο δεδομένων παρέχει μια ισχυρή και κλιμακωμένη λύση για τη διαχείριση των δεδομένων, η οποία αποτελεί κρίσιμο συστατικό κάθε συστήματος MM. Η κύρια λειτουργικότητα του είναι ο χειρισμός διαφορετικών τύπων δεδομένων, δομημένα, αδόμητα, ημιδομημένα ή συνεχούς ροής, υποστηρίζοντας τον καθαρισμό τους, το σχεδιασμό χαρακτηριστικών και την κανονικοποίηση. Επιπλέον, διευκολύνει την ενσωμάτωση δεδομένων από διαφορετικές πηγές και επιτρέπει την αποτελεσματική αποθήκευση σε διάφορους τύπους βάσεων δεδομένων.



Σχήμα 4.3: Αρχιτεκτονική

- **Επίπεδο Μοντέλων:** Το επίπεδο μοντέλων είναι ένα απαραίτητο μέρος κάθε συστήματος MM, καθώς είναι υπεύθυνο για την ανάπτυξη, την εκπαίδευση και την αποθήκευση των μοντέλων που αντιμετωπίζουν τα προβλήματα που παρουσιάστηκαν στην αρχή του Κεφαλαίου. Το επίπεδο μοντέλων επιτρέπει τη δημιουργία σύνθετων μοντέλων που μπορούν να εντοπίζουν μοτίβα σε μεγάλα σύνολα δεδομένων, να κάνουν ακριβείς προβλέψεις και να προσαρμόζονται στις μεταβαλλόμενες συνθήκες με την πάροδο του χρόνου.
- **Επίπεδο Εφαρμογών:** Το επίπεδο αυτό επιτρέπει στους χρήστες να έχουν πρόσβαση και να ερμηνεύουν τις αποφάσεις που λαμβάνονται από τα εκπαιδευμένα μοντέλα και να αποκτούν γνώσεις σχετικά με τους παράγοντες που επηρεάζουν τις προβλέψεις των μοντέλων. Μπορεί να υλοποιηθεί με διάφορους τρόπους, όπως μέσω διαδικτυακών εφαρμογών, εφαρμογών αναφορών ή μέσω διεπαφών προγραμματισμού εφαρμογών. Κάθε ένας από αυτούς τους τρόπους έχει ξεχωριστά πλεονεκτήματα και περιορισμούς, όπως θα δούμε αναλυτικότερα στη συνέχεια της ενότητας.

Στη συνέχεια παρουσιάζονται με μεγαλύτερη λεπτομέρεια τα επιμέρους συστήματα κάθε επιπέδου της αρχιτεκτονικής και οι ρόλοι τους στο σχεδιασμό και την ανάπτυξη μοντέλων MM.

4.4.1 Επίπεδο Δεδομένων

Το επίπεδο δεδομένων (**Data Layer**) αποτελεί το θεμέλιο της προτεινόμενης αρχιτεκτονικής όντας το σημείο όπου αποκτώνται (*ingestion*), προεπεξεργάζονται (*preprocessing*) και αποθηκεύονται (*storage*) τα απαραίτητα δεδομένα για τα ενεργειακά προβλήματα που εξετάζουμε. Η απόκτηση δεδομένων είναι το πρώτο βήμα στο επίπεδο δεδομένων και περιλαμβάνει

την σύνδεση με διάφορες πηγές ώστε να αποκτηθούν τα αντίστοιχα δεδομένα σε πρωτογενή μορφή. Τα δεδομένα αυτά μπορεί να είναι δομημένα, αδόμητα ή ημιδομημένα. Τα δομημένα δεδομένα βασίζονται σε ένα προκαθορισμένο μοντέλο ή σχήμα, όπως, για παράδειγμα, μια σχεσιακή βάση δεδομένων. Τα μη δομημένα δεδομένα, από την άλλη πλευρά, δεν έχουν προκαθορισμένο μοντέλο δεδομένων, όπως για παράδειγμα κείμενο σε μηνύματα ηλεκτρονικού ταχυδρομείου ή αναρτήσεις σε μέσα κοινωνικής δικτύωσης. Τα ημιδομημένα δεδομένα είναι ένας συνδυασμός των παραπάνω, όπως για παράδειγμα δεδομένα XML ή JSON. Τα δεδομένα συνεχούς ροής παράγονται συνεχώς σε πραγματικό χρόνο. Χαρακτηριστικό παράδειγμα αποτελούν δεδομένα αισθητήρων από έξυπνους μετρητές ή συσκευές IoT. Οι πηγές δεδομένων μπορεί να περιλαμβάνουν ενδείξεις αισθητήρων, δεδομένα έξυπνων μετρητών από νοικοκυριά και επιχειρήσεις, δεδομένα καιρού από μετεωρολογικούς σταθμούς ή δεδομένα κατανάλωσης ενέργειας από παρόχους ενέργειας.

Μετά την απόκτηση δεδομένων ακολουθεί το στάδιο της προεπεξεργασίας, η οποία αποτελεί ένα κρίσιμο βήμα για τη διασφάλιση της ποιότητας και της ακρίβειας των δεδομένων. Το βήμα αυτό περιλαμβάνει τη μοντελοποίηση δεδομένων, τον καθαρισμό δεδομένων, το σχεδιασμό χαρακτηριστικών και την κανονικοποίηση δεδομένων. Η μοντελοποίηση δεδομένων περιλαμβάνει τον καθορισμό του σχήματος, των τύπων και των δομών δεδομένων. Ο καθαρισμός περιλαμβάνει τον εντοπισμό και την αφαίρεση των ακραίων τιμών, τον χειρισμό των τιμών που λείπουν και την αντιμετώπιση των ασυνεπειών. Ο σχεδιασμός χαρακτηριστικών περιλαμβάνει την επιλογή και τον μετασχηματισμό χαρακτηριστικών. Τέλος, η κανονικοποίηση δεδομένων χρησιμοποιείται για την κλιμάκωση των δεδομένων σε ένα κοινό εύρος, το οποίο μπορεί να βελτιώσει την αποτελεσματικότητα και την ακρίβεια των μοντέλων. Μετά την προεπεξεργασία των δεδομένων, αυτά αποθηκεύονται σε διάφορους τύπους βάσεων δεδομένων, ανάλογα με τα χαρακτηριστικά τους αλλά και τις απαιτήσεις των μοντέλων MM. Για παράδειγμα, για δομημένα δεδομένα μπορεί να χρησιμοποιηθεί μια βάση δεδομένων SQL, ενώ για μη δομημένα δεδομένα μπορεί να είναι πιο κατάλληλη μια βάση δεδομένων NoSQL. Τα αποθηκευμένα δεδομένα μπορούν να υποβληθούν σε περαιτέρω επεξεργασία στο επίπεδο μοντέλων για την εκπαίδευση και την αξιολόγηση των μοντέλων MM.

Η απόκτηση και η προεπεξεργασία δεδομένων μπορεί να αποτελέσει πρόκληση λόγω του μεγάλου όγκου δεδομένων, της ποικιλίας των πηγών δεδομένων και της πολυπλοκότητας των δεδομένων. Για παράδειγμα, τα δεδομένα κατανάλωσης ενέργειας μπορεί να διαφέρουν σημαντικά μεταξύ των νοικοκυριών και οι πάροχοι ενέργειας μπορεί να έχουν διαφορετικές μορφές δεδομένων και σχήματα δεδομένων. Συνεπώς, είναι πολύ σημαντικό να υπάρχουν ισχυρές διαδικασίες απόκτησης και προεπεξεργασίας δεδομένων για να διασφαλιστεί η ακρίβεια και η αξιοπιστία των μοντέλων.

4.4.2 Επίπεδο Μοντέλων

Το επίπεδο μοντέλων (**Models Layer**) είναι το δεύτερο επίπεδο της αρχιτεκτονικής και περιλαμβάνει το σχεδιασμό (*development*), την εκπαίδευση (*training*) και την αποθήκευση (*storage*) των μοντέλων. Το επίπεδο μοντέλων είναι υπεύθυνο για τη δημιουργία των μοντέλων που θα χρησιμοποιηθούν για την επίλυση των προτεινόμενων ενεργειακών προβλημάτων με τη χρήση των αντίστοιχων κατάλληλων δεδομένων που έχουν προτυποποιηθεί στο επίπεδο δεδομένων.

Ο σχεδιασμός μοντέλων περιλαμβάνει όλες τις ενέργειες που απαιτούνται για τη δημιουργία των μοντέλων MM. Το στάδιο αυτό περιλαμβάνει την επιλογή των κατάλληλων βιβλιοθηκών, αλγορίθμων και τεχνικών για το συγκεκριμένο πρόβλημα. Στα πλαίσια της παρούσας Διατριβής έχουν χρησιμοποιηθεί και υποστηρίζονται διαφορετικές βιβλιοθήκες όπως οι *SkLearn*, *PyTorch*, *TensorFlow Keras*, *XGBoost* και άλλες (Buitinck et al., 2013; Paszke et al., 2019; Chollet et al., 2015; Chen and Guestrin, 2016). Ανάλογα με τη φύση του προβλήματος, μπορούν να χρησιμοποιηθούν διαφορετικοί αλγόριθμοι όπως δέντρα αποφάσεων, τυχαία δάση, μηχανές διανυσμάτων υποστήριξης, νευρωνικά δίκτυα και άλλοι. Η επιλογή της βιβλιοθήκης, του αλγορίθμου και των τεχνικών θα πρέπει να βασίζεται στα χαρακτηριστικά του προβλήμα-

τος, τα διαθέσιμα δεδομένα και τα επιθυμητά κριτήρια απόδοσης. Ειδικότερα στον ενεργειακό τομέα, διάφορα προβλήματα μπορούν να αντιμετωπιστούν με τη χρήση τεχνικών MM, όπως η ταξινόμηση σφαλμάτων σε συστήματα ηλεκτρικής ενέργειας, η παλινδρόμηση της κατανάλωσης ενέργειας, η πρόβλεψη της παραγωγής ενέργειας από ανανεώσιμες πηγές και η ομαδοποίηση των καταναλωτών ενέργειας με βάση τα πρότυπα κατανάλωσής τους. Για παράδειγμα, ένα μοντέλο πρόβλεψης μπορεί να χρησιμοποιηθεί για την πρόβλεψη της ενέργειας που παράγεται από Φ/Β συστήματα, ανεμογεννήτριες ή άλλες ανανεώσιμες πηγές ενέργειας, ενώ ένα μοντέλο ομαδοποίησης μπορεί να χρησιμοποιηθεί για την ομαδοποίηση των καταναλωτών με βάση τα πρότυπα κατανάλωσής με στόχο την κινητροποίηση τους ως προς την εξοικονόμηση ενέργειας.

Αφού αναπτυχθούν τα μοντέλα, πρέπει να εκπαιδευτούν χρησιμοποιώντας τα διαθέσιμα δεδομένα. Η εκπαίδευση του μοντέλου περιλαμβάνει τη ρύθμιση των υπερπαραμέτρων του μοντέλου για τη βελτίωση της απόδοσής του στα δεδομένα εκπαίδευσης. Οι υπερπαραμέτροι είναι οι παράμετροι διαμόρφωσης που καθορίζουν τον τρόπο εκπαίδευσης του μοντέλου, όπως ο ρυθμός μάθησης, ο αριθμός των κρυφών στρωμάτων και ο αριθμός των νευρώνων. Στα πλαίσια της Διατριβής υποστηρίζονται διάφορα εργαλεία για τη ρύθμιση των υπερπαραμέτρων όπως το TensorBoard, καθώς και τα αντίστοιχα περιβάλλοντα εκπαίδευσης όπως το MLFlow. Επιπλέον, η ερμηνευσιμότητα των μοντέλων μπορεί να αξιολογηθεί με τη χρήση διαφόρων εργαλείων, όπως το Shap. Αξίζει να σημειωθεί πως η ποιότητα και η ποσότητα των δεδομένων μπορούν να επηρεάσουν σημαντικά την ακρίβεια και την αξιοπιστία του μοντέλου, καθιστώντας τα στάδια της ρύθμισης των υπερπαραμέτρων και της αξιολόγησης της ερμηνευσιμότητας πολύ κρίσιμα για την επιτυχή ανάπτυξη του μοντέλου. Για παράδειγμα, ένα μοντέλο παλινδρόμησης που προβλέπει την κατανάλωση ενέργειας θα πρέπει να εκπαιδευτεί σε ένα μεγάλο και πλήρες σύνολο δεδομένων με ποικίλες εισόδους, όπως ο καιρός, η παρελθοντική κατανάλωση του κτιρίου και τα χαρακτηριστικά του, για να βελτιωθεί η ακρίβειά του.

Τέλος, αφού εκπαιδευτούν τα μοντέλα, πρέπει να αποθηκευτούν για μελλοντική χρήση. Η αρχιτεκτονική που προτείνουμε μπορεί να υποστηρίξει διαφορετικούς τρόπους αποθήκευσης των μοντέλων, συμπεριλαμβανομένης της τοπικής αποθήκευσης με χρήση του joblib, της αποθήκευσης στο νέφος (cloud) με χρήση εργαλείων όπως το BentoML και της πακετοποίησης με χρήση Docker. Η τοπική αποθήκευση είναι κατάλληλη για την αποθήκευση μικρών μοντέλων που μπορούν εύκολα να φορτωθούν και να χρησιμοποιηθούν στο ίδιο περιβάλλον. Η αποθήκευση στο νέφος είναι κατάλληλη για την αποθήκευση μεγαλύτερων μοντέλων στα οποία μπορεί να υπάρξει πρόσβαση από οπουδήποτε και να χρησιμοποιηθούν σε διαφορετικά περιβάλλοντα, ενώ η πακετοποίηση των μοντέλων με χρήση του Docker επιτρέπει την ανάπτυξή τους ως αυτόνομα πακέτα και τη χρήση τους σε διαφορετικά περιβάλλοντα χωρίς εξαρτήσεις.

4.4.3 Επίπεδο Εφαρμογών

Το επίπεδο εφαρμογών (**Applications Layer**) είναι υπεύθυνο για την παροχή μιας ολοκληρωμένης προβολής των αποτελεσμάτων στους τελικούς χρήστες με τρόπο εύχρηστο, κατανοητό και προσβάσιμο. Υπάρχουν διάφοροι τρόποι για να γίνει αυτό, συμπεριλαμβανομένων των γραφικών διεπαφών χρήστη, των διεπαφών προγραμματισμού εφαρμογών, των διεπαφών γραμμής εντολών, καθώς και των εφαρμογών αναφορών. Μία από τις βασικότερες λειτουργίες αυτού του επιπέδου είναι η ανάπτυξη εφαρμογών που ενισχύουν την ερμηνευσιμότητα και την επεξηγηματικότητα των προβλέψεων του εκάστοτε μοντέλου. Αυτό είναι ιδιαίτερος χρήσιμο σε προβλήματα ενεργειακής διαχείρισης, όπου η κατανόηση των υποκείμενων παραγόντων που συμβάλλουν στην παραχθείσα πρόβλεψη ή σύσταση είναι σημαντική για τη λήψη τεκμηριωμένων αποφάσεων. Το επίπεδο εφαρμογών θα πρέπει επίσης να επιτρέπει στους χρήστες να κατανοήσουν ποια χαρακτηριστικά είναι πιο σημαντικά στις προβλέψεις του μοντέλου και πώς επηρεάζουν το αποτέλεσμα.

Στο πλαίσιο της Διατριβής τα αποτελέσματα μπορούν να γίνουν διαθέσιμα στον τελικό χρήστη με μια ή περισσότερες από τις ακόλουθες επιλογές:

- **Διεπαφές προγραμματισμού εφαρμογών (Application Programming In-**

terfaces - APIs): Σε αυτή την κατηγορία ανήκουν οι διεπαφές που επιτρέπουν στις εφαρμογές λογισμικού να επικοινωνούν μεταξύ τους. Τα μοντέλα μπορούν να ενσωματωθούν σε εφαρμογές μέσω APIs, επιτρέποντας τα αποτελέσματα των των μοντέλων να είναι προσβάσιμα και να χρησιμοποιούνται προγραμματιστικά. Γενικότερα, αυτός ο τρόπος πρόσβασης στα αποτελέσματα ενός μοντέλου χρησιμοποιείται από μεγάλους οργανισμούς ή εταιρείες για την πρόσβαση σε μαζικές προβλέψεις με μεγάλο πλήθος μεταβλητών προς πρόβλεψη.

- **Γραφικές διεπαφές χρήστη (Graphical User Interfaces - GUIs)**: Πρόκειται για διαδραστικές εφαρμογές που παρέχουν οπτική διεπαφή για την αλληλεπίδραση των χρηστών με τα αποτελέσματα των μοντέλων. Οι γραφικές διεπαφές μπορούν να σχεδιαστούν για να εμφανίζουν τα αποτελέσματα με διάφορους τρόπους, όπως διαγράμματα, γραφήματα, πίνακες ή χάρτες. Αυτές οι διεπαφές μπορεί να έχουν τη μορφή μιας διαδικτυακής εφαρμογής που εμφανίζει τις προβλέψεις, τις βασικές μετρικές επίδοσης και άλλες σχετικές πληροφορίες. Σε αυτές τις περιπτώσεις η εφαρμογή θα πρέπει να είναι εύχρηστη, επιτρέποντας στους χρήστες να έχουν γρήγορη πρόσβαση στις πληροφορίες που χρειάζονται και να εμβαθύνουν σε περισσότερες λεπτομέρειες ανάλογα με τις ανάγκες τους.
- **Διεπαφές γραμμής εντολών (Command-Line Interfaces - CLIs)**: Οι διεπαφές γραμμής εντολών επιτρέπουν στους χρήστες να αλληλεπιδρούν με μοντέλα MM μέσω εντολών που εισάγονται σε ένα τερματικό παράθυρο. Ένα από τα πλεονεκτήματα της χρήσης CLI είναι η ταχύτητα και η ευελιξία που προσφέρουν. Τα CLIs επιτρέπουν στους χρήστες να εκτελούν γρήγορα μια πρόβλεψη χρησιμοποιώντας μια απλή εντολή, χωρίς να χρειάζεται να περιηγηθούν σε μια γραφική διεπαφή, ενώ επιπλέον μπορούν εύκολα να ενσωματωθούν σε σενάρια και αυτοματοποιημένες ροές εργασίας, επιτρέποντας την εύκολη ενσωμάτωση με άλλα εργαλεία και διαδικασίες.
- **Εφαρμογές Αναφορών (Reporting Applications)**: Σε αυτή την κατηγορία ανήκουν διαδικτυακές εφαρμογές όπως τα Jupyter Notebooks και το Google Colab, που επιτρέπουν στους χρήστες να δημιουργούν αναφορές που περιλαμβάνουν τα αποτελέσματα των μοντέλων και την ανάλυσή τους. Ένα από τα κύρια πλεονεκτήματα τους είναι η ικανότητά τους να δημιουργούν διαδραστικές αναφορές που επιτρέπουν στους ενδιαφερόμενους να αλληλεπιδρούν με τα μοντέλα και τα δεδομένα. Για παράδειγμα, οι χρήστες μπορούν να αλλάξουν τις παραμέτρους εισόδου ενός μοντέλου και να δουν πώς αλλάζει η έξοδος. Επίσης, μπορούν να συμπεριλάβουν πλούσιες οπτικοποιήσεις οι οποίες βοηθούν στο να γίνουν τα αποτελέσματα πιο προσιτά στους ενδιαφερόμενους.

4.5 Συμπεράσματα

Σε αυτό το Κεφάλαιο παρουσιάστηκαν συνοπτικά τα προβλήματα που θεραπεύονται στην παρούσα Διατριβή καθώς και τα στάδια ανάπτυξης μοντέλων για την επίλυση αυτών των προβλημάτων. Πιο συγκεκριμένα, καλύπτονται τα στάδια ανάπτυξης μοντέλων MM, η αρχιτεκτονική των προτεινόμενων μοντέλων και η διαχείριση των δεδομένων, των μοντέλων και των αποτελεσμάτων. Το προτεινόμενο πλαίσιο μπορεί να χρησιμεύσει ως κατευθυντήρια γραμμή για την ανάπτυξη μοντέλων TN σε άλλους τομείς.

Η ποιότητα των δεδομένων έχει σημαντικό αντίκτυπο στην απόδοση των μοντέλων, επομένως η σημασία της διαχείρισης των δεδομένων στην ανάπτυξη μοντέλων MM είναι κομβική. Σε αυτό το πλαίσιο, παρουσιάστηκε μια αρχιτεκτονική τριών επιπέδων που περιλαμβάνει ένα επίπεδο που εστιάζει στη διαχείριση των δεδομένων, ένα ενδιάμεσο επίπεδο που αφορά στην ανάπτυξη των μοντέλων και ένα επίπεδο που επικεντρώνεται στο χειρισμό των αποτελεσμάτων

Οι μελλοντικές ερευνητικές κατευθύνσεις για την ανάπτυξη ευφυών μοντέλων στον τομέα της ενέργειας θα μπορούσαν να περιλαμβάνουν τη διερεύνηση νέων αλγορίθμων MM για διαφορετικά προβλήματα διαχείρισης ενέργειας και ενεργειακής αποδοτικότητας. Χαρακτηριστικά προβλήματα που θα μπορούσαν να διερευνηθούν είναι η βελτιστοποίηση ενεργειακών συστημάτων, όπως εξειδικευμένα συστήματα αποθήκευσης ενέργειας, προγράμματα απόκρισης στη ζήτηση και διαχείριση έξυπνων δικτύων με αλγορίθμους ενισχυτικής μάθησης. Επιπλέον, η έρευνα μπορεί να επικεντρωθεί στη βελτίωση της ερμηνευσιμότητας και της επεξηγηματικότητας των μοντέλων MM, η οποία είναι πολύ σημαντική για την οικοδόμηση εμπιστοσύνης των ενδιαφερόμενων προς τα μοντέλα.

Συμπερασματικά, η ανάπτυξη μοντέλων TN για προβλήματα που σχετίζονται με την ενέργεια είναι ένας ταχέως εξελισσόμενος τομέας και το προτεινόμενο πλαίσιο χρησιμεύει ως σημείο εκκίνησης για την ανάπτυξη τέτοιων μοντέλων. Συνεπώς, αναμένεται ότι η συνεχής έρευνα στον τομέα αυτό θα οδηγήσει σε νέες γνώσεις και καινοτομίες που θα επιτρέψουν την αποτελεσματικότερη και αποδοτικότερη διαχείριση της ενέργειας μέσα από ευφυείς εφαρμογές με επίκεντρο το χρήστη.

Βιβλιογραφία

- Abdalla, A. N., Nazir, M. S., Tao, H., Cao, S., Ji, R., Jiang, M., and Yao, L. (2021). Integration of energy storage system and renewable energy sources based on artificial intelligence: An overview. *Journal of Energy Storage*, 40:102811.
- Ahmad, T., Zhang, D., Huang, C., Zhang, H., Dai, N., Song, Y., and Chen, H. (2021). Artificial intelligence in sustainable energy industry: Status quo, challenges and opportunities. *Journal of Cleaner Production*, 289:125834.
- Ahmad, T., Zhu, H., Zhang, D., Tariq, R., Bassam, A., Ullah, F., AlGhamdi, A. S., and Alshamrani, S. S. (2022). Energetics systems and artificial intelligence: applications of industry 4.0. *Energy Reports*, 8:334–361.
- Buitinck, L., Louppe, G., Blondel, M., Pedregosa, F., Mueller, A., Grisel, O., Niculae, V., Prettenhofer, P., Gramfort, A., Grobler, J., Layton, R., VanderPlas, J., Joly, A., Holt, B., and Varoquaux, G. (2013). API design for machine learning software: experiences from the scikit-learn project. In *ECML PKDD Workshop: Languages for Data Mining and Machine Learning*, pages 108–122.
- Chen, T. and Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '16, pages 785–794, New York, NY, USA. ACM.
- Chollet, F. et al. (2015). Keras. <https://keras.io>.
- Franzò, S., Frattini, F., Cagno, E., and Trianni, A. (2019). A multi-stakeholder analysis of the economic efficiency of industrial energy efficiency policies: Empirical evidence from ten years of the italian white certificate scheme. *Applied energy*, 240:424–435.
- Friedman, A. L. and Miles, S. (2006). *Stakeholders: Theory and practice*. OUP oxford.
- Hu, J. and Vasilakos, A. V. (2016). Energy big data analytics and security: challenges and opportunities. *IEEE Transactions on Smart Grid*, 7(5):2423–2436.
- Linder, L., Vionnet, D., Bacher, J.-P., and Hennebert, J. (2017). Big building data—a big data platform for smart buildings. *Energy Procedia*, 122:589–594.
- Liu, P., Zhou, Y., Zhou, D. K., and Xue, L. (2017). Energy performance contract models for the diffusion of green-manufacturing technologies in china: A stakeholder analysis from smes' perspective. *Energy Policy*, 106:59–67.
- Marinakos, V., Doukas, H., Tsapelas, J., Mouzakitis, S., Sicilia, Á., Madrazo, L., and Sgouridis, S. (2020). From big data to smart energy services: An application for intelligent energy management. *Future Generation Computer Systems*, 110:572–586.
- Martin, N. and Rice, J. (2015). Improving australia's renewable energy project policy and planning: A multiple stakeholder analysis. *Energy Policy*, 84:128–141.
- Mehmood, M. U., Chun, D., Han, H., Jeon, G., Chen, K., et al. (2019). A review of the applications of artificial intelligence and big data to buildings for energy-efficiency and a comfortable indoor living environment. *Energy and Buildings*, 202:109383.
- Nasr, A. K., Kashan, M. K., Maleki, A., Jafari, N., and Hashemi, H. (2020). Assessment of barriers to renewable energy development using stakeholders approach. *Entrepreneurship and Sustainability Issues*, 7(3):2526.
- Nastasi, B., Manfren, M., and Noussan, M. (2020). Open data and energy analytics.

- Obitko, M., Jirkovský, V., and Bezdíček, J. (2013). Big data challenges in industrial automation. In *Industrial Applications of Holonic and Multi-Agent Systems: 6th International Conference, HoloMAS 2013, Prague, Czech Republic, August 26-28, 2013. Proceedings*, pages 305–316. Springer.
- Papadis, E. and Tsatsaronis, G. (2020). Challenges in the decarbonization of the energy sector. *Energy*, 205:118025.
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin, Z., Gimelshein, N., Antiga, L., Desmaison, A., Kopf, A., Yang, E., DeVito, Z., Raison, M., Tejani, A., Chilamkurthy, S., Steiner, B., Fang, L., Bai, J., and Chintala, S. (2019). Pytorch: An imperative style, high-performance deep learning library. In *Advances in Neural Information Processing Systems 32*, pages 8024–8035. Curran Associates, Inc.
- Sarmas, E., Dimitropoulos, N., Marinakis, V., Mylona, Z., and Doukas, H. (2022a). Transfer learning strategies for solar power forecasting under data scarcity. *Scientific Reports*, 12(1):14643.
- Sarmas, E., Dimitropoulos, N., Stropoulos, S., Mylona, Z., Marinakis, V., Giannadakis, A., Romaios, A., and Doukas, H. (2022b). A web-based building automation and control service. In *2022 13th International Conference on Information, Intelligence, Systems & Applications (IISA)*, pages 1–6. IEEE.
- Sarmas, E., Spiliotis, E., Dimitropoulos, N., Marinakis, V., and Doukas, H. (2023). Estimating the energy savings of energy efficiency actions with ensemble machine learning models. *Applied Sciences*, 13(4):2749.
- Sarmas, E., Spiliotis, E., Marinakis, V., Koutselis, T., and Doukas, H. (2022c). A meta-learning classification model for supporting decisions on energy efficiency investments. *Energy and Buildings*, 258:111836.
- Sarmas, E., Spiliotis, E., Marinakis, V., Tzanes, G., Kaldellis, J. K., and Doukas, H. (2022d). ML-based energy management of water pumping systems for the application of peak shaving in small-scale islands. *Sustainable Cities and Society*, 82:103873.
- Sarmas, E., Stropoulos, S., Marinakis, V., Santori, F., Bucarelli, M. A., and Doukas, H. (2022e). An incremental learning framework for photovoltaic production and load forecasting in energy microgrids. *Electronics*, 11(23):3962.
- Widya Yudha, S. and Tjahjono, B. (2019). Stakeholder mapping and analysis of the renewable energy industry in indonesia. *Energies*, 12(4):602.

Κεφάλαιο 5

Μοντέλο Βαθιάς Μάθησης για την Πρόβλεψη Παραγωγής Φ/B Συστημάτων

5.1 Εισαγωγή

Στο κεφάλαιο αυτό παρουσιάζεται μια ολοκληρωμένη μέθοδος για τη βραχυπρόθεσμη πρόβλεψη της παραγωγής Φ/B. Η μέθοδος που αναπτύχθηκε εισάγει τέσσερα μοντέλα μάθησης βαθιάς αρχιτεκτονικής που μπορούν να προβλέψουν με ακρίβεια τη Φ/B παραγωγή την επόμενη ώρα. Οι προβλέψεις αυτών των μοντέλων χρησιμεύουν ως βάση ενός μοντέλου μετα-μάθησης, το οποίο έχει ως αποστολή να συνδυάζει βέλτιστα αυτές τις προβλέψεις, λαμβάνοντας υπόψη πρόσθετα εξωτερικά χαρακτηριστικά ως είσοδο, όπως καιρικές και εποχιακές μεταβλητές. Το μοντέλο μετα-μάθησης συνδυάζει τις προβλέψεις βάσης εκμεταλλευόμενο τα πλεονεκτήματα κάθε βασικού μοντέλου, βελτιώνοντας τη συνολική ακρίβεια και τη γενίκευση της προτεινόμενης λύσης. Επίσης, η μέθοδος που παρουσιάζεται είναι ανεξάρτητη από καιρικές προβλέψεις, υπό την έννοια ότι τα αξιοποιούμενα χαρακτηριστικά του καιρού αναφέρονται σε προηγούμενα χρονικά βήματα, με αποτέλεσμα να είναι πιο αξιόπιστη και γρήγορη στην ανάπτυξη και εφαρμογή.

Η ηλιακή Φ/B ηλεκτροπαραγωγή μπορεί να οριστεί ως η μετατροπή της ηλιακής ενέργειας σε ηλεκτρική χρησιμοποιώντας τεχνολογίες ηλιακών συλλεκτών. Οι τεχνολογίες αυτές παρέχουν μια καθαρή, ανθόρυβη και χαμηλού κόστους μορφή ηλεκτρικής ενέργειας μειώνοντας το αποτύπωμα άνθρακα και εξοικονομώντας κόστος (Olabi and Abdelkareem, 2022; Lee and Shepley, 2020; Jain et al., 2022). Η παραγωγή ενέργειας από Φ/B έχει σημειώσει αύξηση 22% τα τελευταία χρόνια, γεγονός που την καθιστά τη δεύτερη μεγαλύτερη απόλυτη αύξηση στην παραγωγή ενέργειας από ανανεώσιμες πηγές μετά την αιολική (Reindl and Palm, 2021). Ωστόσο, η λειτουργία των Φ/B συστημάτων μπορεί να αποτελέσει πρόκληση λόγω της μεγάλης μεταβλητότητας της παραγωγής που προκύπτει από τη συσχέτισή της με τις καιρικές συνθήκες, όπως η ηλιακή ακτινοβολία και η θερμοκρασία (Wan et al., 2015). Αυτή η μεταβλητότητα μπορεί να δημιουργήσει δυσκολίες στη διαχείριση του δικτύου καθώς αυξάνεται το ποσοστό διείσδυσης της ηλιακής ενέργειας (Antonanzas et al., 2016), επηρεάζοντας τις τιμές της ηλεκτρικής ενέργειας, τη συνολική αποτελεσματικότητα των αγορών ενέργειας και το κόστος λειτουργίας των ενεργειακών συστημάτων (Maity and Rao, 2010; Gürtler and Paulsen, 2018; Ahmed et al., 2020). Η βραχυπρόθεσμη πρόβλεψη της Φ/B παραγωγής (δηλ. η παροχή εκτιμήσεων σχετικά με την αναμενόμενη παραγωγή για την επόμενη ώρα ή ώρες της ημέρας) είναι κρίσιμη για διάφορους λόγους. Οι ακριβείς προβλέψεις βοηθούν στη βέλτιστη οικονομική κατανομή του φορτίου, με στόχο τη μείωση του κόστους παραγωγής ηλεκτρικής ενέργειας (Wen et al., 2019; Tascikaraoglu et al., 2014). Σε μικρότερη κλίμακα, η βραχυπρόθεσμη πρόβλεψη είναι επίσης σημαντική για την αποτελεσματική διαχείριση των έξυπνων δικτύων και των μικροδικτύων, με την κατάρτιση αξιόπιστων σχεδίων κατανομής

για τα συστήματα αποθήκευσης ενέργειας (Romaní et al., 2018), τη βελτιστοποίηση των διαδικασιών μετατόπισης φορτίου (Tassenoy et al., 2022), τη μείωση του ενεργειακού κόστους (Wu et al., 2022), τη διαχείριση των εφεδρειών (Vu and Chung, 2022) και την προληπτική διατήρηση της απόδοσης των Φ/Β συστημάτων (De Benedetti et al., 2018). Ως αποτέλεσμα, η ανάπτυξη ακριβών μοντέλων βραχυπρόθεσμης πρόβλεψης Φ/Β παραγωγής έχει γίνει ένας τομέας εντατικής έρευνας παγκοσμίως την τελευταία δεκαετία (Mellit and Pavan, 2010; Mellit et al., 2021).

Κοινό χαρακτηριστικό της πλειονότητας των βραχυπρόθεσμων μοντέλων πρόβλεψης Φ/Β παραγωγής που προτείνονται στη βιβλιογραφία είναι ότι εξαρτώνται από αριθμητικές μετεωρολογικές προβλέψεις (**Numerical Weather Predictions - NWP**s) (Bacher et al., 2009). Οι προβλέψεις αυτές μπορούν είτε να εκτιμηθούν με τη χρήση εξελιγμένων μοντέλων πρόβλεψης ακτινοβολίας είτε να αγοραστούν απευθείας από μετεωρολογικές υπηρεσίες (Mathiesen and Kleissl, 2011). Στην πρώτη περίπτωση, το συνολικό υπολογιστικό κόστος για την ανάπτυξη και την εκτέλεση του μοντέλου πρόβλεψης Φ/Β παραγωγής αυξάνεται σημαντικά. Ακόμη και αν η αυξημένη προσπάθεια και η πολυπλοκότητα δεν αποτελούν σημαντικά ζητήματα για τους παραγωγούς ηλεκτρικής ενέργειας μεγάλης κλίμακας (π.χ. συσσωρευτές), δεν ισχύει απαραίτητα το ίδιο για τους ιδιοκτήτες Φ/Β μικρής κλίμακας (π.χ. διαχειριστές Φ/Β συστημάτων σε στέγες), οι οποίοι αναζητούν ακριβείς προβλέψεις χωρίς την ανάγκη σύνδεσης με μετεωρολογικές υπηρεσίες. Στην τελευταία περίπτωση, όπου η ακρίβεια του μοντέλου πρόβλεψης εξαρτάται από εξωτερικές υπηρεσίες, ενδέχεται να προκύψουν διάφοροι κίνδυνοι (π.χ. λόγω προβλημάτων επικοινωνίας και πιθανών αλλαγών στη μορφή ή στις λεπτομέρειες των παρεχόμενων NWP's; Mellit et al., 2014). Όπως και να έχει, και οι δύο προσεγγίσεις βασίζονται σε NWP's που, ακόμη και μέσα σε σύντομες χρονικές περιόδους, μπορεί να διαφέρουν σημαντικά, ενώ είναι επίσης δύσκολο να εκτιμηθούν με ακρίβεια στην πράξη σε τοπικό επίπεδο (Chaturvedi and Isha, 2016). Με βάση τα παραπάνω, η ανάπτυξη βραχυπρόθεσμων μοντέλων πρόβλεψης Φ/Β παραγωγής που απαιτούν ως είσοδο μόνο πληροφορίες σχετικά με την παρακολουθούμενη παραγόμενη ενέργεια και τις καιρικές συνθήκες καθίστανται ιδιαίτερα ελκυστικά (González Ordiano et al., 2017), αποτελώντας μια πιο γενικευμένη, αξιόπιστη και ταχύτερη στην εφαρμογή και εκτέλεση εναλλακτική λύση για τους διαχειριστές ενεργειακών συστημάτων, τους εμπόρους ενέργειας, τους διαχειριστές ενέργειας και πολλούς άλλους ενδιαφερόμενους.

Παρόλα αυτά, ακόμη και αν η βραχυπρόθεσμη πρόβλεψη Φ/Β παραγωγής ενέργειας περιοριζόταν σε μοντέλα ανεξάρτητα από NWP (**NWP-independent**), θα εξακολουθούσαν να υπάρχουν πολυάριθμοι αλγόριθμοι για να επιλέξει κανείς για την ανάπτυξη μιας μεθόδου πρόβλεψης (Ahmed et al., 2020). Στη βιβλιογραφία των προβλέψεων, ωστόσο, είναι γενικά αποδεκτό ότι κανένα μοντέλο δεν μπορεί να ξεπεράσει σταθερά όλα τα διαθέσιμα μοντέλα (για μια εγκυκλοπαιδική επισκόπηση σχετικά με τους συνδυασμούς προβλέψεων ανατρέξτε στην ενότητα 2.6 του Petropoulos et al., 2022) και η πρόβλεψη της Φ/Β παραγωγής δεν αποτελεί εξαίρεση (Sobri et al., 2018). Στο πλαίσιο αυτό, οι υπεύθυνοι για την πρόβλεψη συνδυάζουν τις προβλέψεις πολλαπλών μοντέλων, καθένα από τα οποία κάνει διαφορετικές παραδοχές και έχει διαφορετική δομή, με στόχο την παροχή ακριβέστερων προβλέψεων συνολικά. Για παράδειγμα, ορισμένα μοντέλα μπορεί να αποδίδουν καλύτερα κατά τις ώρες αιχμής της παραγωγής, άλλα μπορεί να είναι πιο ακριβή κατά τις λιγότερο παραγωγικές ώρες, ενώ άλλα μπορεί να είναι πιο ανθεκτικά σε ασυνήθιστες αλλαγές στις καιρικές συνθήκες. Η βασική ιδέα πίσω από τους συνδυασμούς προβλέψεων είναι ότι τα σφάλματα των διαφορετικών μοντέλων θα αλληλοεξουδετερώνονται, οδηγώντας έτσι σε πιο ακριβή αποτελέσματα από τις μεμονωμένες προσεγγίσεις πρόβλεψης. Έχουν προταθεί κυριολεκτικά εκατοντάδες σχήματα για το συνδυασμό προβλέψεων, που κυμαίνονται από απλούς συνδυασμούς (π.χ. μέσος όρος, διάμεσος ή τρόπος των προβλέψεων) έως πιο εξελιγμένους (π.χ. με βάση τα σφάλματα πρόβλεψης εντός και εκτός δείγματος, τα κριτήρια πληροφoρίας, τη θεωρία πιθανοτήτων κατά Bayes και τις μεθόδους γραμμικής ή μη γραμμικής παλινδρόμησης). Πιο πρόσφατα, η μετάδοση (**meta-learning**) έχει προσελκύσει την προσοχή των ερευνητών, καθώς επιτρέπει τον συνδυασμό να πραγματοποιείται υπό την αίρεση ενός συνόλου εξωτερικών μεταβλητών

(π.χ. ώρα της ημέρας ή καιρικές συνθήκες) που μπορεί να επηρεάζουν την απόδοση των βασικών μοντέλων πρόβλεψης και, επομένως, τα βέλτιστα βάρη για τον συνδυασμό των αντίστοιχων προβλέψεων. Ως παράδειγμα, οι [Montero-Manso et al. \(2020\)](#) χρησιμοποίησαν τη μετα-μάθηση για την ανάθεση βαρών στις προβλέψεις εννέα διαφορετικών βασικών μοντέλων πρόβλεψης χρησιμοποιώντας χαρακτηριστικά χρονοσειρών ως είσοδο, επιτυγχάνοντας τη δεύτερη θέση στο διαγωνισμό πρόβλεψης M4 ([Makridakis et al., 2020](#)). Σε αυτό το κεφάλαιο εξετάζουμε μια τέτοια μέθοδο για το συνδυασμό των προβλέψεων διαφόρων μοντέλων BM, τα οποία θεωρούνται σήμερα πολύ αποτελεσματικά για τη βραχυπρόθεσμη πρόβλεψη Φ/B παραγωγής ενέργειας ([Ahmed et al., 2020](#)). Ωστόσο, σε αντίθεση με τις περισσότερες από τις υπάρχουσες μεθόδους μετα-μάθησης, υπολογίζουμε απευθείας τις “βέλτιστες” προβλέψεις χρησιμοποιώντας μια προσέγγιση βασισμένη σε μοντέλο MM με βάση την παλινδρόμηση, αντί να εκτιμήσουμε τα “βέλτιστα” βάρη του συνδυασμού, τα οποία ουσιαστικά θα πρότειναν έναν γραμμικό συνδυασμό των βασικών προβλέψεων.

Η συμβολή της μελέτης που παρουσιάζεται στο κεφάλαιο αυτό συνοψίζεται ως εξής:

- Αναπτύσσουμε και βελτιστοποιούμε τέσσερα μοντέλα TNΔ μακράς βραχυπρόθεσμης μνήμης (**Long Short-Term Memory - LSTM**) διαφορετικής αρχιτεκτονικής που μπορούν να προβλέψουν με ακρίβεια την παραγωγή Φ/B για την επόμενη ώρα (ντετερμινιστικές προβλέψεις μίας ώρας). Δεδομένου ότι ένας βασικός στόχος της μελέτης μας είναι να παράσχουμε ένα γενικευμένο πλαίσιο πρόβλεψης που μπορεί να διευκολύνει τον προγραμματισμό σε εφαρμογές έξυπνων δικτύων και μικροδικτύων, τα μοντέλα έχουν ως αποστολή να παράγουν ντετερμινιστικές (σημειακές) προβλέψεις αντί για πιθανοτικές, οι οποίες είναι πιο σχετικές σε προβλήματα βελτιστοποίησης σε επίπεδο δικτύου.
- Επικεντρωνόμαστε σε NWP-independent προσεγγίσεις πρόβλεψης Φ/B , καθορίζοντας ανάλογα τα χαρακτηριστικά που θα χρησιμοποιηθούν ως είσοδος στα μοντέλα LSTM. Ως αποτέλεσμα, τα μοντέλα που κατασκευάζονται είναι ταχύτερα στην εκτέλεση και πιο αξιόπιστα σε σύγκριση με τις μεθόδους πρόβλεψης που εξαρτώνται από NWP.
- Προτείνουμε τη χρήση ενός μοντέλου μηχανών διανυσμάτων υποστήριξης για παλινδρόμηση (**Support Vector Regressor - SVR**) που χρησιμοποιεί τεχνικές μετα-μάθησης για τη βέλτιστη ανάμειξη των προβλέψεων των τεσσάρων μοντέλων LSTM. Η διαδικασία ανάμειξης εξαρτάται από εξωτερικές μεταβλητές που επηρεάζουν την απόδοση των βασικών μοντέλων πρόβλεψης. Επιπλέον, σε αντίθεση με τις περισσότερες προσεγγίσεις μετα-μάθησης, οι τελικές προβλέψεις υπολογίζονται απευθείας από τον μετα-μαθητή χρησιμοποιώντας μια μέθοδο μη γραμμικής παλινδρόμησης αντί να είναι το προϊόν ενός σταθμισμένου, γραμμικού συνδυασμού των βασικών προβλέψεων.
- Αξιολογούμε την ακρίβεια πρόβλεψης του μετα-μαθητή χρησιμοποιώντας αντιπροσωπευτικά σημεία αναφοράς και ένα σύνολο δεδομένων που περιλαμβάνει τρία Φ/B συστήματα σε στέγες που βρίσκονται στην Πορτογαλία.

Το κεφάλαιο αυτό οργανώνεται ως εξής. Η ενότητα 5.2 παρέχει τη διατύπωση του προβλήματος, καθώς και μια σύντομη ανασκόπηση σχετικά με τη βραχυπρόθεσμη πρόβλεψη της Φ/B παραγωγής. Στην ενότητα 5.3 περιγράφονται τα βασικά μοντέλα πρόβλεψης και η προτεινόμενη μέθοδος μετα-μάθησης. Η ενότητα 5.4 παρουσιάζει μια εμπειρική αξιολόγηση της προτεινόμενης μεθόδου, παρέχοντας λεπτομέρειες σχετικά με τα δεδομένα που χρησιμοποιήθηκαν, τις μετρικές και τα κριτήρια που εξετάστηκαν, καθώς και μια σύνοψη των αποτελεσμάτων μας. Στην ενότητα 5.5 παρέχονται τα συμπεράσματα του κεφαλαίου.

5.2 Αναλυτική Διατύπωση Προβλήματος

Σε αυτή την ενότητα παρουσιάζεται η σχετική έρευνα που έχει διεξαχθεί στο πεδίο της πρόβλεψης της παραγωγής ενέργειας των Φ/B συστημάτων. Το πρώτο μέρος της ενότητας

παρέχει μια επισκόπηση σχετικά με τον τρόπο με τον οποίο η πρόβλεψη της Φ/B παραγωγής ενέργειας μπορεί να διακριθεί σε ορισμένες υποκατηγορίες με βάση ορισμένα κριτήρια, δηλαδή τον εξεταζόμενο ορίζοντα πρόβλεψης, το είδος των μεθόδων που χρησιμοποιούνται και τις μεταβλητές που χρησιμοποιούνται από τα μοντέλα πρόβλεψης ως είσοδο. Το δεύτερο μέρος επικεντρώνεται στις μεθόδους πρόβλεψης BM και εξετάζει διαφορετικές, ενδεικτικές προσεγγίσεις και υλοποιήσεις.

5.2.1 Επισκόπηση και Κατηγοριοποίηση

Οι μέθοδοι πρόβλεψης Φ/B παραγωγής ενέργειας μπορούν να κατηγοριοποιηθούν με βάση διάφορα κριτήρια, όπως ο ορίζοντας πρόβλεψης (πολύ βραχυπρόθεσμος, βραχυπρόθεσμος, μεσοπρόθεσμος, μακροπρόθεσμος), η φύση της μεθόδου που χρησιμοποιείται (φυσική, με βάση τα δεδομένα, MM/BM) και η εξάρτησή τους από NWP (εξαρτημένη, ανεξάρτητη).

Όσον αφορά τον ορίζοντα πρόβλεψης, ο οποίος ορίζεται ως το μελλοντικό χρονικό διάστημα για το οποίο η μέθοδος παράγει προβλέψεις, στη βιβλιογραφία έχουν προταθεί διάφορες κατηγοριοποιήσεις. Η πιο ευρέως υιοθετημένη κατηγοριοποίηση με βάση τον ορίζοντα περιλαμβάνει την ταξινόμηση των μεθόδων πρόβλεψης σε βραχυπρόθεσμες, μεσοπρόθεσμες και μακροπρόθεσμες (Das et al., 2018). Ωστόσο, σύμφωνα με τους Gupta and Singh (2021) και Ahmed et al. (2020), μπορεί να θεωρηθεί μια επιπλέον κατηγορία πολύ βραχυπρόθεσμων μεθόδων πρόβλεψης Φ/B παραγωγής ενέργειας, που οδηγεί στους ακόλουθους ορισμούς:

- Πολύ βραχυπρόθεσμες μέθοδοι πρόβλεψης, που παρέχουν προβλέψεις από μερικά δευτερόλεπτα έως αρκετά λεπτά μπροστά. Τέτοιες μέθοδοι αξιοποιούνται για την ενεργειακή διαχείριση των έξυπνων δικτύων, π.χ. για την άμεση και αποτελεσματική αντιστάθμιση της ενεργού και άεργου ισχύος (Wan et al., 2015; Aslam et al., 2021).
- Μέθοδοι βραχυπρόθεσμης πρόβλεψης, που παρέχουν προβλέψεις από 1 ώρα έως 1 εβδομάδα. Τέτοιες μέθοδοι είναι κατάλληλες για εφαρμογές σε επίπεδο έξυπνου δικτύου, εξασφαλίζοντας τη δέσμευση μονάδων ισχύος, τον προγραμματισμό και την κατανομή (Das et al., 2018), όντας επίσης χρήσιμες για τη δυναμική τιμολόγηση και την προγνωστική συντήρηση (Spiliotis et al., 2018).
- Μέθοδοι μεσοπρόθεσμης πρόβλεψης, οι οποίες παρέχουν προβλέψεις από 1 μήνα έως 1 έτος στο μέλλον. Τέτοιες μέθοδοι χρησιμοποιούνται συνήθως για το βέλτιστο σχεδιασμό του δικτύου και το χρονοδιάγραμμα συντήρησης (Ahmed et al., 2020).
- Μακροπρόθεσμες μέθοδοι πρόβλεψης, οι οποίες παρέχουν προβλέψεις από 1 έτος έως αρκετά έτη μπροστά. Τέτοιες μέθοδοι μπορούν να είναι επωφελείς στη μεταφορά, διανομή και αποθήκευση ενέργειας (Eom et al., 2020).

Ένας πρόσθετος παράγοντας διαφοροποίησης των προσεγγίσεων πρόβλεψης Φ/B παραγωγής ενέργειας είναι η φύση της μεθόδου ή του αλγορίθμου που χρησιμοποιείται για τη δημιουργία προβλέψεων και η εξάρτησή της από πραγματικές μετρήσεις. Γενικά, υπάρχουν δύο γενικές κατηγορίες μεθόδων: φυσικές μέθοδοι και μέθοδοι που βασίζονται σε δεδομένα. Οι φυσικές μέθοδοι βασίζονται σε λεπτομερή μετεωρολογικά δεδομένα και βασικές παραμέτρους σχεδιασμού των Φ/B πλαισίων και χρησιμοποιούν φυσικές εξισώσεις για την πρόβλεψη της Φ/B παραγωγής ενέργειας (Mayer and Gróf, 2021), όπως έδειξαν με επιτυχία οι Zhao et al. (2016), Zameer et al. (2017) και Lei et al. (2009). Αντίθετα, οι μέθοδοι που βασίζονται σε δεδομένα χρησιμοποιούν τεχνικές ανάλυσης δεδομένων για τον εντοπισμό μοτίβων και συσχετίσεων στα δεδομένα καιρού και παραγωγής Φ/B και προβλέπουν αντίστοιχα την παραγωγή των Φ/B (Ahmed et al., 2020). Οι φυσικές μέθοδοι θεωρούνται καταλληλότερες για μακροπρόθεσμες προβλέψεις, ενώ οι μέθοδοι που βασίζονται σε δεδομένα είναι καταλληλότερες για βραχυπρόθεσμες προβλέψεις. Οι καθοδηγούμενες από δεδομένα μέθοδοι μπορούν επίσης να διαχωριστούν σε αμιγώς στατιστικές και σε μεθόδους MM. Ένα ενδεικτικό παράδειγμα

στατιστικών μεθόδων παρουσιάζεται από τους [Sharadga et al. \(2020\)](#) οι οποίοι χρησιμοποίησαν πολλαπλά μοντέλων πρόβλεψης χρονοσειρών, όπως ARMA, ARIMA και SARIMA, για την πρόβλεψη της παραγωγής Φ/Β. Πιο πρόσφατα, οι ? συνέκριναν την ακρίβεια των μοντέλων SARIMAX και Prophet στην πρόβλεψη της ηλιακής ακτινοβολίας με εκείνη διαφόρων μοντέλων που βασίζονται σε NN, καταλήγοντας στο συμπέρασμα ότι τα πρώτα είναι πιο κατάλληλα για μεγαλύτερους ορίζοντες πρόβλεψης, ενώ τα δεύτερα για μικρότερους. Παρομοίως, οι [Akhter et al. \(2019\)](#) παρουσίασαν τα πλεονεκτήματα ενός ενδεικτικού συνόλου μοντέλων MM, όπως τα NN, τα δέντρα απόφασης, τα τυχαία δάση, το gradient boosting και τα SVR. Πρέπει να σημειωθεί ότι εκτός από τις φυσικές μεθόδους και τις μεθόδους που βασίζονται σε δεδομένα, υπάρχουν και υβριδικές μέθοδοι που συνδυάζουν χαρακτηριστικά των δύο προσεγγίσεων. Μια σύγκριση των φυσικών, των data-driven και των υβριδικών μεθόδων μπορεί να βρεθεί στην έρευνα των [Mayer \(2022\)](#).

Ένας άλλος παράγοντας που μπορεί να διακρίνει τις προσεγγίσεις πρόβλεψης είναι η εξάρτησή τους ή όχι από NWP. Εκτός από τις NWP-independent προσεγγίσεις που έχουν αναπτυχθεί με την πάροδο του χρόνου, καθώς και αυτή που προτείνουμε, υπάρχουν και μοντέλα που εξαρτώνται από NWP. Αυτά αξιοποιούν τις μετεωρολογικές προβλέψεις με στόχο τη βελτίωση της ακρίβειας πρόβλεψής τους, δεδομένου ότι η παραγωγή Φ/Β συνδέεται στενά με τις καιρικές συνθήκες. Τέτοιες μέθοδοι έχουν εξεταστεί, για παράδειγμα, από τους [Ogliari et al. \(2017\)](#) και [Dolara et al. \(2015\)](#) οι οποίοι χρησιμοποίησαν διάφορα μοντέλα NN, όπως τα φυσικά υβριδικά τεχνητά NN (PHANN), για την πρόβλεψη της ημέρας. Μια λεπτομερής σύγκριση των μεθόδων πρόβλεψης της Φ/Β παραγωγής ενέργειας που βασίζονται σε NWP έχει πραγματοποιηθεί από τους [Markovics and Mayer \(2022\)](#). Από την άλλη πλευρά, οι NWP-independent μέθοδοι δεν απαιτούν NWP ως χαρακτηριστικά εισόδου, με αποτέλεσμα να είναι ταχύτερες και ευκολότερες στην εφαρμογή, ενώ παραμένουν σχετικά ακριβείς για βραχυπρόθεσμη πρόβλεψη. Οι [Wang et al. \(2018a\)](#) προτείνουν μια εναλλακτική ορολογία για τη διάκριση αυτή, χρησιμοποιώντας τους όρους “έμμεση” και “άμεση” πρόβλεψη για τις εξαρτώμενες και τις ανεξάρτητες μεθόδους από NWP, αντίστοιχα.

5.2.2 Μέθοδοι Βαθιάς Μάθησης

Η BM είναι ένας ειδικός τομέας της MM που έχει επιδείξει κορυφαίες επιδόσεις στην πρόβλεψη της Φ/Β παραγωγής ενέργειας, ξεπερνώντας τα παραδοσιακά μοντέλα MM και τα στατιστικά μοντέλα. Αυτό οφείλεται στην ικανότητα των εν λόγω μοντέλων να ανακαλύπτουν περίπλοκες δομές σε δεδομένα υψηλής διάστασης ([Visser et al., 2022](#)) και να παράγουν πιο αξιόπιστα αποτελέσματα υπό συνθήκες αβεβαιότητας ([LeCun et al., 2015](#)). Με την πάροδο του χρόνου, τα μοντέλα BM έχουν γίνει πιο εξελιγμένα, αποτελούμενα από πολυεπίπεδους νευρώνες, επιτρέποντάς τους να αποτυπώνουν πιο αποτελεσματικά μη γραμμικές και πολύπλοκες σχέσεις μεταξύ των χαρακτηριστικών εισόδου και της εξόδου. Εκτός από την εξέλιξη του τύπου, του αριθμού και του συνδυασμού των μονάδων που χρησιμοποιούνται στις αρχιτεκτονικές BM, εξελίσσεται και ο τρόπος με τον οποίο τα μοντέλα BM μαθαίνουν. Για παράδειγμα, η εκμάθηση μεταφοράς και η περιορισμένη μακράς βραχυπρόθεσμη μνήμη συνδυάζονται με έναν νέο τρόπο για την πρόβλεψη της παραγωγής ενέργειας των νεοκατασκευασμένων Φ/Β συστημάτων (?). Επί του παρόντος, οι περισσότερες αρχιτεκτονικές BM περιλαμβάνουν CNNs, που χρησιμοποιούνται συνήθως για την ανίχνευση μοτίβων και δομών σε εικόνες, και RNNs, που χρησιμοποιούνται συνήθως για την πρόβλεψη δεδομένων με χρονικές σχέσεις. Επιπλέον, τα CNNs και τα RNNs συνδυάζονται συχνά με NNs πρόσθιας τροφοδότησης FFNNs, χρησιμοποιώντας στοιβές πυκνών στρωμάτων στις εξόδους τους, έτσι ώστε οι προβλέψεις των NNs να είναι κατάλληλα συντονισμένες.

Στον Πίνακα 5.1 παρουσιάζουμε ορισμένες πρόσφατες μεθόδους BM που χρησιμοποιούνται για τη βραχυπρόθεσμη πρόβλεψη της παραγωγής ενέργειας των Φ/Β συστημάτων. Όπως φαίνεται στην πρώτη στήλη του πίνακα, δεν υπάρχει κάποιο μοντέλο BM που να χρησιμοποιείται συστηματικά έναντι των άλλων. Παρόλα αυτά, οι πιο συνηθισμένες υλοποιήσεις βασίζονται σε RNNs, CNNs ή σε συνδυασμούς αυτών των δύο τύπων NNs. Όσον αφορά τα χαρακ-

τηριστικά εισόδου, πολλές μελέτες επικεντρώνονται στην άμεση πρόβλεψη, χρησιμοποιώντας ιστορικές (καθυστερημένες) τιμές της παραγωγής ενέργειας των Φ/Β σε συνδυασμό με ιστορικά δεδομένα καιρού, ενώ άλλες υλοποιούν έμμεσες μεθόδους πρόβλεψης που βασίζονται σε NWP. Σε γενικές γραμμές, όπως φαίνεται στην τρίτη στήλη του Πίνακα 5.1, οι NWP χρησιμοποιούνται συνήθως όταν ο ορίζοντας πρόβλεψης είναι μεγαλύτερος από μία ώρα, καθώς η απόδοση των NWP-independent μοντέλων μειώνεται δραστικά μετά από αυτό το σημείο. Στις επόμενες παραγράφους παρουσιάζονται ορισμένες από τις πιο υποσχόμενες μεθόδους ΝΔ, καθώς και τα πιο ενδιαφέροντα αποτελέσματα και γνώσεις που αποκτήθηκαν. Ωστόσο, η άμεση ποσοτική σύγκριση μεταξύ των διαφόρων μεθόδων πρόβλεψης είναι δύσκολη στην πράξη, καθώς η ακρίβειά τους εξαρτάται σε μεγάλο βαθμό από την ποιότητα και την ανάλυση των διαθέσιμων ιστορικών δεδομένων (Sarmas et al., 2022c).

Στη βιβλιογραφία για την πρόβλεψη της Φ/Β παραγωγής ενέργειας έχει γίνει εκτεταμένη χρήση των δικτύων LSTM, μιας ειδικής κατηγορίας RNN που ενσωματώνει μη γραμμικούς, εξαρτώμενους από τα δεδομένα ελέγχους στο κύτταρο RNN και εξασφαλίζει ότι η κλίση της αντικειμενικής συνάρτησης ως προς το σήμα κατάστασης ούτε εξαφανίζεται ούτε εκρήγνυται. Οι Wen et al. (2019) χρησιμοποίησαν ένα βαθύ μοντέλο LSTM για να προβλέψει την ωριαία παραγωγή Φ/Β σε βραχυπρόθεσμους ορίζοντες με βάση το πρόγραμμα, τον καιρό και τις μεταβλητές της χρονικής κλίμακας με στόχο τη βέλτιστη κατανομή του φορτίου ενός κοινοτικού μικροδικτύου. Τα αποτελέσματα έδειξαν ότι τα LSTM ήταν πιο ακριβή από άλλους αλγορίθμους MM. Οι Lee et al. (2018) πρότειναν ένα μοντέλο που συνδυάζει δίκτυα CNN και LSTM για την πρόβλεψη της ημερήσιας παραγωγής Φ/Β συστημάτων χρησιμοποιώντας παρατηρήσεις Φ/Β παραγωγής ενέργειας της προηγούμενης ημέρας. Ομοίως, οι Wang et al. (2019) πρότειναν ένα υβριδικό μοντέλο CNN και LSTM και συνέκριναν την απόδοσή του σε σχέση με τα αμιγή μοντέλα LSTM και CNN. Τα αποτελέσματα απέτυχαν να υποδείξουν μια ανώτερη προσέγγιση πρόβλεψης, καθώς το CNN αποδείχθηκε ακριβέστερο για μεγαλύτερους ορίζοντες πρόβλεψης, ενώ το LSTM για ορισμένες περιόδους πρόβλεψης. Οι ? χώρισαν την παραγωγή ενέργειας από Φ/Β σε τέσσερις κατηγορίες εργασιών (οικιακή, γεωργική, βιομηχανική και εμπορική) και πρότειναν ένα multitasking RNN με τη δυνατότητα μεταφοράς και επαναχρησιμοποίησης της μάθησης μεταξύ των εργασιών.

Μια άλλη κατηγορία μοντέλων BM που χρησιμοποιήθηκε πρόσφατα για τη βραχυπρόθεσμη πρόβλεψη της ενέργειας Φ/Β συστημάτων είναι τα GRUs. Οι GRU είναι παρόμοιες με τις LSTM, αλλά περιλαμβάνουν λιγότερες παραμέτρους, απαιτώντας έτσι λιγότερο χρόνο για την εκπαίδευσή τους (Wang et al., 2018b). Παρακινούμενοι από τις δυνατότητες των μοντέλων GRU, οι Abdel-Basset et al. (2021) και Rai et al. (2022) πρότειναν τρόπους για τον επανασχεδιασμό αυτών των δικτύων. Οι Abdel-Basset et al. (2021) τροποποίησαν το συμβατικό κύτταρο GRU χρησιμοποιώντας διευρυμένες συζεύξεις και υπολειμματικές συνδέσεις για να μπορέσει το δίκτυο να συλλάβει τις χωροχρονικές αναπαραστάσεις των Φ/Β δεδομένων και ανέφεραν βελτιώσεις στην ακρίβεια σε σχέση με τις υπάρχουσες υλοποιήσεις BM, συμπεριλαμβανομένων των μοντέλων CNN και LSTM των Wang et al. (2019), του μοντέλου LSTM των Sharadga et al. (2020) και του μοντέλου GRU των Lee and Kim (2021). Οι Rai et al. (2022) πρότειναν έναν αυτόματο κωδικοποιητή με βάση το GRU και συνέκριναν την απόδοσή του σε σχέση με τα μοντέλα LSTM, CNN και GRU, καθώς και με υβρίδια για την περίπτωση οριζόντων πρόβλεψης 24 ωρών, 48 ωρών και 15 ημερών, αναφέροντας ελπιδοφόρα αποτελέσματα.

Όσον αφορά τα CNNs, η δημοτικότητά τους στην πρόβλεψη της Φ/Β παραγωγής ενέργειας μπορεί να αποδοθεί κυρίως στην ικανότητά τους να επεξεργάζονται δεδομένα με χαρακτηριστικά τοπολογίας δικτύου και στην αποτελεσματικότητά τους να εξάγουν κρυφές δομές και εγγενή χαρακτηριστικά (Ahmed et al., 2020). Οι Zang et al. (2020) χρησιμοποίησαν δημοφιλείς αρχιτεκτονικές CNN, δηλαδή ResNet (residual network; He et al., 2016) και DenseNet (density convolutional network; Huang et al., 2017) για την πρόβλεψη της ημερήσιας παραγωγής Φ/Β ενέργειας και συνέκριναν τις επιδόσεις τους με στατιστικά, φυσικά, MM και τυποποιημένα μοντέλα CNN, αναφέροντας ενθαρρυντικά αποτελέσματα. Σε παρόμοια συμπεράσματα κατέληξαν και οι Aslam et al. (2021), οι οποίοι πραγματοποίησαν μια

εκτεταμένη συγκριτική μελέτη και διαπίστωσαν ότι τα μοντέλα BM και ιδιαίτερα τα υβριδικά μοντέλα BM επιτυγχάνουν ανώτερη ακρίβεια.

Τέλος, έχει αποδειχθεί ότι το *ensembling* πολλαπλών μοντέλων (συγκέντρωση των προβλέψεων πολλαπλών ανεξάρτητων βασικών μοντέλων πρόβλεψης) ήταν πολύ αποτελεσματικό για τη βραχυπρόθεσμη πρόβλεψη παραγωγής ενέργειας Φ/B συστημάτων σύμφωνα με την (Ahmed et al., 2020). Το *ensembling* μπορεί να αναφέρεται στο συνδυασμό διαφορετικών μοντέλων ή στο συνδυασμό διαφορετικών περιπτώσεων του ίδιου μοντέλου με διαφορετικές ρυθμίσεις παραμέτρων. Ορισμένες ενδεικτικές μελέτες που χρησιμοποιούν το *ensembling* μπορούν να βρεθούν στην έρευνα των Zhu et al. (2019), όπου χρησιμοποιείται ένα απλό μέσο *ensemble*, και στην έρευνα των Liu et al. (2019), όπου χρησιμοποιείται ένα σταθμισμένο μέσο μοντέλο *ensemble*. Εκτός από το *ensembling* με βάση τον μέσο όρο, ορισμένες μελέτες έχουν εξετάσει τη μετα-μάθηση για την πρόβλεψη της Φ/B παραγωγής ενέργειας. Η μετα-μάθηση αναφέρεται στη διαδικασία χρήσης ενός μοντέλου MM (ή BM) για την ανάμειξη των βασικών προβλέψεων αντί της χρήσης ενός συμβατικού τελεστή (π.χ. μέσος όρος, διάμεσος και τρόπος). Για παράδειγμα, οι Lateko et al. (2021) πρότειναν έναν μετα-μαθητή με βάση το RNN που συνδύαζε τις προβλέψεις πέντε βασικών μοντέλων. Παρομοίως, οι Eom et al. (2020) πρότειναν έναν μετα-μαθητή με βάση το CNN που επέλεγε χαρακτηριστικά και συνδύαζε τις προβλέψεις δύο στατιστικών μοντέλων και ενός LSTM.

Όπως αποδεικνύεται από τον μεγάλο αριθμό μελετών που παρουσιάζονται στον Πίνακα 5.1, η αύξηση των δεδομένων παραγωγής ηλεκτρικής ενέργειας από ηλιακούς συλλέκτες οδήγησε στην αναγνώριση των μοντέλων BM ως την πλέον κατάλληλη προσέγγιση για την πρόβλεψη της Φ/B παραγωγής ενέργειας. Ειδικά τα LSTMs μπορούν να αξιοποιηθούν για πολυμεταβλητές προβλέψεις, είναι ικανά να μαθαίνουν σύνθετα χαρακτηριστικά από διαδοχικά δεδομένα και μπορούν να παράγουν αποτελεσματικά προβλέψεις πολλαπλών βημάτων. Ωστόσο, όπως φαίνεται σε αυτή την ενότητα ανασκόπησης, οι τρέχουσες λύσεις δεν έχουν ακόμη εκμεταλλευτεί πλήρως τις δυνατότητες της BM και απαιτείται περαιτέρω έρευνα στον τομέα του συνδυασμού και της σύγκρισης διαφορετικών αρχιτεκτονικών BM για την περαιτέρω βελτίωση της ακρίβειας πρόβλεψης. Επίσης, ένας περιορισμένος αριθμός μελετών έχει επικεντρωθεί στη δημιουργία μοντέλων συνόλου με στόχο την αξιοποίηση του συνδυασμού διαφορετικών αρχιτεκτονικών BM.

5.3 Προτεινόμενο Μοντέλο

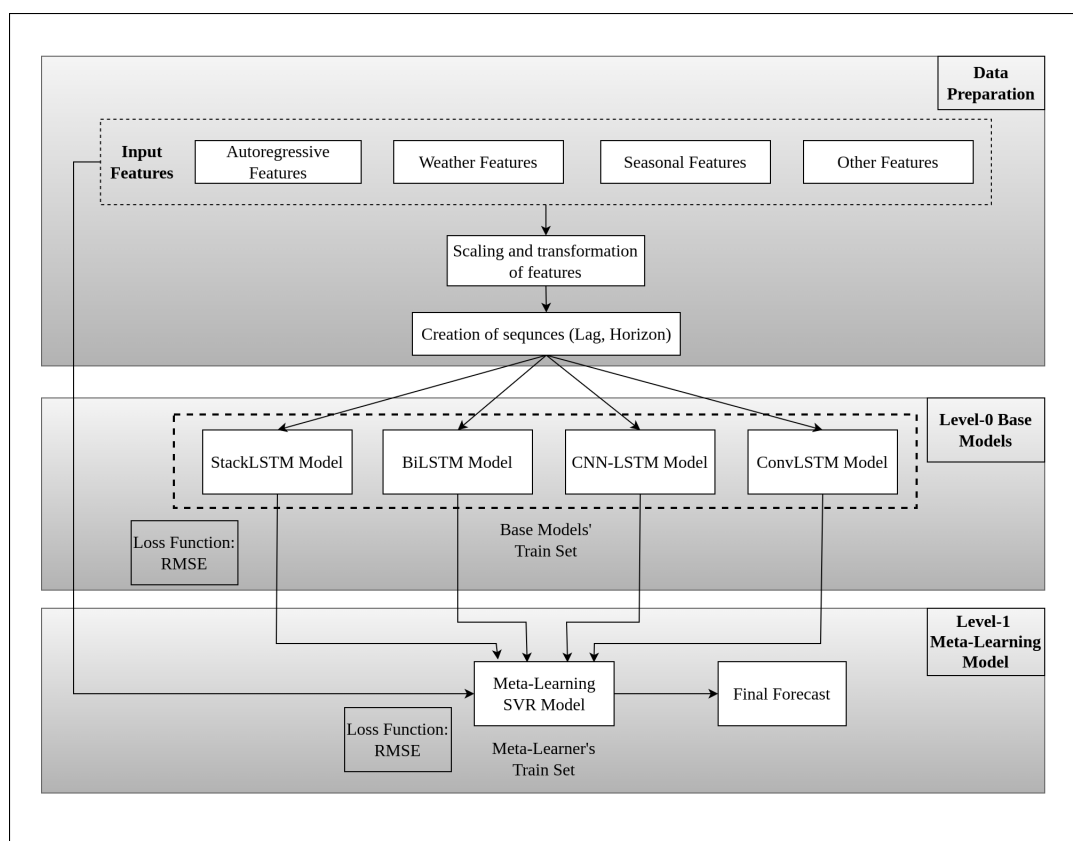
Σε αυτή την ενότητα παρουσιάζεται η προτεινόμενη μέθοδος. Αρχικά, παρουσιάζεται το συνολικό μεθοδολογικό πλαίσιο. Στη συνέχεια, παρέχεται λεπτομερής περιγραφή της μονάδας LSTM, καθώς αποτελεί το βασικό συστατικό όλων των αρχιτεκτονικών NNs που εξετάστηκαν για την ανάπτυξη των βασικών μοντέλων πρόβλεψης. Τέλος, περιγράφονται οι αρχιτεκτονικές των βασικών μοντέλων πρόβλεψης και του μετα-μαθητή.

5.3.1 Αρχιτεκτονική Μοντέλου

Η προτεινόμενη μέθοδος μετα-μάθησης (Meta) αποτελείται από τρεις επιμέρους φάσεις: προετοιμασία δεδομένων, εκπαίδευση των βασικών μοντέλων πρόβλεψης και εκπαίδευση του μετα-μαθητή. Η πρώτη φάση περιλαμβάνει ένα σύνολο ενεργειών που πρέπει να εκτελεστούν προκειμένου να συλλεχθούν τα ακατέργαστα δεδομένα και να μετατραπούν σε κατάλληλα μορφοποιημένες, δομημένες πληροφορίες που μπορούν να χρησιμοποιηθούν ως είσοδος, τόσο από τα βασικά μοντέλα πρόβλεψης όσο και από τον μετα-μαθητή. Η δεύτερη φάση περιλαμβάνει τη διαδικασία εκπαίδευσης των βασικών μοντέλων πρόβλεψης χρησιμοποιώντας τα επεξεργασμένα δεδομένα ως είσοδο και παράγοντας βασικές προβλέψεις (επίπεδο-0) ως έξοδο. Η τελική φάση αποτελείται από τη διαδικασία εκπαίδευσης του μετα-μαθητή που περιγράφεται στην ενότητα 5.3.4, ο οποίος λαμβάνει τις βασικές προβλέψεις μαζί με πρόσθετα χαρακτηριστικά ως είσοδο και παράγει τις τελικές (επίπεδο-1) προβλέψεις ως έξοδο. Αυτές οι φάσεις συνοψίζονται στο Σχήμα 5.1.

Πίνακας 5.1: Βιβλιογραφική ανασκόπηση μεθόδων ΒΜ για βραχυπρόθεσμες προβλέψεις παραγωγής Φ/B συστημάτων.

Model	Features	Forecasting Horizon	Measures	Source
NN - LSTM - XGB	Lagged PV Output - Forecasted global horizontal irradiance, temperature & relative humidity - Calendar Data	15-min - 1-hour - 1-day ahead	MAE - RMSE - R2	Khan et al. (2022)
AE - GRU	Lagged PV Output	1-hour ahead	MAE - MSE - R2	Rai et al. (2022)
NN - Gradient Boosting	Forecasted irradiance, temperature, cloud coverage & wind speed	1-week ahead	RMSE - MAE	Sarmas et al. (2022c)
PVNET (ConvGRU - BiLSTM)	Lagged PV Output - Lagged wind direction, diffuse horizontal radiation, global horizontal radiation, weather relative humidity, weather temperature - Current Phase Average	5-min ahead	MAE - MAPE - RMSE	Abdel-Basset et al. (2021)
RNN meta-learner, ANN, DNN, SVR, LSTM, CNN	Lagged PV Output, Lagged air temperature, relative humidity, average wind speed	1-day ahead	MRE, MAE, nRMSE, R2	Lateko et al. (2021)
LSTM - BiLSTM - GRU - BiGRU - CNN	Lagged PV Output	1-5-30-60-min ahead	COR - MAE - MAPE - RMSE	Mellit et al. (2021)
FFNN - GRU - LSTM	Lagged PV Inverter Output - Lagged global horizontal irradiance, ambient-temperature, absolute-air-pressure, wind direction, wind speed, relative-humidity	(1-6)-hour ahead	MAPE - NRMSE	Du Plessis et al. (2021)
RNN - LSTM	Lagged PV Output	1-day ahead	RMSE	Liu et al. (2021)
RNN - LSTM - Hybrid(CSO - GWO)	Lagged Solar Radiation	1-hour - 1-day - 1-week ahead	MSE - MAPE - DA	Jayalakshmi et al. (2021)
CNN	Lagged PV Output - NWP	1-day ahead	MAE - MASE - MHE - MSE - MSLE - NIA - UI - U2	Zang et al. (2020)
RF meta-learner, FFNNs	Lagged PV Output, Lagged solar irradiance, ambient temperature, wind speed	1-hour ahead	nRMSE, nMAE	Wang et al. (2020b)
LSTM - RNN	Lagged PV Output	1-day ahead	COR - MAE - RMSE	Wang et al. (2020a)
WPD - LSTM	Lagged PV Output (Decomposed) - Lagged Weather Data	1-hour ahead	MAPE - MBE - RMSE	Li et al. (2020)
LSTM	Lagged PV Output - Lagged cloud coverage, visibility, temperature, dew point, relative humidity, wind speed	1-hour ahead	MAE - MAPE - RMSE - R2	Mishra et al. (2020)
RBFNN - CSO	Historical Weather Data	1-day ahead	RMSE - STD	Yang et al. (2020)
NN - Bi-LSTM - ARMA - ARIMA - SARIMA	Lagged PV Output	1-2-hour ahead	R2 - RMSE	Sharadga et al. (2020)
GASVM	Lagged PV Output - Lagged solar irradiance, temperature	1-hour ahead	MAPE - RMSE	VanDeventer et al. (2019)
CNN	Lagged PV Output - Sky Images	15-min ahead	RMSE - Forecast Skill Index	Sun et al. (2019)
LSTM - CNN - CLSTM	Lagged PV Output - Lagged wind speed, weather temperature, weather relative humidity, global horizontal radiation, diffuse horizontal radiation, wind direction - Current Phase Average	1-day ahead	MAE - MAPE - RMSE	Wang et al. (2019)
Simple Averaging meta-learner, RNN mGRU, XGBoost, MLP	Lagged PV panel operating state parameters, Lagged Meteorological Parameters	1-day ahead	RMSE, MAE, MAPE	Zhu et al. (2019)
RNN - BPTT	Lagged PV Output	15-30-90-min ahead	MAE - RMSE - MAPE - R2	Li et al. (2019)
CNN(PVPNet) - LSTM	Lagged temperature, humidity, wind speed, horizontal radiation, diffuse horizontal radiation	1-day ahead	MAE - RMSE	Huang and Kuo (2019)
DRNN-LSTM	Lagged PV Output, Lagged wind speed, weather temperature, weather relative humidity, global horizontal radiation, diffuse horizontal radiation and wind direction	1-day ahead	RMSE - MAE - MAPE - PCC	Wen et al. (2019)
Weighted Averaging meta-learner, SVM, MLP, MARS	Lagged PV Output - Lagged temperature, solar radiation	1-day ahead	RMSE, MAE, MAPE	Liu et al. (2019)
GRNN - ELMNN - Elman.NN	Lagged temperature, humidity, wind speed, horizontal radiation, diffuse horizontal radiation	5-min ahead	MAPE	Liu et al. (2018)
NN(LM - LRNN)	Lagged solar irradiation	1-day ahead	RMSE	Rodriguez et al. (2018)
PSF - NN - DL	Lagged PV Output	1-day ahead	RMSE - MAE	Torres et al. (2018)
CNN - LSTM	Lagged PV Output - Lagged temperature, wind speed, humidity, solar irradiation	1-day ahead	MAPE - RMSE - MAE	Lee et al. (2018)
NN - CSRM - REL	Lagged PV Output - Forecasted Weather Data	1-day ahead	NMAE - WMAE - nRMSE	Leva et al. (2017)
Deterministic - PHANN - EBP	Lagged PV Output - Forecasted Weather Data	1-day ahead	MBE - MAE - NMAE - R2	Ogliari et al. (2017)
NN Ensemble - SVM	Lagged PV Output - Lagged solar irradiance, temperature, humidity, wind speed	5-min to 1-hour ahead	MAE - MRE	Rana et al. (2016)
WNN - WT	Lagged solar irradiance	1-hour ahead	MBE - nRMSE	Sharma et al. (2016)
PHANN (NN + CSRM)	Lagged PV Output - Forecasted Weather Data	1-day ahead	WMAE - NMAE - nRMSE	Dolara et al. (2015)
DANN - TDNN - NAR	Lagged PV Output - Forecasted Weather Data	1-hour ahead	RMSE - RE	Almonacid et al. (2014)



Σχήμα 5.1: Η προτεινόμενη μέθοδος μετα-μάθησης.

Η φάση της προετοιμασίας των δεδομένων περιλαμβάνει δύο βασικά βήματα. Το πρώτο βήμα είναι η επιλογή των χαρακτηριστικών που θα χρησιμοποιηθούν ως μεταβλητές πρόβλεψης στα βασικά μοντέλα πρόβλεψης που περιγράφονται στην ενότητα 5.3.3 καθώς και των εισόδων που θα χρησιμοποιηθούν από τον μετα-μαθητή για τη "βέλτιστη" ανάμειξη των βασικών προβλέψεων. Στο πλαίσιο της βραχυπρόθεσμης πρόβλεψης Φ/B παραγωγής ενέργειας, αυτό μπορεί να περιλαμβάνει τη συλλογή ή το σχεδιασμό των αυτοπαλινδρομικών χαρακτηριστικών (παρελθούσες παρατηρήσεις Φ/B παραγωγής), των καιρικών χαρακτηριστικών (π.χ. παρελθούσες παρατηρήσεις ηλιακής ακτινοβολίας και θερμοκρασίας), των εποχιακών χαρακτηριστικών (π.χ. ώρα και μήνας) και άλλων χαρακτηριστικών που μπορούν να συμβάλουν σε ακριβέστερες προβλέψεις. Σημειώστε ότι, αν και κατ' αρχήν τα χαρακτηριστικά των βασικών μοντέλων και του μετα-μαθητή μπορεί να διαφέρουν, στην περίπτωση μας είναι τα ίδια για λόγους απλότητας. Το δεύτερο βήμα αναφέρεται στην επεξεργασία των ακατέργαστων δεδομένων που διευκολύνει την εκπαίδευση των βασικών μοντέλων MM, η οποία πραγματοποιείται όπως περιγράφεται στην ενότητα 5.3.3. Αυτό μπορεί, για παράδειγμα, να περιλαμβάνει τον καθαρισμό των δεδομένων, την προεπεξεργασία ή τυχόν μετασχηματισμούς. Περισσότερες λεπτομέρειες σχετικά με τη φάση προετοιμασίας των δεδομένων της προτεινόμενης μεθόδου μετα-μάθησης, προσαρμοσμένης στην εξεταζόμενη μελέτη περίπτωσης, παρέχονται στην ενότητα 5.4.

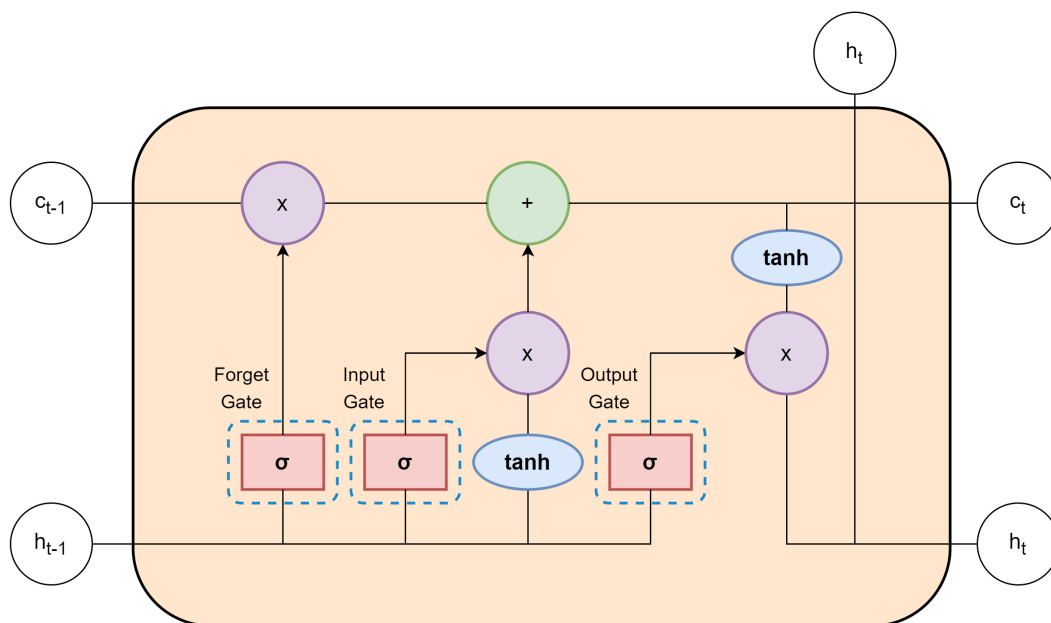
Τα βασικά μοντέλα υλοποιήθηκαν με τη χρήση της βιβλιοθήκης Tensorflow Keras για Python, έκδοση 2.6.0 (Chollet et al., 2015), ενώ ο μετα-μαθητής υλοποιήθηκε με τη χρήση της βιβλιοθήκης Scikit-learn για Python, έκδοση 1.0 (Pedregosa et al., 2011).

5.3.2 Το μοντέλο LSTM

Τα RNNs είναι ένας ειδικός τύπος NNs που έχει σχεδιαστεί ειδικά για να διευκολύνει την πρόβλεψη δεδομένων με χρονικές σχέσεις. Στα RNNs, η έξοδος του δικτύου από ένα συγκεκριμένο χρονικό βήμα περνά ως είσοδος στο επόμενο χρονικό βήμα, επιτρέποντας στο μοντέλο να εκτελεί προβλέψεις με βάση το συνδυασμό της εισόδου του τρέχοντος χρονικού

βήματος και της εξόδου προηγούμενων χρονικών βημάτων. Ένα από τα πιο ευρέως χρησιμοποιούμενα RNNs είναι το δίκτυο LSTM. Τα LSTM ενσωματώνουν μια εσωτερική μονάδα μνήμης που επιτρέπει στο μοντέλο να συσσωρεύει αποτελεσματικά την κατάσταση επί των χαρακτηριστικών εισόδου, καθιστώντας τα ιδιαίτερα κατάλληλα για την πρόβλεψη χρονοσειρών όπου μπορεί να εμφανιστούν συσχετίσεις άγνωστης διάρκειας μεταξύ των παρατηρήσεων και σημαντικών γεγονότων.

Η αρχιτεκτονική των LSTMs εμπνεύστηκε από την ανάλυση της ροής σφαλμάτων στα συμβατικά RNNs, με αποτέλεσμα να καταλήξει στο συμπέρασμα ότι οι μακροχρόνιες εξαρτήσεις δεν μπορούσαν να αντιμετωπιστούν από τέτοια μοντέλα (Sagheer and Kotb, 2019; Donahue et al., 2015). Η δημοτικότητα των LSTMs προέρχεται ακριβώς από την έμφυτη ικανότητά τους να ξεπερνούν τα σημαντικότερα προβλήματα των κοινών αρχιτεκτονικών RNNs: τις εξαφανιζόμενες κλίσεις και τις εκρηκτικές κλίσεις. Τα RNNs έχουν συνήθως ένα περιορισμένο εύρος πληροφοριών που μπορούν να επεξεργαστούν και να ενσωματώσουν στις προβλέψεις τους. Η κύρια αιτία αυτού του προβλήματος είναι ότι η επιρροή (συντελεστής στάθμησης) της εισόδου στην έξοδο του δικτύου μπορεί να υποβαθμίζεται εκθετικά, προκαλώντας το πρόβλημα της εξαφανιζόμενης κλίσης, ή να εκρήγνυται εκθετικά, προκαλώντας το πρόβλημα της εκρηκτικής κλίσης (Hochreiter, 1998). Για την αντιμετώπιση των παραπάνω προβλημάτων, τα LSTMs περιλαμβάνουν κύτταρα που ενσωματώνουν μια προσθετική δομή κλίσης, επιτρέποντας μια επιθυμητή συμπεριφορά από την κλίση σφάλματος σε κάθε βήμα της διαδικασίας εκπαίδευσης (Graves et al., 2008). Η αρχιτεκτονική του LSTM, όπως καθορίστηκε από τους Graves (2013) και Olah (2015), συνοψίζεται στο Σχήμα 5.2.



Σχήμα 5.2: Επισκόπηση της μονάδας LSTM.

Σε αντίθεση με τα συμβατικά RNNs, τα οποία περιλαμβάνουν μία μόνο μονάδα, τα τυπικά κύτταρα LSTM περιλαμβάνουν τέσσερις μονάδες. Η πιο σημαντική έννοια της περιγραφόμενης αρχιτεκτονικής είναι η κατάσταση του κελιού που απεικονίζεται με την οριζόντια γραμμή στην κορυφή του Σχήματος 5.2. Κάθε γραμμή στο σχήμα μπορεί να θεωρηθεί ως ένα διάνυσμα στο οποίο εκτελούνται διάφορες σημειακές πράξεις. Η κατάσταση κυττάρου περικλείει την ικανότητα της μακροπρόθεσμης μνήμης τέτοιων δικτύων που αποθηκεύει και φορτώνει πληροφορίες όχι απαραίτητα αμέσως προηγούμενων γεγονότων. Εκτός από την κατάσταση κελιού, τα κύτταρα LSTM περιλαμβάνουν επίσης την ικανότητα μνήμης εργασίας που μεταφέρει πληροφορίες από αμέσως προηγούμενα γεγονότα, γνωστή ως κρυφή κατάσταση. Η κρυφή κατάσταση των LSTM αντικαθίσταται σε κάθε βήμα.

Τα κύτταρα LSTM απαιτούν τρεις εισόδους και παράγουν δύο εξόδους. Οι εισόδοι, που περνούν σε διανυσματική μορφή, είναι οι εξής: η τρέχουσα είσοδος x_t , η προηγούμενη κρυφή κατάσταση h_{t-1} και η προηγούμενη κατάσταση του κελιού c_{t-1} . Οι βασικές λειτουργίες ενός LSTM υλοποιούνται μέσω των τριών πυλών του: την πύλη λήθης, την πύλη εισόδου και την πύλη εξόδου.

Η πύλη λήθης είναι το πρώτο μπλοκ που αναπαρίσταται στην αρχιτεκτονική LSTM. Ο ρόλος της πύλης λήθης είναι να καθορίζει ποιο μέρος της πληροφορίας πρέπει να διατηρηθεί ή να απορριφθεί. Οι εισόδοι αυτής της πύλης είναι η προηγούμενη κρυφή κατάσταση h_{t-1} και η τρέχουσα είσοδος x_t . Αυτές οι εισόδοι περνούν μέσα από τη σιγμοειδή συνάρτηση σ_g η οποία οδηγεί σε τιμές εξόδου μεταξύ 0 (καμία πληροφορία δεν περνάει) και 1 (όλη η πληροφορία περνάει). Το διάνυσμα ενεργοποίησης της πύλης λήθης f_t δίνεται ως εξής

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f). \quad (5.1)$$

Η πύλη εισόδου χρησιμεύει ως είσοδος για την ενημέρωση της κατάστασης της μονάδας. Η πύλη εισόδου λειτουργεί σε δύο μέρη. Πρώτον, η προηγούμενη κρυφή κατάσταση και η τρέχουσα είσοδος περνούν στη δεύτερη σιγμοειδή συνάρτηση σ_g . Δεύτερον, οι ίδιες εισόδοι περνούν στην συνάρτηση υπερβολικής εφαιπτομένης σ_c προκειμένου να ρυθμιστεί το δίκτυο. Τέλος, το διάνυσμα κατάστασης της μονάδας c_t είναι το αποτέλεσμα του στοιχειομετρικού γινομένου του διανύσματος ενεργοποίησης εισόδου της μονάδας \tilde{c}_t και του διανύσματος ενεργοποίησης της πύλης ενημέρωσης i_t . Οι συναρτήσεις ενεργοποίησης της πύλης εισόδου δίνονται από το ακόλουθο σύνολο εξισώσεων:

$$\tilde{c}_t = \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \quad (5.2)$$

$$i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \quad (5.3)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (5.4)$$

Τέλος, η πύλη εξόδου καθορίζει ποια θα πρέπει να είναι η επόμενη κρυφή κατάσταση h_t που παρέχεται από το κύτταρο. Η κρυφή κατάσταση περιλαμβάνει πληροφορίες σχετικά με τις προηγούμενες εισόδους και χρησιμοποιείται για πρόβλεψη. Η προηγούμενη κρυφή κατάσταση h_{t-1} και η τρέχουσα είσοδος x_t περνούν στην τρίτη σιγμοειδή συνάρτηση σ_g . Στη συνέχεια, η τροποποιημένη κατάσταση του κελιού περνάει στην συνάρτηση υπερβολικής εφαιπτομένης σ_h . Αυτές οι έξοδοι πολλαπλασιάζονται στοιχειωδώς επιτρέποντας στο δίκτυο να καθορίσει ποια πληροφορία θα πρέπει να μεταφέρει η κρυφή κατάσταση.

$$o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \quad (5.5)$$

$$h_t = o_t \circ \sigma_h(c_t) \quad (5.6)$$

Οι παράμετροι $W \in \mathbb{R}^{h \times d}$, $U \in \mathbb{R}^{h \times h}$ και $b \in \mathbb{R}^h$ των παραπάνω εξισώσεων αντιπροσωπεύουν πίνακες βαρών και παραμέτρους διανυσμάτων προκατάληψης, αντίστοιχα, που μαθαίνονται κατά τη διάρκεια της διαδικασίας εκπαίδευσης. Σημειώστε ότι αυτή η περιγραφή απεικονίζει τον τρόπο λειτουργίας μιας μεμονωμένης μονάδας LSTM.

5.3.3 Baseline Μοντέλα Πρόβλεψης

Παρακάτω παρουσιάζουμε τις αρχιτεκτονικές TNΔ των τεσσάρων μοντέλων LSTM που εξετάστηκαν για την ανάπτυξη του μετα-μαθητή. Παρόλο που η συνολική αρχιτεκτονική κάθε μοντέλου είναι καταρχήν γενική, οι τελικές αρχιτεκτονικές επιλέχθηκαν για τα πειράματά μας με την εκτέλεση μιας βελτιστοποίησης αναζήτησης πλέγματος σε βασικές υπερπαραμέτρους των δικτύων, δηλαδή τον αριθμό των στρωμάτων, τον αριθμό των κελιών LSTM ανά στρώμα και τον αριθμό των φίλτρων (για τα CNN).

Stacked LSTM

Οι τυπικές αρχιτεκτονικές των μοντέλων LSTM περιλαμβάνουν ένα μόνο πλήρως συνδεδεμένο επίπεδο μονάδων LSTM, ακολουθούμενο από ένα επίπεδο εξόδου με πρόωση. Το μοντέλο stacked LSTM (**StackLSTM**) που χρησιμοποιήθηκε στην παρούσα μελέτη αποτελείται από πολλαπλά πλήρως συνδεδεμένα στρώματα, καθένα από τα οποία περιλαμβάνει πολλαπλά κύτταρα LSTM. Αυτά τα στρώματα στοιβάζονται διαδοχικά, δημιουργώντας μια βαθύτερη αρχιτεκτονική που μπορεί να αντιμετωπίσει πιο αποτελεσματικά πολύπλοκα μαθησιακά καθήκοντα (Bengio et al., 2009). Όταν πρόκειται για τα FFNNs, η στοιβάξη πολλαπλών πλήρως συνδεδεμένων στρωμάτων έχει ως αποτέλεσμα μια ιεραρχική αναπαράσταση χαρακτηριστικών των δεδομένων που χρησιμοποιείται για την εκπαίδευση του μοντέλου. Το ίδιο ισχύει και στην περίπτωση των βαθιών μοντέλων LSTM. Η χρήση πολλαπλών επιπέδων πλήρως συνδεδεμένων στρωμάτων LSTM επιτρέπει στο μοντέλο να συνδυάζει τις αναπαραστάσεις που μαθαίνονται από τα προηγούμενα στρώματα και να συλλαμβάνει νέα μοτίβα, προσθέτοντας ένα υψηλότερο επίπεδο αφάιρσης. Σύμφωνα με τους Hermans and Schrauwen (2013), κάθε επίπεδο επιλύει κάποιο μέρος του προβλήματος πρόβλεψης και μεταβιβάζει την παραγόμενη πρόβλεψη στο επόμενο επίπεδο. Κατά συνέπεια, η αρχιτεκτονική μπορεί να θεωρηθεί ως ένας αγωγός επεξεργασίας όπου κάθε στρώμα συμβάλλει σε ένα διαφορετικό μέρος της διαδικασίας επίλυσης του προβλήματος μέχρι το τελευταίο στρώμα να παρέχει την τελική πρόβλεψη. Ως εκ τούτου, τα στρώματα παρέχουν στο μοντέλο ισχυρή ικανότητα εντοπισμού πιο σύνθετων μοτίβων και δομών στις χρονοσειρές εισόδου.

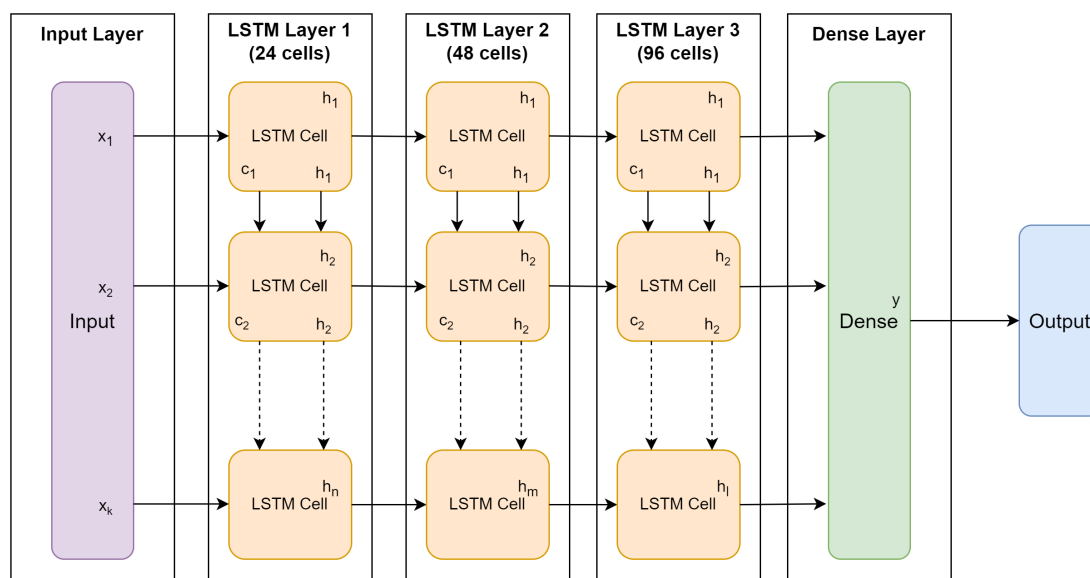
Στο εξεταζόμενο μοντέλο, κάθε στρώμα LSTM εξάγει μια ακολουθία διανυσμάτων τα οποία διαβιβάζονται απευθείας ως είσοδος στο επόμενο στρώμα LSTM. Ένα μεμονωμένο στρώμα LSTM λαμβάνει μια τρισδιάστατη είσοδο και παράγει μια δισδιάστατη έξοδο, συμπεριλαμβανομένης της κρυφής κατάστασης του τελευταίου χρονικού βήματος που ερμηνεύει το τέλος της ακολουθίας. Το επόμενο στρώμα του μοντέλου, όμως, θα πρέπει να τροφοδοτείται επίσης με μια τρισδιάστατη είσοδο. Έτσι, η έξοδος LSTM του προηγούμενου στρώματος, συμπεριλαμβανομένης της κρυφής κατάστασης όλων των προηγούμενων χρονικών βημάτων, περνάει στο επόμενο. Αυτή η αρχιτεκτονική επιτρέπει σε όλα τα στρώματα να έχουν μια τρισδιάστατη είσοδο από το προηγούμενο κρυφό στρώμα στο επόμενο. Αυτή η ιεραρχία των κρυφών στρωμάτων επιτρέπει την εκμάθηση πιο σύνθετης αναπαράστασης δεδομένων διαφορετικών κλιμάκων (Pascanu et al., 2013).

Η αρχιτεκτονική StackLSTM που χρησιμοποιήθηκε στην παρούσα μελέτη παρουσιάζεται στο Σχήμα 5.3. Ας ορίσουμε το *batch_size* ως τον αριθμό των δειγμάτων δεδομένων εκπαίδευσης πριν από την ενημέρωση των εσωτερικών παραμέτρων του μοντέλου, το *num_timesteps* ως τον αριθμό των προηγούμενων χρονικών βημάτων που δόθηκαν στο μοντέλο και το *num_features* ως το μήκος της ακολουθίας χαρακτηριστικών (αριθμός των χαρακτηριστικών του μοντέλου). Κατά τη λεπτομερή ρύθμιση του μοντέλου, εξετάστηκαν δύο υπερπαραμέτροι: ο αριθμός των στρωμάτων με πιθανές τιμές 1, 2 και 3 στρώματα και το μέγεθος κάθε στρώματος με πιθανές τιμές 24, 48, 96 και 192. Η κυρίαρχη αρχιτεκτονική αποτελείται από 3 στρώματα LSTM των 24, 48 και 96 κελιών, αντίστοιχα.

Bidirectional LSTM

Σε πολλά προβλήματα πρόβλεψης, είναι ωφέλιμο να αναπτύσσονται μοντέλα LSTM που μπορούν να μαθαίνουν χρονικές σχέσεις και προς τις δύο κατευθύνσεις, δηλαδή προς τα εμπρός (από το παρελθόν στο μέλλον) και προς τα πίσω (από το μέλλον στο παρελθόν). Το κύριο πλεονέκτημα αυτής της προσέγγισης είναι ότι με τη συνένωση και των δύο ερμηνειών, οι προβλέψεις γίνονται χρησιμοποιώντας διαδοχικές πληροφορίες από όλα τα σημεία δεδομένων πριν και μετά από αυτά (Graves and Schmidhuber, 2005). Αυτά τα μοντέλα ονομάζονται γενικά αμφίδρομα RNNs (Schuster and Paliwal, 1997) ή, όταν τα στρώματα αποτελούνται από κύτταρα LSTM, αμφίδρομα LSTM (**BiLSTM**).

Η διαφορά μεταξύ των BiLSTMs και των τυπικών LSTMs όσον αφορά την αρχιτεκτονική έγκειται στο γεγονός ότι τα BiLSTMs ενσωματώνουν δύο παράλληλα στρώματα και στις δύο



Σχήμα 5.3: Η προτεινόμενη αρχιτεκτονική του μοντέλου stacked LSTM (StackLSTM).

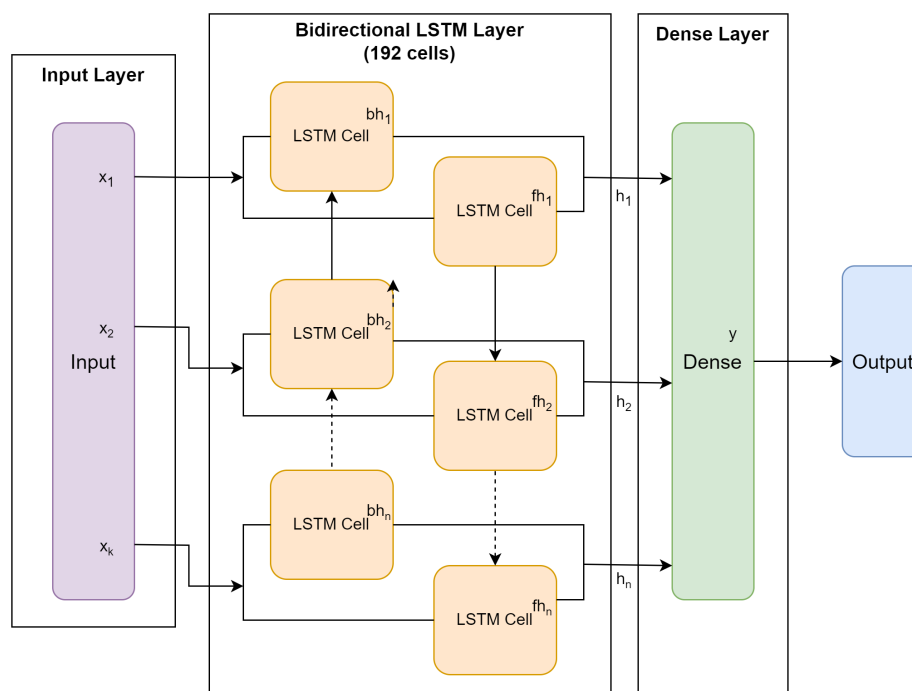
κατευθύνσεις διάδοσης (Yao and Huang, 2016). Έτσι, η προς τα εμπρός μετάδοση και η προς τα πίσω μετάδοση κάθε στρώματος εκτελούνται με παρόμοιο τρόπο με τα κανονικά NN, με τη διαφορά ότι αυτά τα δύο στρώματα έχουν την ικανότητα να απομνημονεύουν πληροφορίες και από τις δύο κατευθύνσεις (Wang and Nyberg, 2015). Αυτό το χαρακτηριστικό των BiLSTMs προσθέτει μια διαφορετική προσέγγιση, καθώς παρακάμπτει την αδυναμία των συμβατικών LSTMs, τα οποία είναι σε θέση να αξιοποιήσουν μόνο το προηγούμενο πλαίσιο. Ως εκ τούτου, τα BiLSTMs έχουν χρησιμοποιηθεί με επιτυχία σε ένα ευρύ φάσμα εργασιών πρόβλεψης, όπως η αναγνώριση ομιλίας (Sajjad et al., 2020) και η ανάλυση συναισθήματος (Chen et al., 2017), μεταξύ άλλων, καθιστώντας τα ένα από τα πλέον κατάλληλα μοντέλα για την πρόβλεψη χρονοσειρών.

Η λεπτομερής ρύθμιση του μοντέλου BiLSTM πραγματοποιήθηκε με βάση τον αριθμό των αμφίδρομων στρωμάτων LSTM και τον αριθμό των κελιών ανά στρώμα. Όσον αφορά τον αριθμό των στρωμάτων, δοκιμάστηκαν 1, 2 και 3 στρώματα, ενώ ο αριθμός των πιθανών κελιών ανά στρώμα κυμάνθηκε στα 24, 48, 96 και 192. Η επιλεγμένη αρχιτεκτονική, που παρουσιάζεται στο Σχήμα 5.4, περιλαμβάνει 1 αμφίδρομο στρώμα LSTM με 192 κελιά.

CNN-LSTM

Μια άλλη προσέγγιση για την πρόβλεψη χρονοσειρών περιλαμβάνει μια προσαρμοσμένη αρχιτεκτονική που συνδυάζει CNN με LSTM. Σε γενικές γραμμές, τα CNNs είναι μια ειδική κατηγορία NNs, που εφαρμόζεται συνήθως για την ανάλυση οπτικών εικόνων, την αναγνώριση προσώπου, την αναζήτηση εικόνων και την επαυξημένη πραγματικότητα (Li et al., 2021). Τα CNNs μπορούν να θεωρηθούν ως κανονικοποιημένες εκδόσεις των πολυστρωματικών perceptrons, οι οποίες στοχεύουν στην εκμετάλλευση του ιεραρχικού προτύπου στα δεδομένα, δημιουργώντας πρότυπα αυξανόμενης πολυπλοκότητας χρησιμοποιώντας μικρότερα και απλούστερα πρότυπα μέσω φίλτρων.

Η χρήση συνελκτικών στρωμάτων δίνει στο μοντέλο το ξεχωριστό πλεονέκτημα να μαθαίνει την εσωτερική αναπαράσταση και τα μοτίβα των δεδομένων ακολουθίας. Η χρήση μονοδιάστατων CNN έχει αποδειχθεί πολύ αποτελεσματική στην εκμάθηση χαρακτηριστικών από ακολουθίες εισόδου. Επιπλέον, έχει αποδειχθεί ότι η σύζευξη CNNs με LSTMs συνδυάζει αποτελεσματικά τα πλεονεκτήματα και των δύο αρχιτεκτονικών ΤΝΔ (Livieris et al., 2020). Ο συνδυασμός των στρωμάτων συνελκτικής ανάλυσης και των στρωμάτων LSTM έχει ως αποτέλεσμα τη δημιουργία ενός υβριδικού μοντέλου, που ονομάζεται CNN-LSTM, όπου τα



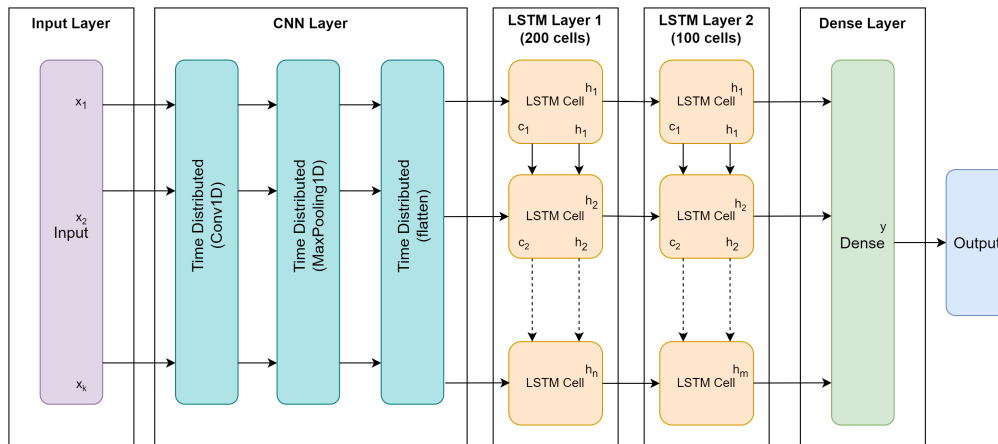
Σχήμα 5.4: Η προτεινόμενη αρχιτεκτονική του μοντέλου bidirectional LSTM (BiLSTM).

στρώματα συνελικτικής ανάλυσης χρησιμοποιούνται για την εξαγωγή μοτίβων δεδομένων και τα στρώματα LSTM αξιοποιούνται για την πραγματοποίηση προβλέψεων. Πρακτικά, κάθε συνελικτικό στρώμα χρησιμεύει ως κωδικοποιητής που μαθαίνει τη δομή μικρών υποακολουθιών των δεδομένων εισόδου, οι οποίες στη συνέχεια τροφοδοτούνται ως χρονικά βήματα σε ένα στρώμα LSTM.

Η αρχιτεκτονική του μοντέλου CNN-LSTM αποτελείται από δύο μέρη. Το πρώτο μέρος αποτελείται από στρώματα συνελικτικής και συγκέντρωσης που αναγνωρίζουν και εξάγουν χαρακτηριστικά από τα δεδομένα εισόδου, χρησιμεύοντας ως στρώματα προεπεξεργασίας που τροφοδοτούν με πληροφορίες τα πλήρως συνδεδεμένα στρώματα δικτύου (Rawat and Wang, 2017). Το στρώμα συνελικτικής επεξεργασίας συνήθως ακολουθείται από μια μη γραμμική συνάρτηση ενεργοποίησης και ένα στρώμα συγκέντρωσης μέγιστου. Το στρώμα συγκέντρωσης εκτελεί μια τεχνική υποδειγματοληψίας η οποία εξάγει ορισμένες τιμές από τα συνεπτυγμένα χαρακτηριστικά και παράγει έναν πίνακα χαμηλότερης διάστασης. Το max pooling εκτελείται με παρόμοιο τρόπο με τη συνέλιξη, χρησιμοποιώντας ένα ολισθαίνον παράθυρο που λαμβάνει ως είσοδο τις τιμές κάθε τμήματος των συνεπτυγμένων χαρακτηριστικών και εξάγει το μέγιστο των τιμών κάθε τμήματος (Rawat and Wang, 2017). Το δεύτερο μέρος της αρχιτεκτονικής αποτελείται από πλήρως συνδεδεμένα στρώματα LSTM που μαθαίνουν τις μακροχρόνιες εξαρτήσεις των χαρακτηριστικών και οδηγούν στο πυκνό στρώμα που εξάγει την πρόβλεψη.

Από τεχνικής άποψης, είναι απαραίτητο να χωριστούν οι ακολουθίες εισόδου σε διαστάσεις υποακολουθίες προκειμένου να επεξεργαστεί το CNN. Υποθέτοντας ότι τα δεδομένα χρονοσειρών αποτελούνται από k χρονικά βήματα ως είσοδο και μία έξοδο, κάθε δείγμα εισόδου χωρίζεται σε $k/2$ υποακολουθίες, καθεμία από τις οποίες αποτελείται από δύο χρονικά βήματα, επιτρέποντας στο CNN να ερμηνεύσει κάθε υποακολουθία ξεχωριστά δίνοντας αυτή την ερμηνεία ως είσοδο στο μοντέλο LSTM. Οι λεπτομερώς ρυθμισμένες παράμετροι του μοντέλου ήταν ο αριθμός των φίλτρων (πιθανές τιμές: 32, 64, 128- επιλεγμένη τιμή: 64), ο αριθμός των στρωμάτων LSTM (πιθανές τιμές: 1, 2, 3- επιλεγμένη τιμή: 2) και ο αριθμός των κελιών LSTM ανά στρώμα (πιθανές τιμές: 25, 50, 100- επιλεγμένες τιμές: 200 για το στρώμα 1 και 100 για το στρώμα 2). Η αρχιτεκτονική του μοντέλου CNN-LSTM που αναπτύχθηκε

παρουσιάζεται στο Σχήμα 5.5.



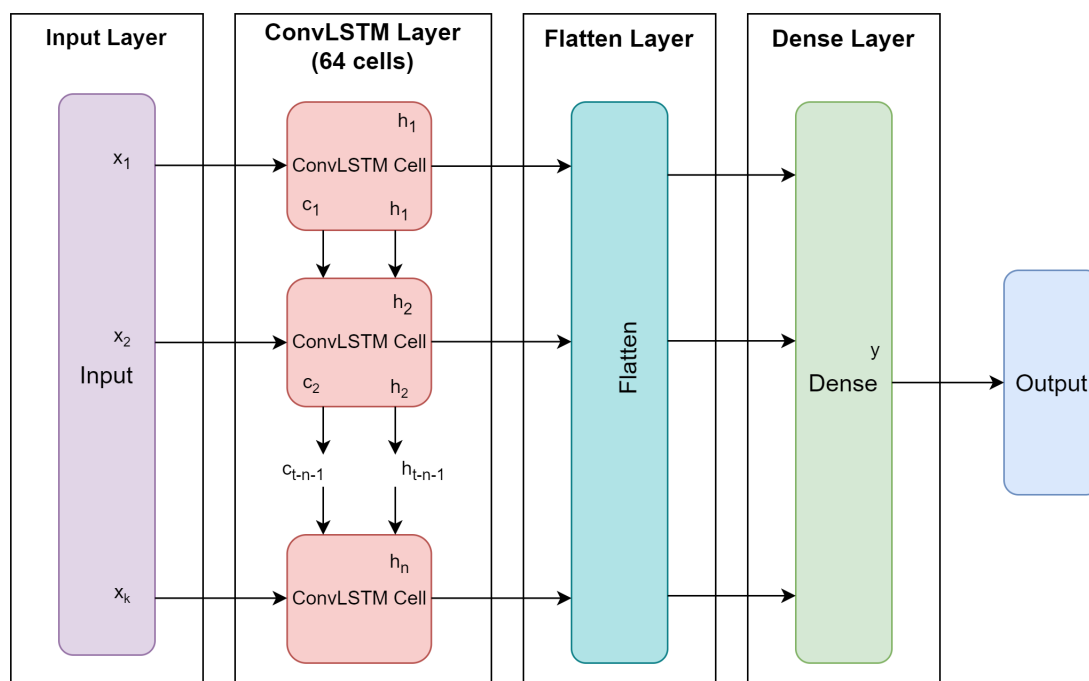
Σχήμα 5.5: Η προτεινόμενη αρχιτεκτονική του μοντέλου CNN-LSTM.

ConvLSTM

Στην αρχιτεκτονική CNN-LSTM, το CNN αναπτύσσει συνελικτικές λειτουργίες προσπαθώντας να συλλάβει χωρικά χαρακτηριστικά και το LSTM είναι υπεύθυνο για την εκμάθηση διαδοχικών χαρακτηριστικών μέσω των μονάδων μνήμης του. Το Convolutional LSTM (ConvLSTM), λοιπόν, καταφέρνει να ενσωματώσει τα πλεονεκτήματα και τις δυνατότητες της αρχιτεκτονικής CNN-LSTM σε κύτταρα convLSTM, προσφέροντας μια πιο συμπαγή υλοποίηση. Η αρχιτεκτονική του μοντέλου ConvLSTM βασίζεται στην παροχή συνελίξεων στα στρώματα LSTM για τις κρυφές καταστάσεις και τις καταστάσεις των κελιών, διαφέροντας από το παραδοσιακό CNN-LSTM που χρησιμοποιεί πολλαπλασιασμό πινάκων (Shi et al., 2015). Αυτή η προσαρμοσμένη αρχιτεκτονική διευκολύνει την ανάπτυξη της συνελικτικής ανάγνωσης της εισόδου απευθείας σε κάθε μονάδα LSTM. Γενικά, το μοντέλο ConvLSTM έχει σχεδιαστεί για τη λήψη χωροχρονικών δεδομένων σε δύο διαστάσεις ως είσοδο. Ωστόσο, η αρχιτεκτονική του μπορεί επίσης να χρησιμοποιηθεί για την πρόβλεψη πολυμεταβλητών χρονοσειρών.

Παρόμοια με το μοντέλο CNN-LSTM, στο ConvLSTM η χρονοσειρά πρέπει να υποβληθεί σε προεπεξεργασία προτού δοθεί ως είσοδος στο μοντέλο. Έτσι, κάθε δείγμα εισόδου (που αποτελείται από k βήματα) χωρίζεται σε $k/2$ υποακολουθίες, καθεμία από τις οποίες αποτελείται από δύο χρονικά βήματα. Ως αποτέλεσμα, το μοντέλο λαμβάνει τα δεδομένα εισόδου με τη μορφή k χρονικών βημάτων σε μια διδιάστατη αναπαράσταση που αποτελείται από $k/2$ γραμμές και δύο στήλες. Η μόνη παράμετρος που έχει ρυθμιστεί λεπτομερώς για το μοντέλο ConvLSTM που αναπτύχθηκε είναι ο αριθμός των φίλτρων για το συνελικτικό στρώμα LSTM. Οι πιθανές τιμές ήταν 16, 32, 64 και 128, ενώ επικράτησε η τιμή 64. Η επιλεγμένη αρχιτεκτονική του μοντέλου ConvLSTM συνοψίζεται στο Σχήμα 5.6.

Για να συνοψίσουμε τις πληροφορίες που παρουσιάστηκαν παραπάνω, τα τέσσερα βασικά μοντέλα πρόβλεψης που εξετάστηκαν έχουν όλα επιδείξει εξαιρετικές δυνατότητες πρόβλεψης στον τομέα της πρόβλεψης της Φ/B παραγωγής ενέργειας. Ωστόσο, κάθε μοντέλο έχει τα δικά του μοναδικά πλεονεκτήματα και περιορισμούς. Το Stacked-LSTM είναι ιδιαίτερα κατάλληλο για διαδοχικά δεδομένα όπως οι χρονοσειρές, καθώς είναι σε θέση να συλλάβει τις μακροπρόθεσμες εξαρτήσεις όταν χρησιμοποιείται σε βαθιά δίκτυα. Το Bi-LSTM μπορεί να συλλάβει τόσο τις παρελθοντικές όσο και τις μελλοντικές σχέσεις δεδομένων, αλλά μπορεί να μην αποδίδει απαραίτητα τόσο καλά όσο το Stacked-LSTM για σχετικά μεγαλύτερους ορίζοντες πρόβλεψης. Το CNN-LSTM, όπως και το Stacked-LSTM, είναι επίσης αποτελεσματικό στην ακριβή επεξεργασία διαδοχικών δεδομένων, αλλά περιλαμβάνει ένα πρόσθετο φίλτρο για



Σχήμα 5.6: Η προτεινόμενη αρχιτεκτονική του μοντέλου ConvLSTM.

την εξαγωγή και επεξεργασία πιο σύνθετων μοτίβων. Τέλος, το ConvLSTM είναι καλά εξοπλισμένο για να χειρίζεται χωροχρονικά δεδομένα και μπορεί εύκολα να προσαρμοστεί για την πρόβλεψη μονομεταβλητών χρονοσειρών. Λόγω των προκλήσεων που υπάρχουν στην πρόβλεψη της Φ/B παραγωγής ενέργειας, κανένα μοντέλο δεν είναι πιθανό να αποδίδει καλύτερα σε όλες τις περιπτώσεις. Ως αποτέλεσμα, στην επόμενη ενότητα προτείνεται ένας μετα-μαθητής που συνδυάζει τις δυνατότητες και των τεσσάρων βασικών μοντέλων.

5.3.4 Μοντέλο Μετα-Μάθησης

Η μετα-μάθηση (ή στοίβαξη) είναι η διαδικασία της "μάθησης για μάθηση", με την έννοια ότι αναθέτει σε ένα μοντέλο MM την αποστολή να βελτιώσει την ακρίβεια ενός συγκεκριμένου έργου πρόβλεψης χρησιμοποιώντας ως βάση (μετα-δεδομένα) τις προβλέψεις άλλων μοντέλων πρόβλεψης (Vanschoren, 2019). Η εργασία αυτή μπορεί να αποδειχθεί ιδιαίτερα χρήσιμη σε εργασίες πρόβλεψης όπου διαφορετικά μοντέλα πρόβλεψης με ποικίλα χαρακτηριστικά, δομές και παραδοχές δεδομένων αναμένεται να αποδώσουν διαφορετικά υπό διάφορες συνθήκες (Sarmas et al., 2022b). Για παράδειγμα, στην πρόβλεψη Φ/B παραγωγής ενέργειας ορισμένα μοντέλα μπορεί να αποδίδουν καλύτερα το καλοκαίρι, όταν οι καιρικές συνθήκες γίνονται πιο σταθερές, αλλά να υποαποδίδουν το χειμώνα. Ομοίως, η ακρίβεια ορισμένων μοντέλων μπορεί να αυξάνεται κατά τη διάρκεια των ωρών αιχμής της Φ/B παραγωγής αλλά να επιδεινώνεται κατά τη διάρκεια ωριαίων διαστημάτων χαμηλής παραγωγής.

Παρόλο που οι τελικές προβλέψεις (προβλέψεις επιπέδου-1) που παράγονται από τον μετα-μαθητή μπορεί να είναι ουσιαστικά ένας συνδυασμός των βασικών προβλέψεων (προβλέψεις επιπέδου-0), είτε γραμμικών είτε μη γραμμικών, η μετα-μάθηση δεν πρέπει να θεωρείται ως ένα συμβατικό σχήμα συνδυασμού προβλέψεων. Αυτό οφείλεται στο γεγονός ότι ο στόχος του μετα-μαθητή είναι να συνδυάσει τις προβλέψεις βάσης όχι παρατηρώντας απλώς τη μέση σχετική απόδοση των μοντέλων βάσης, αλλά κατανοώντας τις συγκεκριμένες συνθήκες υπό τις οποίες ένα μεμονωμένο μοντέλο βάσης ή ένας συνδυασμός μοντέλων βάσης αποδίδει καλύτερα (Todorovski and Džeroski, 2000). Εάν αυτές οι συνθήκες μαθευτούν, τότε ο συνδυασμός προβλέψεων μπορεί να προηγηθεί με έναν αποτελεσματικό, καθοδηγούμενο από τα δεδομένα

τρόπο που επιτρέπει καλύτερη γενίκευση (Wolpert, 1992). Σύμφωνα με τους Hospedales et al. (2020), η μετα-μάθηση παρέχει την ευκαιρία να αντιμετωπιστούν πολλές προκλήσεις της συμβατικής MM, συμπεριλαμβανομένων των δεδομένων και των υπολογιστικών δυσχερειών..

Ο μετα-μαθητής υλοποιείται χρησιμοποιώντας τη μέθοδο SVR (Schölkopf and Smola, 2001). Ο SVR είναι ένας ευρέως χρησιμοποιούμενος αλγόριθμος MM που εκτελεί παλινδρόμηση με παρόμοιο τρόπο με τη συμβατική γραμμική παλινδρόμηση υπό την έννοια ότι η γραμμή που χρησιμοποιείται για την πραγματοποίηση προβλέψεων εκτιμάται ως

$$\hat{y} = \mathbf{W}^T \mathbf{x} + b, \quad (5.7)$$

όπου \hat{y} είναι η μεταβλητή-στόχος, \mathbf{x} είναι το σύνολο των χαρακτηριστικών που χρησιμοποιούνται ως μεταβλητές πρόβλεψης, \mathbf{W} είναι ένα διάνυσμα βαρών και b είναι μια παρεμβολή που λαμβάνει υπόψη τη μεροληψία. Ωστόσο, το SVR χρησιμοποιεί έναν διαφορετικό τρόπο για τον υπολογισμό της γραμμής πρόβλεψης, που αναφέρεται ως υπερεπίπεδο. Τα δεδομένα σε κάθε πλευρά του υπερεπιπέδου που έχουν τη μικρότερη απόσταση από το υπερεπίπεδο ονομάζονται διανύσματα υποστήριξης. Οι παραδοσιακές μέθοδοι παλινδρόμησης στοχεύουν στην ελαχιστοποίηση του σφάλματος μεταξύ των πραγματικών τιμών και των προβλέψεων. Αντίθετα, η μέθοδος SVR στοχεύει στην προσαρμογή της βέλτιστης γραμμής εντός μιας τιμής κατωφλίου d που περιγράφει την απόσταση μεταξύ του υπερεπιπέδου και των διανυσμάτων υποστήριξης. Έτσι, γενικά, η μέθοδος SVR ικανοποιεί τη συνθήκη $-d < y - \mathbf{W}^T \mathbf{x} + b < d$, χρησιμοποιώντας τα σημεία εντός του ορίου για τη δημιουργία προβλέψεων. Στην παρούσα μελέτη, η συνάρτηση ακτινικής βάσης (Radial Basis Function - RBF) χρησιμοποιείται ως συνάρτηση πυρήνα της SVR, προκειμένου να απεικονίσει τα δεδομένα του δείγματος σε έναν χώρο χαρακτηριστικών υψηλής διάστασης και να επιτρέψει τη μη γραμμική παλινδρόμηση.

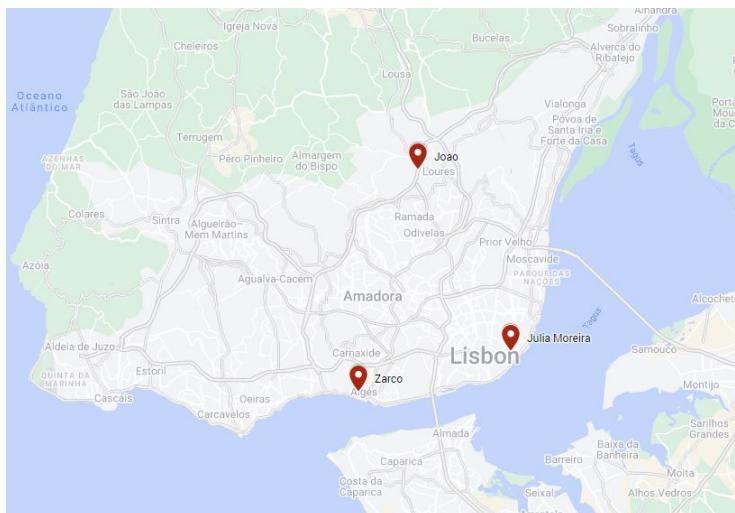
Το SVR προτιμήθηκε ως μετα-μαθητής έναντι άλλων μοντέλων MM, καθώς μπορεί να συνδυάσει τις προβλέψεις των βασικών μοντέλων με σταθμισμένο τρόπο, ενώ παράλληλα αποτυπώνει μη γραμμικές σχέσεις μεταξύ των χαρακτηριστικών. Άλλες δημοφιλείς επιλογές που θα μπορούσαν να χρησιμοποιηθούν ως μοντέλα μετα-μάθησης θα ήταν η γραμμική παλινδρόμηση, η παλινδρόμηση με βάση τα δέντρα και τα NN. Ωστόσο, όλες οι προαναφερθείσες εναλλακτικές λύσεις υστερούν σε ένα ή περισσότερα χαρακτηριστικά σε σύγκριση με το SVR. Πιο συγκεκριμένα, αν και η γραμμική παλινδρόμηση είναι μια σταθμισμένη, διασθητική μέθοδος, δεν μπορεί να συλλάβει μη γραμμικές σχέσεις μεταξύ των επιλεγμένων χαρακτηριστικών. Τα μοντέλα που βασίζονται σε δέντρα, όπως τα δέντρα με ενίσχυση κλίσης και τα τυχαία δάση, δεν μπορούν να συνδυάσουν άμεσα τις προβλέψεις επιπέδου-0 με τις προβλέψεις επιπέδου-1, καθώς η τελική πρόβλεψη αυτών των μοντέλων είναι ουσιαστικά ο μέσος όρος των δειγμάτων που ικανοποιούν τους κανόνες των αντίστοιχων κόμβων. Τέλος, αν και τα TND είναι κατάλληλα για μη γραμμική παλινδρόμηση, συνήθως απαιτούν πολύ μεγαλύτερα σύνολα εκπαίδευσης από τα SVR για να εκπαιδευτούν αποτελεσματικά. Εκτός από τα παραπάνω, δεδομένου ότι οι τελικές προβλέψεις του προτεινόμενου μετα-μαθητή υπολογίζονται με μια μέθοδο μη γραμμικής παλινδρόμησης, ο μηχανισμός ανάμειξης που εξετάζεται είναι πιο ευέλικτος και γενικός σε σύγκριση με τους τυπικούς μετα-μαθητές που εκτιμούν τα “βέλτιστα” βάρη συνδυασμού των βασικών προβλέψεων και χρησιμοποιούν έναν σταθμισμένο μέσο όρο αυτών.

5.4 Μελέτη Περίπτωσης

Αυτή η ενότητα παρέχει λεπτομέρειες σχετικά με τη μελέτη περίπτωσης που εξετάστηκε για την αξιολόγηση της απόδοσης πρόβλεψης της προτεινόμενης μεθόδου μετα-μάθησης. Αυτό περιλαμβάνει την περιγραφή του συνόλου δεδομένων που χρησιμοποιήθηκε, τον πειραματικό σχεδιασμό, τα μέτρα που επιλέχθηκαν για την αξιολόγηση της ακρίβειας πρόβλεψης και τις μεθόδους πρόβλεψης που θεωρήθηκαν ως σημεία αναφοράς. Τα αποτελέσματα παρουσιάζονται στο τελευταίο μέρος της ενότητας.

5.4.1 Σύνολο Δεδομένων

Το σύνολο δεδομένων περιλαμβάνει τρία Φ/Β συστήματα που βρίσκονται στη Λισαβόνα της Πορτογαλίας, και συγκεκριμένα τους “Joao”, “Julia Moreira” και “Zarco”. Οι τοποθεσίες τους φαίνονται στο Σχήμα 5.7. Τα τρία Φ/Β συστήματα είναι εγκατεστημένα σε δημόσια κτίρια (ίδρυμα κοινωνικής αλληλεγγύης, μονάδα οδοντιατρικής και δημοτικό σχολείο) και έχουν ισχύ 40, 27 και 50 kW αντίστοιχα.



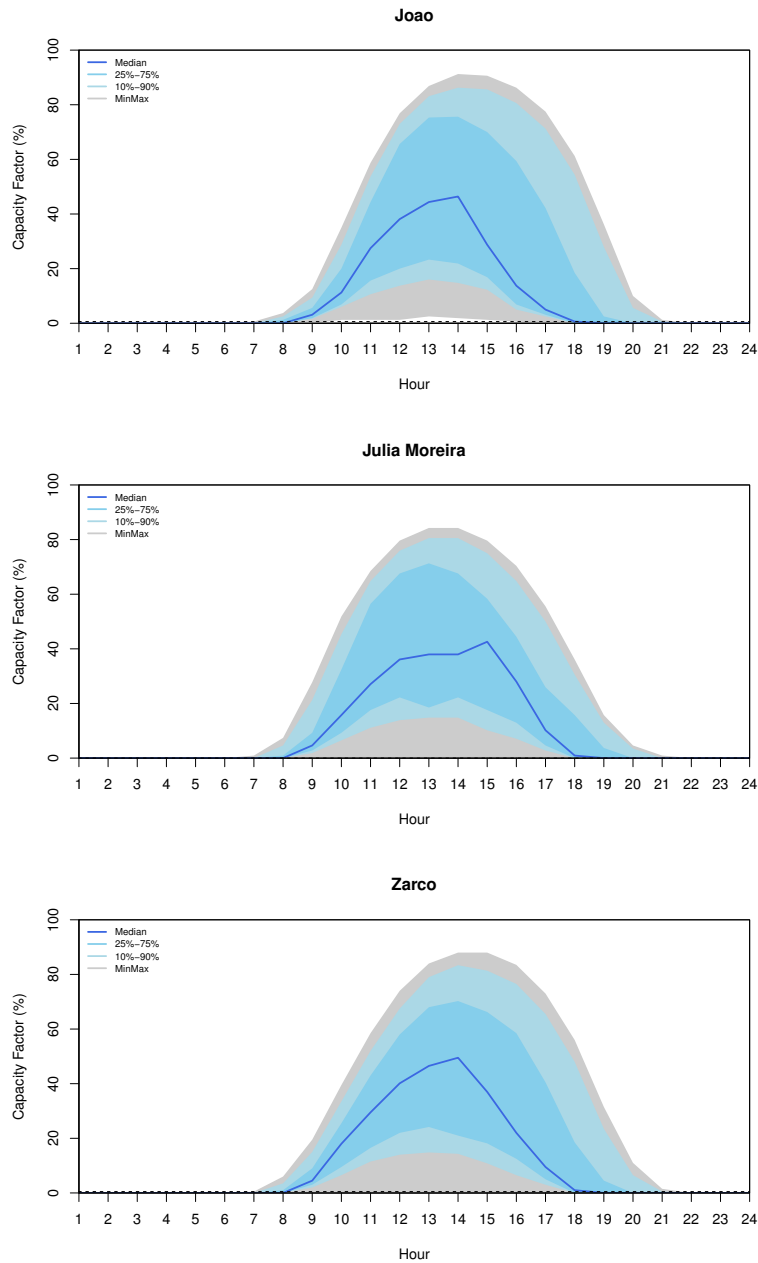
Σχήμα 5.7: Τοποθεσία των τριών Φ/Β συστημάτων που εξετάστηκαν στη μελέτη περίπτωσης.

Τα δεδομένα που χρησιμοποιούνται είναι ωριαία και έχουν διάρκεια περίπου 2 ετών και έξι μηνών (21.958 ώρες), από την 1η Αυγούστου 2018 έως τις 31 Ιανουαρίου 2021. Στο Σχήμα 5.8 παρουσιάζεται η ωριαία κατανομή του συντελεστή ισχύος για τα τρία Φ/Β συστήματα. Όπως αναμενόταν, η παραγωγή ηλεκτρικής ενέργειας είναι συνήθως υψηλότερη μεταξύ 12:00 και 15:00, δηλαδή όταν η ηλιακή ακτινοβολία είναι γενικά μεγαλύτερη εντός της ημέρας, και σημαντικά χαμηλότερη τις πρώτες πρωινές ώρες (09:00 έως 11:00) και το απόγευμα (16:00 έως 18:00), ενώ σε αντίθετη περίπτωση είναι μηδενική (δεν υπάρχει ηλιακή ακτινοβολία τη νύχτα). Ωστόσο, είναι σαφές ότι, ανάλογα με τις καιρικές συνθήκες, η Φ/Β παραγωγή μπορεί να διαφέρει σημαντικά μεταξύ διαφορετικών ημερών. Επιπλέον, παρατηρούμε ότι οι κατανομές των εξεταζόμενων πάρκων είναι παρόμοιες, καθώς οι εγκαταστάσεις βρίσκονται σε κοντινές περιοχές και έχουν συγκρίσιμο προσανατολισμό. Ως εκ τούτου, στο υπόλοιπο του παρόντος υποκεφαλαίου η ανάλυσή μας θα επικεντρωθεί στο υποσύνολο δεδομένων “Joao”.

Η έντονη ημερήσια εποχικότητα των δεδομένων σε διαδοχικές ημέρες, οι οποίες φυσικά χαρακτηρίζονται από παρόμοιες καιρικές συνθήκες, απεικονίζεται στο διάγραμμα αυτο-συσχέτισης του Σχήματος 5.9. Όπως φαίνεται, οι προηγούμενες παρατηρήσεις μπορούν να αποτελέσουν ιδιαίτερα χρήσιμα χαρακτηριστικά για την ανάπτυξη μεθόδων πρόβλεψης, ειδικά όταν χρησιμοποιούνται για την πρόβλεψη της παραγωγής Φ/Β στις επόμενες λίγες ώρες (π.χ. υστέρηση=1 έως υστέρηση=6). Το Σχήμα 5.9 δείχνει επίσης ότι ο μήνας του έτους θα μπορούσε να είναι μια άλλη χρήσιμη μεταβλητή πρόβλεψης, καθώς οι διαφορετικοί μήνες υποδηλώνουν γενικά διαφορετικές καιρικές συνθήκες και, ως εκ τούτου, διαφορετική Φ/Β παραγωγή.

Εκτός από τα αρχεία παραγωγής ηλεκτρικής ενέργειας, μετρούμενα σε kW, για κάθε πάρκο, το σύνολο δεδομένων περιλαμβάνει τις παρατηρούμενες καιρικές συνθήκες όσον αφορά την ηλιακή ακτινοβολία (μετρούμενη σε W/m^2), τη διάχυτη ηλιακή ακτινοβολία (μετρούμενη σε W/m^2) και τη θερμοκρασία (μετρούμενη σε $^{\circ}C$). Οι μετεωρολογικές μεταβλητές μετρώνται επιτόπου από μετεωρολογικούς σταθμούς που είναι εγκατεστημένοι στα Φ/Β πάρκα και αντιπροσωπεύουν τις μέσες καιρικές συνθήκες των αντίστοιχων ωρών.

Το Σχήμα 5.10 απεικονίζει τις κατανομές (ιστογράμματα) της ηλεκτρικής ενέργειας που




Σχήμα 5.8: Ωριαία κατανομή του συντελεστή δυναμικότητας (υπολογίζεται με χρήση προσθετικής αποσύνθεσης με κινητούς μέσους όρους; [Spiliotis et al., 2020](#)) για τα εξεταζόμενα Φ/Β συστήματα. Η χαμηλή διακύμανση γύρω από το εποχικό προφίλ (μπλε γραμμή) υποδηλώνει ισχυρή ημερήσια εποχικότητα (οι παρατηρήσεις επικαλύπτονται κάθε 24 ώρες).

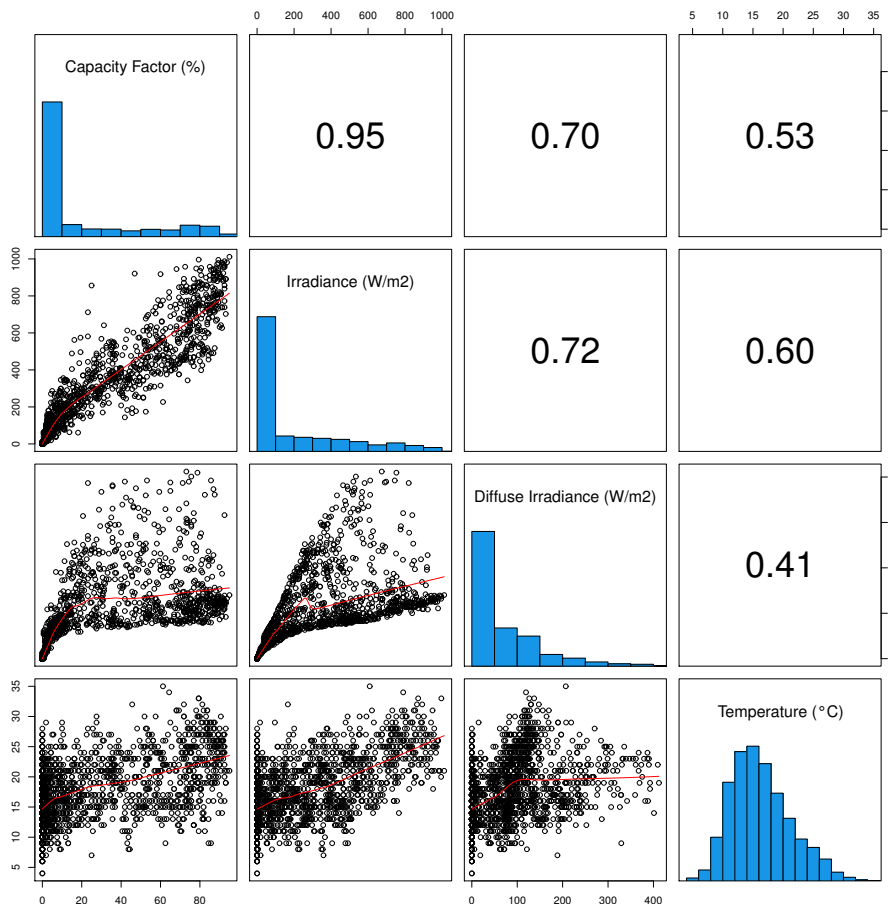
παράγεται στο Φ/Β πάρκο “Joao” και των τριών διαθέσιμων καιρικών μεταβλητών, καθώς και τις κατά ζεύγη συσχετίσεις τους. Παρατηρούμε ότι η Φ/Β παραγωγή συσχετίζεται έντονα με την ηλιακή ακτινοβολία και τη διάχυτη ηλιακή ακτινοβολία, επηρεαζόμενη επίσης θετικά από τη θερμοκρασία. Ως εκ τούτου, συμπεραίνουμε ότι όλες οι μετεωρολογικές μεταβλητές θα μπορούσαν να είναι χρήσιμες εισροές για την πρόβλεψη της παραγωγής Φ/Β .

5.4.2 Πειραματική Μοντελοποίηση

Προκειμένου τα αποτελέσματά μας να είναι αντιπροσωπευτικά, αποτυπώνοντας τη δυναμική πολλαπλών χρονικών περιόδων και, ως εκ τούτου, διαφορετικών καιρικών συνθηκών, εφαρ-



Σχήμα 5.9: Συνάρτηση αυτοσυσχέτισης της Φ/Β παραγωγής στο εργοστάσιο "Joao" (αριστερά) υπολογισμένη κατά τη διάρκεια της εβδομάδας (168 ώρες) και μέσος ημερήσιος συντελεστής δυναμικότητας (δεξιά) για κάθε μήνα του έτους.



Σχήμα 5.10: Συσχέτιση κατά ζεύγη της ηλεκτρικής ενέργειας που παράγεται στο Φ/Β "Joao" (συντελεστής δυναμικότητας) και των τριών διαθέσιμων καιρικών μεταβλητών. Στο άνω μέρος του τριγωνικού πίνακα παρουσιάζονται οι συντελεστές συσχέτισης Pearson των μεταβλητών, ενώ στο κάτω μέρος του τα αντίστοιχα διαγράμματα διασποράς. Η κύρια διαγώνιος παρουσιάζει τις κατανομές (ιστογράμματα) των μεταβλητών.

μόζουμε την προσέγγιση αξιολόγησης κυλιόμενης προέλευσης (Tashman, 2000). Σύμφωνα

με την προσέγγιση αυτή, η οποία ισοδυναμεί με τη διασταυρούμενη επικύρωση για δεδομένα χρονοσειρών, μια περίοδος ιστορικών δεδομένων χρησιμοποιείται αρχικά για την εκπαίδευση της μεθόδου πρόβλεψης που μας ενδιαφέρει. Στη συνέχεια, η μέθοδος χρησιμοποιείται για την πρόβλεψη της παραγωγής Φ/B για την επόμενη ώρα (πρόβλεψη ενός βήματος) και, τέλος, μετράται η ακρίβεια της πρόβλεψης δεδομένης της πραγματοποιηθείσας παραγωγής και ενός μέτρου απόδοσης προτίμησης. Στη συνέχεια, η αφετηρία της πρόβλεψης μετατοπίζεται κατά μία ώρα και η ίδια μέθοδος χρησιμοποιείται για την παραγωγή νέας πρόβλεψης, συμβάλλοντας σε άλλη αξιολόγηση. Η διαδικασία αυτή επαναλαμβάνεται έως ότου δεν απομείνουν δεδομένα για την εκτέλεση μιας αξιολόγησης και η συνολική απόδοση της μεθόδου καθορίζεται με βάση τη μέση ακρίβειά της κατά τις διενεργηθείσες αξιολογήσεις.

Στην παρούσα μελέτη περίπτωσης χρησιμοποιήσαμε το πρώτο έτος δεδομένων (8760 παρατηρήσεις) για την εκπαίδευση των βασικών μοντέλων πρόβλεψης. Στη συνέχεια, χρησιμοποιήσαμε τα εκπαιδευμένα μοντέλα για την παραγωγή προβλέψεων για το επόμενο έτος, συγκεντρώνοντας ένα αρκετά μεγάλο σύνολο εκπαίδευσης για τον μετα-μαθητή. Κατά συνέπεια, εκπαιδύσαμε τον μετα-μαθητή και δοκιμάσαμε την απόδοσή του (μαζί με εκείνη των βασικών μοντέλων πρόβλεψης) χρησιμοποιώντας ένα σύνολο δοκιμών που αποτελείται από δεδομένα περίπου 6 μηνών με τρόπο κυλιόμενης προέλευσης.

Όσον αφορά τα μέτρα απόδοσης, εξετάζουμε τη ρίζα του μέσου τετραγωνικού σφάλματος (RMSE), ως εξής

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2},$$

όπου y_t είναι η πραγματική ηλεκτρική ενέργεια που παράγεται στο σημείο t , \hat{y}_t η αντίστοιχη πρόβλεψη της μεθόδου που αξιολογείται και n ο αριθμός των προβλέψεων που παράγονται κατά την εφαρμογή της αξιολόγησης κυλιόμενης προέλευσης. Χαμηλότερες τιμές RMSE υποδηλώνουν καλύτερη ακρίβεια. Δεδομένου ότι ο μέσος όρος ελαχιστοποιεί το άθροισμα των τετραγώνων των σφαλμάτων πρόβλεψης (Koutsandreas et al., 2022), το επιλεγμένο μέτρο καθίσταται ιδιαίτερα χρήσιμο για τον εντοπισμό μοντέλων που παρέχουν καλύτερες προβλέψεις, τόσο κατά μέσο όρο, όσο και κατά τις ώρες αιχμής της παραγωγής που είναι πιο κρίσιμες για τους παραγωγούς ενέργειας.

Ωστόσο, η ακρίβεια των μοντέλων πρόβλεψης της ηλιακής ή της Φ/B παραγωγής ενέργειας θα πρέπει να είναι μεταξύ τους συγκρίσιμη σε Φ/B συστήματα που βρίσκονται σε διαφορετικές τοποθεσίες ή με μετρήσεις που λαμβάνονται σε διαφορετικές εποχές (Yang, 2019b). Έτσι, ο δείκτης ικανότητας πρόβλεψης χρησιμοποιείται επιπλέον του μέτρου RMSE για την αξιολόγηση της σχετικής απόδοσης των μοντέλων πρόβλεψης (Yang, 2019a). Αυτή η μέτρηση βασίζεται στη σύγκριση του προτεινόμενου μοντέλου με ένα μοντέλο αναφοράς, χρησιμοποιώντας το RMSE ως βασικό μέτρο ακρίβειας. Ως μοντέλο αναφοράς, επιλέγουμε το μοντέλο εμμονής το οποίο υποθέτει ότι η μελλοντική κατάσταση (πρόβλεψη) θα είναι η ίδια με την παρούσα κατάσταση (πραγματική αξία) (Sarmas et al., 2022a). Το μοντέλο εμμονής είναι το πιο συνηθισμένο μοντέλο αναφοράς που χρησιμοποιείται στη βιβλιογραφία για την τυποποίηση της επαλήθευσης των μοντέλων πρόβλεψης της ηλιακής ενέργειας. Ο δείκτης ικανότητας πρόβλεψης ορίζεται ως εξής:

$$\text{Forecast Skill Index} = 1 - \frac{\text{RMSE}_{\text{proposed}}}{\text{RMSE}_{\text{reference}}} \quad (5.8)$$

όπου $\text{RMSE}_{\text{proposed}}$ και $\text{RMSE}_{\text{reference}}$ είναι οι εκτιμήσεις ακρίβειας των προτεινόμενων μοντέλων πρόβλεψης και των μοντέλων πρόβλεψης εμμονής σύμφωνα με το μέτρο RMSE, αντίστοιχα.

5.4.3 Μέθοδοι Πρόβλεψης

Αξιολογούμε την ακρίβεια πρόβλεψης των τεσσάρων βασικών μοντέλων και του μετα-μαθητή που περιγράφεται στην ενότητα 5.3. Αναμφίβολα, η αποτελεσματική εφαρμογή των προτεινόμενων μεθόδων εξαρτάται από την επιλογή των κατάλληλων χαρακτηριστικών που παρέχουν χρήσιμες πληροφορίες ως είσοδο στους αντίστοιχους αλγόριθμους πρόβλεψης. Με βάση τις γνώσεις της υποενότητας 7.4.1, και δεδομένου ότι μας ενδιαφέρει η ανάπτυξη NWP-independent μοντέλων, εξετάζουμε το ακόλουθο σύνολο χαρακτηριστικών:

- Η ένταση της ηλιακής ακτινοβολίας που μετρήθηκε τις τελευταίες έξι ώρες από τους μετεωρολογικούς σταθμούς.
- Χαρακτηριστικά που προσομοιώνουν τις εποχιακές και ημερολογιακές διακυμάνσεις της Φ/B παραγωγής, δηλαδή τον μήνα του έτους και την ώρα της ημέρας. Το πρώτο χαρακτηριστικό μετασχηματίζεται με τη χρήση κωδικοποίησης ενός σημείου, ενώ το δεύτερο με τη χρήση των μετασχηματισμών ημιτόνου και συνημιτόνου. Παρόμοια με την ηλιακή ακτινοβολία, τα εποχικά και ημερολογιακά χαρακτηριστικά εξάγονται για τις τελευταίες έξι ώρες.
- Παρελθούσες παρατηρήσεις της Φ/B παραγωγής (υστέρηση=1 έως υστέρηση=6), λαμβάνοντας υπόψη πιθανές αυτοσυσχετίσεις.
- Μια κατηγορική μεταβλητή που υποδεικνύει το προφίλ του καιρού των τελευταίων έξι ωρών. Για τον προσδιορισμό του προφίλ καιρού κάθε ώρας, οι παρατηρήσεις του συνόλου δεδομένων ομαδοποιούνται λαμβάνοντας υπόψη την ηλιακή ακτινοβολία, τη διάχυτη ηλιακή ακτινοβολία και τη θερμοκρασία ως δεδομένα εισόδου στον αλγόριθμο k-means με στόχο τη δημιουργία τριών ομάδων. Η έξοδος του αλγόριθμου μετασχηματίζεται με τη χρήση κωδικοποίησης ενός σημείου, με αποτέλεσμα να προκύπτουν συνολικά τρία δυαδικά χαρακτηριστικά. Το Σχήμα 5.2 απεικονίζει το είδος των πληροφοριών που παρέχουν οι συστάδες στις μεθόδους πρόβλεψης. Όπως φαίνεται, οι δύο πρώτες συστάδες αντιστοιχούν κυρίως σε ώρες που χαρακτηρίζονται από υψηλή και μεσαία ηλιακή ακτινοβολία, αντίστοιχα, ενώ η τρίτη συστάδα σε ώρες χαμηλής ακτινοβολίας και θερμοκρασίας.

Πίνακας 5.2: Προφίλ καιρού που δημιουργήθηκαν για το Φ/B εργοστάσιο "Joao". Για κάθε ένα από τα τρία προφίλ αναφέρεται ο μέσος όρος και η τυπική απόκλιση (σε παρένθεση) των μεταβλητών που χρησιμοποιήθηκαν για τη δημιουργία των συστάδων.

Cluster	Irradiance	Diffuse Irradiance	Temperature
1	709.95 (138.26)	168.75 (84.87)	23.34 (4.49)
2	316.18 (117.30)	129.78 (59.36)	17.76 (4.11)
3	13.13 (33.69)	8.01 (19.06)	14.94 (3.88)

Συνολικά, οι μέθοδοι πρόβλεψης περιλαμβάνουν 19 χαρακτηριστικά \times 6 υστερήσεις = 114 είσοδοι που κλιμακώνονται σε ένα εύρος μεταξύ μηδέν και ένα για να διευκολύνουν την εκπαίδευση και να επιτρέπουν καλύτερη γενίκευση.

5.4.4 Μετρικές Αξιολόγησης

Προκειμένου ο μετα-μαθητής να συμβάλει στην ακριβέστερη πρόβλεψη, οι προβλέψεις του θα πρέπει να υπερτερούν εκείνων των τεσσάρων βασικών μοντέλων που χρησιμοποιήθηκαν για την κατασκευή των τελικών προβλέψεων. Πρακτικά, ένα τέτοιο εύρημα θα έδειχνε ότι κανένα μεμονωμένο βασικό μοντέλο δεν είναι κατά μέσο όρο πιο ακριβές από τις "βέλτιστες" προβλέψεις που υπολογίζονται από τη μέθοδο μετα-μάθησης. Επομένως, τα φυσικά σημεία

αναφοράς της μελέτης μας είναι τα τέσσερα μοντέλα βάσης που περιγράφονται στην ενότητα 5.3.

Παρόλα αυτά, όπως παρουσιάστηκε στην ενότητα 5.1, τα σύνολα προβλέψεων συνήθως οδηγούν σε πιο ακριβή αποτελέσματα από τις προβλέψεις από τις οποίες αποτελούνται. Αυτό ισχύει ιδιαίτερα για τους απλούς συνδυασμούς που βασίζονται στο μέσο όρο ή τη διάμεσο των βασικών προβλέψεων (Makridakis et al., 2020). Για να αξιολογηθεί κατά πόσον ο μετα-μαθητής προσθέτει αξία σε σύγκριση με μια τέτοια προσέγγιση, εξετάζεται ο συνδυασμός των τεσσάρων βασικών μοντέλων με ίση στάθμιση (**Equal Weight - EW**) ως πρόσθετο σημείο αναφοράς.

5.4.5 Αποτελέσματα και Σχολιασμός

Ο Πίνακας 5.3 συνοψίζει ανά Φ/B σύστημα τη συνολική ακρίβεια του μετα-μαθητή, των τεσσάρων βασικών μοντέλων πρόβλεψης και του δείκτη αναφοράς EW από την άποψη του RMSE και του δείκτη ικανότητας πρόβλεψης.

Πίνακας 5.3: Συνολική ακρίβεια (RMSE και δείκτης ικανότητας πρόβλεψης) ανά μέθοδο πρόβλεψης και Φ/B σύστημα. Η ακριβέστερη μέθοδος πρόβλεψης για κάθε μονάδα και μέτρο ακρίβειας επισημαίνεται με έντονα γράμματα.


PV plant	Persistence	StackLSTM	BiLSTM	CNN-LSTM	ConvLSTM	EW	Meta
Joao	4.555	2.393	2.569	2.435	2.415	2.377	2.273
Julia Moreira	2.764	1.587	1.645	1.719	1.634	1.601	1.570
Zarco	4.798	2.413	2.323	2.497	2.434	2.312	2.298
							Forecast Skill Index
Joao	0	0.475	0.436	0.465	0.470	0.478	0.500
Julia Moreira	0	0.426	0.405	0.378	0.409	0.421	0.432
Zarco	0	0.497	0.516	0.479	0.493	0.518	0.521

Εστιάζοντας στην απόδοση των βασικών μοντέλων πρόβλεψης, παρατηρούμε ότι καμία από τις προσεγγίσεις πρόβλεψης δεν είναι κυρίαρχη, πράγμα που σημαίνει ότι διαφορετικά βασικά μοντέλα αποδίδουν καλύτερα ανάλογα με το υπό εξέταση Φ/B σύστημα. Κατά μέσο όρο, το StackLSTM φαίνεται να παρέχει ακριβέστερα αποτελέσματα, ακολουθούμενο από το ConvLSTM και το BiLSTM. Ωστόσο, οι διαφορές μεταξύ των επιμέρους βασικών μοντέλων δεν είναι ούτε συνεπείς ούτε σημαντικές. Το εύρημα αυτό υποστηρίζει την ανάγκη βέλτιστου συνδυασμού των προβλέψεων πολλαπλών μοντέλων για την αναζήτηση πιο γενικευμένων και ακριβών λύσεων πρόβλεψης.

Διαπιστώνουμε επίσης ότι, σύμφωνα με το RMSE, ο μετα-μαθητής καταφέρνει να παρέχει ακριβέστερα αποτελέσματα από τα βασικά μοντέλα πρόβλεψης σε όλα τα εξεταζόμενα Φ/B συστήματα, βελτιώνοντας την ακρίβεια έως και 5% σε σχέση με το ακριβέστερο βασικό μοντέλο ανά σύστημα. Ομοίως, ανάλογα με το Φ/B σύστημα, ο μετα-μαθητής υπερτερεί έναντι του προτύπου αναφοράς EW κατά 0.6 % έως 4.4 %. Αντίθετα, παρατηρούμε ότι παρόλο που το EW είναι κατά μέσο όρο ακριβέστερο από τα βασικά μοντέλα, σε ορισμένες περιπτώσεις το σημείο αναφοράς δεν καταφέρνει να ξεπεράσει το ακριβέστερο μεμονωμένο μοντέλο. Επομένως, συμπεραίνουμε ότι η προτεινόμενη προσέγγιση μετα-μάθησης μπορεί να συνδυάσει αποτελεσματικά τις προβλέψεις πολλαπλών μοντέλων, ξεπερνώντας τις τυπικές αλλά ανταγωνιστικές προσεγγίσεις συνδυασμών.

Για να συμπεράνουμε αν ο μετα-μαθητής παρέχει σημαντικά καλύτερες προβλέψεις, χρησιμοποιούμε το τεστ πολλαπλών συγκρίσεων με τον καλύτερο (**multiple comparisons with the best - MCB**) (Koning et al., 2005). Το MCB τεστ υπολογίζει τις μέσες θέσεις των μεθόδων πρόβλεψης σύμφωνα με το RMSE σε όλο το σύνολο των ωριαίων προβλέψεων όπου η πραγματική Φ/B παραγωγή είναι μεγαλύτερη από το μηδέν και συμπεραίνει αν οι θέσεις αυτές είναι στατιστικά διαφορετικές ή όχι. Στο Σχήμα 5.11 παρουσιάζονται τα αποτελέσματα της ανάλυσης για κάθε Φ/B σύστημα ξεχωριστά. Εάν τα διαστήματα των δύο μεθόδων δεν


επικαλύπτονται, αυτό υποδηλώνει στατιστικά διαφορετική απόδοση. Έτσι, οι μέθοδοι που δεν συμπίπτουν με το γκριζό διάστημα του σχήματος θεωρούνται σημαντικά χειρότερες από τις καλύτερες και αντίστροφα.



Σχήμα 5.11: Αποτελέσματα του τεστ Nemenyi σε επίπεδο σημαντικότητας 5% για το RMSE. Οι δοκιμές αφορούν εγγραφές όπου η πραγματική παραγωγή Φ/Β είναι μεγαλύτερη από το μηδέν.

Τα αποτελέσματα της δοκιμής MCB είναι ιδιαίτερα ελπιδοφόρα, υποδηλώνοντας ότι ο μετα-μαθητής παρέχει σημαντικά ακριβέστερες προβλέψεις από οποιοδήποτε από τα εξεταζόμενα κριτήρια αναφοράς σε δύο από τις τρεις Φ/Β εγκαταστάσεις. Στο τρίτο πάρκο, “Julia Moreira”, η προσέγγιση μετα-μάθησης κατατάσσεται επίσης πρώτη, αλλά η διαφορά της από τις προσεγγίσεις EW και StackLSTM είναι στατιστικά ασήμαντη.

Ως τελικό βήμα στην ανάλυσή μας, διερευνούμε πώς η ακρίβεια πρόβλεψης ποικίλλει ανάλογα με τον πραγματοποιούμενο συντελεστή δυναμικότητας. Αυτή η ανάλυση μπορεί να παράσχει περαιτέρω πληροφορίες υπό ποιες συνθήκες ο μετα-μαθητής αναμένεται να προσθέσει μεγαλύτερη αξία όσον αφορά τη βελτίωση της ακρίβειας πρόβλεψης. Το Σχήμα 5.12 συνοψίζει την ακρίβεια του μετα-μαθητή και των σημείων αναφοράς σύμφωνα με το RMSE για διαφορετικούς συντελεστές υλοποιημένης χωρητικότητας. Όπως φαίνεται, στις περισσότερες περιπτώσεις η ακρίβεια του μετα-μαθητή είναι είτε καλύτερη είτε ισοδύναμη με εκείνη των σημείων αναφοράς, με τις περισσότερες βελτιώσεις να έρχονται όταν ο συντελεστής δυναμικότητας είναι σχετικά υψηλότερος. Η παρατήρηση αυτή υποστηρίζει την αρχική μας διαπίστωση ότι ο μετα-μαθητής είναι πιθανότερο να βελτιώσει την ακρίβεια πρόβλεψης σε ώρες αιχμής.



Σχήμα 5.12: Ακρίβεια πρόβλεψης (RMSE) για διαφορετικούς συντελεστές δυναμικότητας. Το RMSE του συντελεστή δυναμικότητας x % αντιστοιχεί στα μέσα σφάλματα πρόβλεψης των συντελεστών δυναμικότητας μέχρι x %.

5.5 Συμπεράσματα

Στο παρόν κεφάλαιο παρουσιάστηκε μια ολοκληρωμένη μέθοδος για τη βραχυπρόθεσμη πρόβλεψη της παραγωγής Φ/B . Η μέθοδος που αναπτύχθηκε εισάγει τέσσερα μοντέλα LSTM διαφορετικής βαθιάς αρχιτεκτονικής που μπορούν να προβλέψουν με ακρίβεια τη Φ/B παραγωγή την επόμενη ώρα. Οι προβλέψεις αυτών των μοντέλων χρησιμεύουν ως βάση ενός μοντέλου μετα-μάθησης, το οποίο έχει ως αποστολή να συνδυάζει βέλτιστα αυτές τις προβλέψεις, λαμβάνοντας υπόψη πρόσθετα εξωτερικά χαρακτηριστικά ως είσοδο, όπως καιρικές και εποχιακές μεταβλητές. Αποτελεσματικά, ο μετα-μαθητής συνδυάζει τις προβλέψεις βάσης εκμεταλλευόμενος τα πλεονεκτήματα κάθε βασικού μοντέλου, βελτιώνοντας τη συνολική ακρίβεια και γενίκευση της προτεινόμενης λύσης. Επίσης, η μέθοδος που παρουσιάζεται είναι NWP-independent, υπό την έννοια ότι τα αξιοποιούμενα χαρακτηριστικά του καιρού αναφέρονται σε προηγούμενα χρονικά βήματα, με αποτέλεσμα να είναι πιο αξιόπιστη και γρήγορη στην ανάπτυξη και εφαρμογή.

Η προτεινόμενη μεθοδολογία αξιολογήθηκε χρησιμοποιώντας δεδομένα από τρεις Φ/B εγκαταστάσεις σε στέγες που βρίσκονται στη Λισαβόνα της Πορτογαλίας. Τα αποτελέσματά μας επιβεβαιώνουν ότι διαφορετικά μοντέλα βάσης αποδίδουν καλύτερα σε διαφορετικές εγκαταστάσεις. Επιπλέον, τα ευρήματά μας δείχνουν ότι η μετα-μάθηση μπορεί να βελτιώσει σημαντικά την ακρίβεια πρόβλεψης κατά μέσο όρο. Επίσης, μια μετα-ανάλυση των αποτελεσμάτων υποδεικνύει ότι η μετα-μάθηση συμβάλλει περισσότερο στις ώρες αιχμής της παραγωγής, δηλαδή όταν η πραγματοποίηση ακριβών προβλέψεων είναι πιο δύσκολη και χρήσιμη για τους υπεύθυνους λήψης αποφάσεων.

Η μελλοντική έρευνα θα μπορούσε να επικεντρωθεί στην εξέταση του τρόπου με τον οποίο η μετα-μάθηση μπορεί να ωφελήσει τα μοντέλα πρόβλεψης Φ/B παραγωγής ενέργειας πολλαπλών βημάτων. Είναι κοινά αποδεκτό ότι η απόδοση των NWP-independent μοντέλων μειώνεται σημαντικά σε μερικές ώρες, γεγονός που τα καθιστά λιγότερο αξιόπιστα από τα μοντέλα που στηρίζονται σε NWPs για π.χ. την πρόβλεψη της ημέρας. Όπως και να έχει, η μετα-μάθηση θα μπορούσε να χρησιμοποιηθεί για να βελτιώσει την απόδοση των βασικών μοντέλων που χρησιμοποιούνται για την πραγματοποίηση τέτοιων προβλέψεων. Επιπλέον, η μελλοντική έρευνα θα μπορούσε να διερευνήσει άλλους τύπους μοντέλων ως μετα-μαθητές και να συγκρίνει την απόδοσή τους με την προτεινόμενη μέθοδο SVR. Αν και η χρήση του μοντέλου SVR είναι επαρκώς αιτιολογημένη, η εξέταση διαφορετικών χαρακτηριστικών και βασικών προβλέψεων ως εισροών του μετα-μαθητή θα μπορούσε ενδεχομένως να επηρεάσει την επιλογή του μετα-μαθητή. Θα μπορούσε επίσης να δοθεί μεγαλύτερη έμφαση στην επιλογή και την ανάπτυξη των βασικών μοντέλων. Η BM είναι ένα ισχυρό εργαλείο στα χέρια των προβλέψεων και των επιστημόνων δεδομένων, αλλά οι δυνατότητές της δεν έχουν ακόμη αξιοποιηθεί πλήρως. Κατά συνέπεια, η περαιτέρω βελτίωση της απόδοσης του βασικού μοντέλου μέσω διαφορετικών αρχιτεκτονικών BM και καλύτερης επιλογής χαρακτηριστικών και τεχνικών προεπεξεργασίας δεδομένων θα μπορούσε να αποτελέσει μέρος της μελλοντικής εργασίας που θα γίνει στον τομέα. Τέλος, θα ήταν ενδιαφέρον να διερευνηθεί η επίδραση του μετα-μαθητή σε πιθανοτικές ρυθμίσεις πρόβλεψης αντί για ντετερμινιστικές.

Βιβλιογραφία

- Abdel-Basset, M., Hawash, H., Chakraborty, R. K., and Ryan, M. (2021). Pv-net: An innovative deep learning approach for efficient forecasting of short-term photovoltaic energy production. *Journal of Cleaner Production*, 303:127037.
- Ahlborg, H. and Hammar, L. (2014). Drivers and barriers to rural electrification in tanzania and mozambique—grid-extension, off-grid, and renewable energy technologies. *Renewable Energy*, 61:117–124.
- Ahmed, R., Sreeram, V., Mishra, Y., and Arif, M. (2020). A review and evaluation of the state-of-the-art in pv solar power forecasting: Techniques and optimization. *Renewable and Sustainable Energy Reviews*, 124:109792.
- Akhter, M. N., Mekhilef, S., Mokhlis, H., and Mohamed Shah, N. (2019). Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques. *IET Renewable Power Generation*, 13(7):1009–1023.
- Almonacid, F., Pérez-Higueras, P., Fernández, E. F., and Hontoria, L. (2014). A methodology based on dynamic artificial neural network for short-term forecasting of the power output of a pv generator. *Energy Conversion and Management*, 85:389–398.
- Antonanzas, J., Osorio, N., Escobar, R., Urraca, R., Martinez-de Pison, F. J., and Antonanzas-Torres, F. (2016). Review of photovoltaic power forecasting. *Solar energy*, 136:78–111.
- Aslam, S., Herodotou, H., Mohsin, S. M., Javaid, N., Ashraf, N., and Aslam, S. (2021). A survey on deep learning methods for power load and renewable energy forecasting in smart microgrids. *Renewable and Sustainable Energy Reviews*, 144:110992.
- Bacher, P., Madsen, H., and Nielsen, H. A. (2009). Online short-term solar power forecasting. *Solar energy*, 83(10):1772–1783.
- Bengio, Y. et al. (2009). Learning deep architectures for ai. *Foundations and trends® in Machine Learning*, 2(1):1–127.
- Chaturvedi, D. and Isha, I. (2016). Solar power forecasting: A review. *International Journal of Computer Applications*, 145(6):28–50.
- Chen, T., Xu, R., He, Y., and Wang, X. (2017). Improving sentiment analysis via sentence type classification using bilstm-crf and cnn. *Expert Systems with Applications*, 72:221–230.
- Chollet, F. et al. (2015). Keras. <https://keras.io>.
- Das, U. K., Tey, K. S., Seyedmahmoudian, M., Mekhilef, S., Idris, M. Y. I., Van Deventer, W., Horan, B., and Stojcevski, A. (2018). Forecasting of photovoltaic power generation and model optimization: A review. *Renewable and Sustainable Energy Reviews*, 81:912–928.
- De Benedetti, M., Leonardi, F., Messina, F., Santoro, C., and Vasilakos, A. (2018). Anomaly detection and predictive maintenance for photovoltaic systems. *Neurocomputing*, 310:59–68.
- Dolara, A., Grimaccia, F., Leva, S., Mussetta, M., and Ogliari, E. (2015). A physical hybrid artificial neural network for short term forecasting of pv plant power output. *Energies*, 8(2):1138–1153.

- Donahue, J., Anne Hendricks, L., Guadarrama, S., Rohrbach, M., Venugopalan, S., Saenko, K., and Darrell, T. (2015). Long-term recurrent convolutional networks for visual recognition and description. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2625–2634.
- Du Plessis, A., Strauss, J., and Rix, A. (2021). Short-term solar power forecasting: Investigating the ability of deep learning models to capture low-level utility-scale photovoltaic system behaviour. *Applied Energy*, 285:116395.
- Eom, H., Son, Y., and Choi, S. (2020). Feature-selective ensemble learning-based long-term regional pv generation forecasting. *IEEE access*, 8:54620–54630.
- González Ordiano, J. Á., Waczowicz, S., Reischl, M., Mikut, R., and Hagenmeyer, V. (2017). Photovoltaic power forecasting using simple data-driven models without weather data. *Computer Science-Research and Development*, 32(1):237–246.
- Graves, A. (2013). Generating sequences with recurrent neural networks. *arXiv preprint arXiv:1308.0850*.
- Graves, A., Liwicki, M., Fernández, S., Bertolami, R., Bunke, H., and Schmidhuber, J. (2008). A novel connectionist system for unconstrained handwriting recognition. *IEEE transactions on pattern analysis and machine intelligence*, 31(5):855–868.
- Graves, A. and Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional lstm and other neural network architectures. *Neural networks*, 18(5-6):602–610.
- Gupta, P. and Singh, R. (2021). Pv power forecasting based on data-driven models: a review. *International Journal of Sustainable Engineering*, 14(6):1733–1755.
- Gürtler, M. and Paulsen, T. (2018). The effect of wind and solar power forecasts on day-ahead and intraday electricity prices in germany. *Energy Economics*, 75:150–162.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778.
- Hermans, M. and Schrauwen, B. (2013). Training and analysing deep recurrent neural networks. *Advances in neural information processing systems*, 26.
- Hochreiter, S. (1998). The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 6(02):107–116.
- Hospedales, T., Antoniou, A., Micaelli, P., and Storkey, A. (2020). Meta-learning in neural networks: A survey. *arXiv preprint arXiv:2004.05439*.
- Huang, C.-J. and Kuo, P.-H. (2019). Multiple-input deep convolutional neural network model for short-term photovoltaic power forecasting. *IEEE access*, 7:74822–74834.
- Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4700–4708.
- Jain, S., Sharma, T., and Gupta, A. K. (2022). End-of-life management of solar pv waste in india: Situation analysis and proposed policy framework. *Renewable and Sustainable Energy Reviews*, 153:111774.

- Jayalakshmi, N. Y., Shankar, R., Subramaniam, U., Baranilingesan, I., Karthick, A., Stalin, B., Rahim, R., and Ghosh, A. (2021). Novel multi-time scale deep learning algorithm for solar irradiance forecasting. *Energies*, 14(9):2404.
- Khan, W., Walker, S., and Zeiler, W. (2022). Improved solar photovoltaic energy generation forecast using deep learning-based ensemble stacking approach. *Energy*, 240:122812.
- Koning, A. J., Franses, P. H., Hibon, M., and Stekler, H. (2005). The M3 competition: Statistical tests of the results. *International Journal of Forecasting*, 21(3):397–409.
- Koutsandreas, D., Spiliotis, E., Petropoulos, F., and Assimakopoulos, V. (2022). On the selection of forecasting accuracy measures. *Journal of the Operational Research Society*, 73(5):937–954.
- Lateko, A. A., Yang, H.-T., Huang, C.-M., Aprillia, H., Hsu, C.-Y., Zhong, J.-L., and Phuong, N. H. (2021). Stacking ensemble method with the rnn meta-learner for short-term pv power forecasting. *Energies*, 14(16):4733.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *nature*, 521(7553):436–444.
- Lee, D. and Kim, K. (2021). Pv power prediction in a peak zone using recurrent neural networks in the absence of future meteorological information. *Renewable Energy*, 173:1098–1110.
- Lee, J. and Shepley, M. M. (2020). Benefits of solar photovoltaic systems for low-income families in social housing of korea: Renewable energy applications as solutions to energy poverty. *Journal of Building Engineering*, 28:101016.
- Lee, W., Kim, K., Park, J., Kim, J., and Kim, Y. (2018). Forecasting solar power using long-short term memory and convolutional neural networks. *IEEE access*, 6:73068–73080.
- Lei, M., Shiyan, L., Chuanwen, J., Hongling, L., and Yan, Z. (2009). A review on the forecasting of wind speed and generated power. *Renewable and sustainable energy reviews*, 13(4):915–920.
- Leva, S., Dolara, A., Grimaccia, F., Mussetta, M., and Ogliari, E. (2017). Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power. *Mathematics and computers in simulation*, 131:88–100.
- Li, G., Wang, H., Zhang, S., Xin, J., and Liu, H. (2019). Recurrent neural networks based photovoltaic power forecasting approach. *Energies*, 12(13):2538.
- Li, P., Zhou, K., Lu, X., and Yang, S. (2020). A hybrid deep learning model for short-term pv power forecasting. *Applied Energy*, 259:114216.
- Li, Z., Liu, F., Yang, W., Peng, S., and Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*.
- Liu, C.-H., Gu, J.-C., and Yang, M.-T. (2021). A simplified lstm neural networks for one day-ahead solar power forecasting. *IEEE Access*, 9:17174–17195.
- Liu, L., Zhan, M., and Bai, Y. (2019). A recursive ensemble model for forecasting the power output of photovoltaic systems. *Solar Energy*, 189:291–298.
- Liu, L., Zhao, Y., Chang, D., Xie, J., Ma, Z., Sun, Q., Yin, H., and Wennersten, R. (2018). Prediction of short-term pv power output and uncertainty analysis. *Applied energy*, 228:700–711.

- Livieris, I. E., Pintelas, E., and Pintelas, P. (2020). A cnn-lstm model for gold price time-series forecasting. *Neural computing and applications*, 32(23):17351–17360.
- Maity, I. and Rao, S. (2010). Simulation and pricing mechanism analysis of a solar-powered electrical microgrid. *IEEE Systems Journal*, 4(3):275–284.
- Makridakis, S., Spiliotis, E., and Assimakopoulos, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1):54–74.
- Markovics, D. and Mayer, M. J. (2022). Comparison of machine learning methods for photovoltaic power forecasting based on numerical weather prediction. *Renewable and Sustainable Energy Reviews*, 161:112364.
- Mathiesen, P. and Kleissl, J. (2011). Evaluation of numerical weather prediction for intraday solar forecasting in the continental united states. *Solar Energy*, 85(5):967–977.
- Mayer, M. J. (2022). Benefits of physical and machine learning hybridization for photovoltaic power forecasting. *Renewable and Sustainable Energy Reviews*, 168:112772.
- Mayer, M. J. and Gróf, G. (2021). Extensive comparison of physical models for photovoltaic power forecasting. *Applied Energy*, 283:116239.
- Mellit, A. and Pavan, A. M. (2010). A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected pv plant at trieste, italy. *Solar energy*, 84(5):807–821.
- Mellit, A., Pavan, A. M., and Lughi, V. (2014). Short-term forecasting of power production in a large-scale photovoltaic plant. *Solar Energy*, 105:401–413.
- Mellit, A., Pavan, A. M., and Lughi, V. (2021). Deep learning neural networks for short-term photovoltaic power forecasting. *Renewable Energy*, 172:276–288.
- Mishra, M., Dash, P. B., Nayak, J., Naik, B., and Swain, S. K. (2020). Deep learning and wavelet transform integrated approach for short-term solar pv power prediction. *Measurement*, 166:108250.
- Montero-Manso, P., Athanasopoulos, G., Hyndman, R. J., and Talagala, T. S. (2020). FFORMA: Feature-based forecast model averaging. *International Journal of Forecasting*, 36(1):86–92.
- Ogliari, E., Dolara, A., Manzolini, G., and Leva, S. (2017). Physical and hybrid methods comparison for the day ahead pv output power forecast. *Renewable energy*, 113:11–21.
- Olabi, A. and Abdelkareem, M. A. (2022). Renewable energy and climate change. *Renewable and Sustainable Energy Reviews*, 158:112111.
- Olah, C. (2015). Understanding lstm networks.
- Pascanu, R., Gulcehre, C., Cho, K., and Bengio, Y. (2013). How to construct deep recurrent neural networks. *arXiv preprint arXiv:1312.6026*.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.

- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Ben Taieb, S., Bergmeir, C., Bessa, R. J., Bijak, J., Boylan, J. E., Browell, J., Carnevale, C., Castle, J. L., Cirillo, P., Clements, M. P., Cordeiro, C., Cyrino Oliveira, F. L., De Baets, S., Dokumentov, A., Ellison, J., Fiszeder, P., Franses, P. H., Frazier, D. T., Gilliland, M., Gönül, M. S., Goodwin, P., Grossi, L., Grushka-Cockayne, Y., Guidolin, M., Guidolin, M., Gunter, U., Guo, X., Guseo, R., Harvey, N., Hendry, D. F., Hollyman, R., Januschowski, T., Jeon, J., Jose, V. R. R., Kang, Y., Koehler, A. B., Kolassa, S., Kourentzes, N., Leva, S., Li, F., Litsiou, K., Makridakis, S., Martin, G. M., Martinez, A. B., Meeran, S., Modis, T., Nikolopoulos, K., Önkál, D., Paccagnini, A., Panagiotelis, A., Panapakidis, I., Pavía, J. M., Pedio, M., Pedregal, D. J., Pinson, P., Ramos, P., Rappach, D. E., Reade, J. J., Rostami-Tabar, B., Rubaszek, M., Sermpinis, G., Shang, H. L., Spiliotis, E., Syntetos, A. A., Talagala, P. D., Talagala, T. S., Tashman, L., Thomakos, D., Thorarinsdottir, T., Todini, E., Trapero Arenas, J. R., Wang, X., Winkler, R. L., Yusupova, A., and Ziel, F. (2022). Forecasting: theory and practice. *International Journal of Forecasting*, 38(3):705–871.
- Rai, A., Shrivastava, A., and Jana, K. C. (2022). A robust auto encoder-gated recurrent unit (ae-gru) based deep learning approach for short term solar power forecasting. *Optik*, 252:168515.
- Rana, M., Koprinska, I., and Agelidis, V. G. (2016). Univariate and multivariate methods for very short-term solar photovoltaic power forecasting. *Energy Conversion and Management*, 121:380–390.
- Rawat, W. and Wang, Z. (2017). Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*, 29(9):2352–2449.
- Reindl, K. and Palm, J. (2021). Installing pv: Barriers and enablers experienced by non-residential property owners. *Renewable and Sustainable Energy Reviews*, 141:110829.
- Rodríguez, F., Fleetwood, A., Galarza, A., and Fontán, L. (2018). Predicting solar energy generation through artificial neural networks using weather forecasts for microgrid control. *Renewable energy*, 126:855–864.
- Romaní, J., Belusko, M., Alemu, A., Cabeza, L. F., de Gracia, A., and Bruno, F. (2018). Control concepts of a radiant wall working as thermal energy storage for peak load shifting of a heat pump coupled to a PV array. *Renewable Energy*, 118:489–501.
- Sagheer, A. and Kotb, M. (2019). Time series forecasting of petroleum production using deep LSTM recurrent networks. *Neurocomputing*, 323:203–213.
- Sajjad, M., Kwon, S., et al. (2020). Clustering-based speech emotion recognition by incorporating learned features and deep bilstm. *IEEE Access*, 8:79861–79875.
- Sarmas, E., Dimitropoulos, N., Marinakis, V., Mylona, Z., and Doukas, H. (2022a). Transfer learning strategies for solar power forecasting under data scarcity. *Scientific Reports*, 12(1):1–13.
- Sarmas, E., Spiliotis, E., Marinakis, V., Koutselis, T., and Doukas, H. (2022b). A meta-learning classification model for supporting decisions on energy efficiency investments. *Energy and Buildings*, 258:111836.
- Sarmas, E., Spiliotis, E., Marinakis, V., Tzanes, G., Kaldellis, J. K., and Doukas, H. (2022c). ML-based energy management of water pumping systems for the application of peak shaving in small-scale islands. *Sustainable Cities and Society*, 82:103873.

- Schölkopf, B. and Smola, A. J. (2001). *Learning with kernel: Support Vector Machines, Regularization, Optimization and Beyond*. The MIT Press.
- Schuster, M. and Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE transactions on Signal Processing*, 45(11):2673–2681.
- Shaahid, S. and El-Amin, I. (2009). Techno-economic evaluation of off-grid hybrid photovoltaic–diesel–battery power systems for rural electrification in saudi arabia—a way forward for sustainable development. *Renewable and sustainable energy reviews*, 13(3):625–633.
- Sharadga, H., Hajimirza, S., and Balog, R. S. (2020). Time series forecasting of solar power generation for large-scale photovoltaic plants. *Renewable Energy*, 150:797–807.
- Sharma, V., Yang, D., Walsh, W., and Reindl, T. (2016). Short term solar irradiance forecasting using a mixed wavelet neural network. *Renewable Energy*, 90:481–492.
- Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., and Woo, W.-c. (2015). Convolutional lstm network: A machine learning approach for precipitation nowcasting. *Advances in neural information processing systems*, 28.
- Sobri, S., Koohi-Kamali, S., and Rahim, N. A. (2018). Solar photovoltaic generation forecasting methods: A review. *Energy Conversion and Management*, 156:459–497.
- Spiliotis, E., Legaki, N. Z., Assimakopoulos, V., Doukas, H., and El Moursi, M. S. (2018). Tracking the performance of photovoltaic systems: a tool for minimising the risk of malfunctions and deterioration. *IET Renewable Power Generation*, 12(7):815–822.
- Spiliotis, E., Petropoulos, F., Kourentzes, N., and Assimakopoulos, V. (2020). Cross-temporal aggregation: Improving the forecast accuracy of hierarchical electricity consumption. *Applied Energy*, 261:114339.
- Sun, Y., Venugopal, V., and Brandt, A. R. (2019). Short-term solar power forecast with deep learning: Exploring optimal input and output configuration. *Solar Energy*, 188:730–741.
- Talaat, M., Said, T., Essa, M. A., and Hatata, A. (2022). Integrated mffnn-mvo approach for pv solar power forecasting considering thermal effects and environmental conditions. *International Journal of Electrical Power & Energy Systems*, 135:107570.
- Tascikaraoglu, A., Erdinc, O., Uzunoglu, M., and Karakas, A. (2014). An adaptive load dispatching and forecasting strategy for a virtual power plant including renewable energy conversion units. *Applied energy*, 119:445–453.
- Tashman, L. J. (2000). Out-of-sample tests of forecasting accuracy: an analysis and review. *International Journal of Forecasting*, 16(4):437–450.
- Tassenoy, R., Couvreur, K., Beyne, W., De Paepe, M., and Lecompte, S. (2022). Techno-economic assessment of Carnot batteries for load-shifting of solar PV production of an office building. *Renewable Energy*, 199:1133–1144.
- Todorovski, L. and Džeroski, S. (2000). Combining multiple models with meta decision trees. In *European conference on principles of data mining and knowledge discovery*, pages 54–64. Springer.
- Torres, J. F., Troncoso, A., Koprinska, I., Wang, Z., and Martínez-Álvarez, F. (2018). Deep learning for big data time series forecasting applied to solar power. In *The 13th International Conference on Soft Computing Models in Industrial and Environmental Applications*, pages 123–133. Springer.

- Tuohy, A., Zack, J., Haupt, S. E., Sharp, J., Ahlstrom, M., Dise, S., Gritmit, E., Mohrlen, C., Lange, M., Casado, M. G., et al. (2015). Solar forecasting: methods, challenges, and performance. *IEEE Power and Energy Magazine*, 13(6):50–59.
- VanDeventer, W., Jamei, E., Thirunavukkarasu, G. S., Seyedmahmoudian, M., Soon, T. K., Horan, B., Mekhilef, S., and Stojcevski, A. (2019). Short-term pv power forecasting using hybrid gasvm technique. *Renewable energy*, 140:367–379.
- Vanschoren, J. (2019). Meta-learning. In *Automated machine learning*, pages 35–61. Springer, Cham.
- Visser, L., AlSkaif, T., and van Sark, W. (2022). Operational day-ahead solar power forecasting for aggregated PV systems with a varying spatial distribution. *Renewable Energy*, 183:267–282.
- Vu, B. H. and Chung, I.-Y. (2022). Optimal generation scheduling and operating reserve management for PV generation using RNN-based forecasting models for stand-alone microgrids. *Renewable Energy*, 195:1137–1154.
- Wan, C., Zhao, J., Song, Y., Xu, Z., Lin, J., and Hu, Z. (2015). Photovoltaic and solar power forecasting for smart grid energy management. *CSEE Journal of Power and Energy Systems*, 1(4):38–46.
- Wang, D. and Nyberg, E. (2015). A long short-term memory model for answer sentence selection in question answering. In *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 2: Short Papers)*, pages 707–712.
- Wang, F., Xuan, Z., Zhen, Z., Li, K., Wang, T., and Shi, M. (2020a). A day-ahead pv power forecasting method based on lstm-rnn model and time correlation modification under partial daily pattern prediction framework. *Energy Conversion and Management*, 212:112766.
- Wang, J., Li, P., Ran, R., Che, Y., and Zhou, Y. (2018a). A short-term photovoltaic power prediction model based on the gradient boost decision tree. *Applied Sciences*, 8(5):689.
- Wang, J., Qian, Z., Wang, J., and Pei, Y. (2020b). Hour-ahead photovoltaic power forecasting using an analog plus neural network ensemble method. *Energies*, 13(12):3259.
- Wang, K., Qi, X., and Liu, H. (2019). A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network. *Applied Energy*, 251:113315.
- Wang, Y., Liao, W., and Chang, Y. (2018b). Gated recurrent unit network-based short-term photovoltaic forecasting. *Energies*, 11(8):2163.
- Wen, L., Zhou, K., Yang, S., and Lu, X. (2019). Optimal load dispatch of community microgrid with deep learning based solar power and load forecasting. *Energy*, 171:1053–1065.
- Wolpert, D. H. (1992). Stacked generalization. *Neural networks*, 5(2):241–259.
- Wu, Y., Liu, Z., Li, B., Liu, J., and Zhang, L. (2022). Energy management strategy and optimal battery capacity for flexible PV-battery system under time-of-use tariff. *Renewable Energy*, 200:558–570.
- Yang, D. (2019a). A guideline to solar forecasting research practice: Reproducible, operational, probabilistic or physically-based, ensemble, and skill (ropes). *Journal of Renewable and Sustainable Energy*, 11(2):022701.

- Yang, D. (2019b). Making reference solar forecasts with climatology, persistence, and their optimal convex combination. *Solar Energy*, 193:981–985.
- Yang, Z., Mourshed, M., Liu, K., Xu, X., and Feng, S. (2020). A novel competitive swarm optimized rbf neural network model for short-term solar power generation forecasting. *Neurocomputing*, 397:415–421.
- Yao, Y. and Huang, Z. (2016). Bi-directional lstm recurrent neural network for chinese word segmentation. In *International conference on neural information processing*, pages 345–353. Springer.
- Zameer, A., Arshad, J., Khan, A., and Raja, M. A. Z. (2017). Intelligent and robust prediction of short term wind power using genetic programming based ensemble of neural networks. *Energy conversion and management*, 134:361–372.
- Zang, H., Cheng, L., Ding, T., Cheung, K. W., Wei, Z., and Sun, G. (2020). Day-ahead photovoltaic power forecasting approach based on deep convolutional neural networks and meta learning. *International Journal of Electrical Power & Energy Systems*, 118:105790.
- Zhao, J., Guo, Z.-H., Su, Z.-Y., Zhao, Z.-Y., Xiao, X., and Liu, F. (2016). An improved multi-step forecasting model based on WRF ensembles and creative fuzzy systems for wind speed. *Applied Energy*, 162:808–826.
- Zhu, R., Guo, W., and Gong, X. (2019). Short-term photovoltaic power output prediction based on k-fold cross-validation and an ensemble model. *Energies*, 12(7):1220.

Κεφάλαιο 6

Τεχνικές Μεταφοράς Μάθησης για την Πρόβλεψη Παραγωγής Φ/Β υπό καθεστώς Έλλειψης Δεδομένων

6.1 Εισαγωγή

Το κεφάλαιο αυτό παρουσιάζει ορισμένες τεχνικές Μεταφοράς Μάθησης (**Transfer Learning - TL**) με στόχο να προσδιοριστεί κατά πόσον μπορεί να χρησιμοποιηθεί αποτελεσματικά για την παροχή προβλέψεων Φ/Β παραγωγής για εγκαταστάσεις με περιορισμένο όγκο δεδομένων. Αναπτύσσονται τρεις στρατηγικές TL που βασίζονται σε μια στοιβαγμένη αρχιτεκτονική LSTM και συγκρίνονται με μια προσέγγιση χωρίς TL. Η μεθοδολογία που παρουσιάζεται δοκιμάζεται σε Φ/Β συστήματα παραγωγής ενέργειας σε διαφορετικές πόλεις και με διαφορετική ονομαστική ισχύ. Τα ευρήματα της πειραματικής εφαρμογής δείχνουν ότι και οι τρεις στρατηγικές TL υπερτερούν σημαντικά της προσέγγισης χωρίς TL όσον αφορά την ακρίβεια πρόβλεψης, η οποία αξιολογείται με διάφορους δείκτες σφάλματος.

Οι επιπτώσεις της αστικοποίησης είναι εμφανείς κατά τις τελευταίες δεκαετίες, καθώς όλο και περισσότεροι άνθρωποι μετακινούνται στις πόλεις, με αποτέλεσμα πάνω από το 90% των ανθρωπογενών εκπομπών διοξειδίου του άνθρακα να παράγεται σε αστικά περιβάλλοντα (Svirejeva-Hopkins et al., 2004). Αυτή η νέα πραγματικότητα ανέδειξε την ανάγκη για σταδιακή μετάβαση σε έξυπνες πόλεις, όπου η λειτουργική αποτελεσματικότητα βελτιώνεται με τη χρήση αναδυόμενων εφαρμογών τεχνολογίας πληροφοριών και επικοινωνιών (Kolokotsa, 2016; Pira, 2021). Παράλληλα, ο αντίκτυπος της εποχής της ψηφιοποίησης είναι πιο εμφανής από ποτέ, βελτιώνοντας την ποιότητα ζωής μέσω της ψηφιακής αυτοματοποίησης πολύπλοκων διαδικασιών (Nižetić et al., 2019; Ng et al., 2021). Αυτός ο μετασχηματισμός δεν θα μπορούσε να αφήσει ανεπηρέαστο τον τομέα της ενέργειας, καθώς η σύγκλιση της ηλεκτρικής ενέργειας και των δεδομένων προσφέρει ευκαιρίες για νέες υπηρεσίες (Marinakis et al., 2020), με στόχο τη μείωση του κόστους και την αναδιαμόρφωση των επιχειρηματικών μοντέλων (Ghobakhloo and Fathi, 2021). Στο πλαίσιο ενός συνεχώς εξελισσόμενου αστικού περιβάλλοντος, είναι σημαντικό να προωθηθεί η έννοια των ενεργειακών κοινοτήτων, δηλαδή η οργάνωση συλλογικών ενεργειακών δράσεων γύρω από την ανοικτή, δημοκρατική συμμετοχή και διακυβέρνηση (Gjorgievski et al., 2021).

Ένα σημαντικό σημείο ενδιαφέροντος για τις ενεργειακές κοινότητες είναι η αποτελεσματική πρόβλεψη της παραγωγής ηλεκτρικής ενέργειας από Ανανεώσιμες Πηγές Ενέργειας (ΑΠΕ), καθώς, όπως είδαμε και στο προηγούμενο κεφάλαιο, είναι ζωτικής σημασίας για την εξισορρόπηση της προσφοράς και της ζήτησης ηλεκτρικής ενέργειας και, κατά συνέπεια, για τον προγραμματισμό και την ανάλυση των δικτύων διανομής και τη διασφάλιση της κοινοτικής αυτονομίας (Pena-Bello et al., 2021). Πιο συγκεκριμένα, τα Φ/Β συστήματα σε στέγες είναι

μια από τις πιο υποσχόμενες πηγές παραγωγής ενέργειας για τους παραγωγούς-καταναλωτές σε μεγάλες πόλεις (Miranda et al., 2015). Μελέτες έχουν δείξει ότι τα Φ/Β συστήματα στέγης μπορούν να καλύψουν σχεδόν πλήρως την εγχώρια ζήτηση ηλεκτρικής ενέργειας για τους παραγωγούς-καταναλωτές, γεγονός που δείχνει ότι οι αυτόνομοι πόλεις αναμένεται να είναι πρωταγωνιστές της εποχής της ενεργειακής μετάβασης (Gómez-Navarro et al., 2021). Ωστόσο, τα αποτελεσματικά συστήματα αυτοπαραγωγής βασίζονται σε ακριβή μοντέλα πρόβλεψης της ηλιακής παραγωγής. Το πρόβλημα γίνεται πιο απαιτητικό όταν λαμβάνεται υπόψη η έλλειψη δεδομένων, η οποία αποτελεί σύνηθες φαινόμενο στην περίπτωση των πρόσφατα εγκατεστημένων Φ/Β συστημάτων, όπου απαιτείται μεγάλο χρονικό διάστημα για τη συλλογή επαρκούς δείγματος δεδομένων. Στο κεφάλαιο αυτό παρουσιάζεται μια προσέγγιση TL για την πρόβλεψη της παραγωγής Φ/Β στην περίπτωση έλλειψης δεδομένων, όπου τα προγνωστικά μοντέλα BM εκπαιδεύονται σε Φ/Β συστήματα με επάρκεια δεδομένων και μεταφέρουν τη γνώση σε Φ/Β συστήματα με μικρό δείγμα διαθέσιμων δεδομένων.

6.2 Αναλυτική Διατύπωση Προβλήματος

Όπως είδαμε και στο προηγούμενο κεφάλαιο, έχουν προταθεί διάφορες προσεγγίσεις για το πρόβλημα της πρόβλεψης της παραγωγής ενέργειας σε Φ/Β. Η απλούστερη προσέγγιση είναι η απλή μέθοδος εμμονής, η οποία υποθέτει ότι η παραγόμενη ισχύς θα παραμείνει ίδια με την προηγούμενη παρατήρηση. Μια πιο σύνθετη παραλλαγή αυτής της προσέγγισης είναι η μέθοδος smart persistence, η οποία υποθέτει επιπλέον ότι ο δείκτης καθαρού ουρανού (clear sky index) (Sun et al., 2019, 2021) της παραγόμενης ισχύος είναι ο ίδιος στο μέλλον με το παρόν. Αυτές οι προσεγγίσεις χρησιμοποιούνται συνήθως ως μοντέλα αναφοράς έναντι άλλων πιο σύνθετων μεθόδων. Εκτός από τις μεθόδους persistence, έχουν προταθεί πολλές μέθοδοι βασισμένες σε δεδομένα, όπως μοντέλα πρόβλεψης χρονοσειρών, στατιστικά μοντέλα και τεχνικές MM. Σύμφωνα με τους Bacher et al. (2009), υπάρχουν δύο κυρίαρχες προσεγγίσεις για την πρόβλεψη της ηλιακής ενέργειας: Η πρώτη προσέγγιση απαιτεί την κανονικοποίηση της ηλιακής ισχύος με ένα μοντέλο clear sky προκειμένου να διαμορφωθεί μια πιο στάσιμη χρονοσειρά που διευκολύνει την πρόβλεψη με κλασικές μεθόδους γραμμικών χρονοσειρών. Η δεύτερη προσέγγιση περιλαμβάνει τη χρήση ΤΝΔ με διαφορετικούς τύπους εισόδου για την άμεση πρόβλεψη της ηλιακής ισχύος. Οι παραδοσιακές στατιστικές προσεγγίσεις και τα μοντέλα χρονοσειρών έχουν αξιοποιηθεί σε μεγάλο βαθμό για βραχυπρόθεσμες και μακροπρόθεσμες προβλέψεις. Ενδεικτικά παραδείγματα σε αυτή την κατηγορία είναι το μοντέλο αυτοπαλινδρομικού κινητού μέσου (ARMA) που προτάθηκε από τους Huang et al. (2012), μια σειρά στατιστικών μεθόδων παλινδρόμησης που παρουσιάστηκαν από τους Zamo et al. (2014) και η εκθετική εξομάλυνση για την πρόβλεψη της ηλιακής ακτινοβολίας που αναπτύχθηκε από τους Dong et al. (2013). Εκτός από τα στατιστικά μοντέλα, το πρόβλημα της πρόβλεψης Φ/Β παραγωγής έχει αντιμετωπιστεί επιτυχώς με την αξιοποίηση μεθόδων MM. Μελέτες που βασίζονται σε μοντέλα διανυσματικών μηχανών υποστήριξης (SVM) (VanDeventer et al., 2019), στον αλγόριθμο k-κοντινότερων γειτόνων (Tripathy et al., 2022) και σε μοντέλα που βασίζονται σε δέντρα, όπως το Random Forest (RF) (Niu et al., 2020) και τα δέντρα απόφασης (Ahmad et al., 2018), είναι ενδεικτικά παραδείγματα του πόσο αποτελεσματικές μπορούν να είναι οι μέθοδοι MM για το πρόβλημα αυτό. Ωστόσο, οι προαναφερθείσες προσεγγίσεις έχουν ξεπεραστεί από τα μοντέλα BM που εμφανίστηκαν την τελευταία δεκαετία (Ogliari et al., 2017). Η αυξημένη επεξεργαστική ισχύς που παρέχουν οι μονάδες γραφικής επεξεργασίας έχει οδηγήσει στην άνοδο της BM, προσφέροντας τη δυνατότητα επίλυσης ενός ευρέος φάσματος προβλημάτων με καλή ακρίβεια (Yona et al., 2008). Πιο συγκεκριμένα, τα μοντέλα FFNN (Dumitru et al., 2016), RNN, καθώς και η πιο πρόσφατη παραλλαγή τους, το μοντέλο LSTM (Wang et al., 2020), έχουν κερδίσει έδαφος έναντι των παραδοσιακών στατιστικών μεθόδων όσον αφορά το πρόβλημα της πρόβλεψης της Φ/Β παραγωγής. Επιπλέον, μια ευρέως υιοθετημένη κατηγορία μεθόδων είναι οι λεγόμενες υβριδικές μέθοδοι, οι οποίες αποτελούν ουσιαστικά συνδυασμό μοντέλων MM ή BM, είτε με τη μορφή συνόλων (Sarmas et al., 2022) είτε με τη χρήση πιο εξελιγμένων μεθόδων όπως boosting, bagging

ή meta-learning (Persson et al., 2017). Στην παρούσα μελέτη, επιλέγεται μια αρχιτεκτονική *stacked LSTM*, δηλαδή ένα μοντέλο LSTM που αποτελείται από πολλαπλά στρώματα LSTM, για δύο λόγους. Πρώτον, το LSTM μπορεί να αναπαραστήσει τη δυναμική απόδοση των συστημάτων, όντας ικανό να χειρίζεται αποτελεσματικά διαδοχικά δεδομένα με χρονικές σχέσεις. Τέτοιες διαχρονικές, μη γραμμικές, σχέσεις υπάρχουν μεταξύ των μεταβλητών του καιρού και της παραγωγής ισχύος των Φ/Β, αποτελώντας το LSTM ως κατάλληλο μοντέλο για το συγκεκριμένο πρόβλημα πρόβλεψης. Δεύτερον, καθώς είναι ένα μοντέλο βασισμένο σε βάρος, σε αντίθεση με άλλες στατιστικές μεθόδους, είναι κατάλληλο για την εφαρμογή προσεγγίσεων TL.

Ωστόσο, τα μοντέλα BM καταναλώνουν δεδομένα, σε γενικές γραμμές, απαιτώντας επαρκή όγκο δεδομένων προκειμένου να επιτευχθούν προβλέψεις υψηλής ακρίβειας. Ακόμη πιο ενδιαφέρον είναι ότι τα μοντέλα BM εξαρτώνται περισσότερο από τα δεδομένα σε σχέση με τις παραδοσιακές τεχνικές πρόβλεψης χρονοσειρών και τα μοντέλα MM, γεγονός που αντισταθμίζεται από την αυξημένη προβλεπτική τους ικανότητα. Σε αυτό το πλαίσιο, είναι γενικά αποδεκτό ότι τα μοντέλα BM που εκπαιδεύονται με πολύ λίγα δεδομένα υποφέρουν από υποπροσαρμογή και ότι οδηγούν σε κακή προσέγγιση και, κατά συνέπεια, σε εκτίμηση της απόδοσης του μοντέλου με υψηλή απόκλιση. Η αιτία αυτού του προβλήματος είναι γνωστή ως έλλειψη δεδομένων. Πιο συγκεκριμένα, η έλλειψη δεδομένων μπορεί να οριστεί ως η κατάσταση κατά την οποία υπάρχει περιορισμένος αριθμός δεδομένων εκπαίδευσης. Σε γενικές γραμμές, υπάρχουν δύο διαφορετικές μορφές έλλειψης δεδομένων όταν πρόκειται για δεδομένα παραγωγής Φ/Β ισχύος. Πρώτα απ' όλα, η έλλειψη δεδομένων είναι ένα σύννητες φαινόμενο στην περίπτωση των πρόσφατα εγκατεστημένων Φ/Β συστημάτων, όπου απαιτείται μεγάλο χρονικό διάστημα για τη συλλογή επαρκούς δείγματος δεδομένων εξόδου ισχύος προκειμένου να εκπαιδευτούν τα μοντέλα. Δεύτερον, η έλλειψη δεδομένων μπορεί να αποδοθεί σε ελλιπείς τιμές (ή κενά δεδομένων) λόγω δυσλειτουργίας των έξυπνων μετρητών. Σε κάθε περίπτωση, το αποτέλεσμα είναι η έλλειψη δεδομένων για την εκπαίδευση ενός μοντέλου πρόβλεψης BM από την αρχή. Στην περίπτωση της πρόβλεψης της Φ/Β παραγωγής, επαρκής ποσότητα δεδομένων εκπαίδευσης είναι ένα ημερολογιακό έτος, ώστε να μπορέσει το μοντέλο να μάθει εποχικά πρότυπα. Για να αντιμετωπίσουμε αυτό το πρόβλημα, αξιοποιούμε ένα μοντέλο που έχει εκπαιδευτεί για μια τοποθεσία και το εφαρμόζουμε σε μια άλλη τοποθεσία όπου υπάρχουν πολύ λίγα ιστορικά δεδομένα.

Οι άνθρωποι έχουν την έμφυτη ικανότητα να εκμεταλλεύονται τις πληροφορίες που συλλέγονται από μια εργασία προκειμένου να επιλύουν παρόμοιες εργασίες. Το ίδιο ισχύει και στον τομέα της BM (Torrey and Shavlik, 2010). Οι παραδοσιακές προσεγγίσεις BM βασίζονται στην εκμάθηση νέων εννοιών από το μηδέν, χρησιμοποιώντας δεδομένα από ένα συγκεκριμένο θέμα προκειμένου να εκπαιδεύσουν το μοντέλο. Ωστόσο, η αξιοποίηση δεδομένων από παρόμοιες εφαρμογές μπορεί να διευκολύνει τη διαδικασία μάθησης. Το TL έχει αποδειχθεί ότι είναι πολύ αποτελεσματική για την αντιμετώπιση προβλημάτων με ανεπαρκή ή ελλιπή δεδομένα. Η ανεπάρκεια δεδομένων εμφανίζεται συχνά λόγω της μη προσβασιμότητας των δεδομένων, του υψηλού κόστους των μηχανισμών συλλογής δεδομένων και των συσκευών του Διαδικτύου των Πραγμάτων (IoT) ή της έλλειψης κατάλληλων συστημάτων αποθήκευσης δεδομένων. Ωστόσο, ο αντίκτυπος της εποχής της ψηφιοποίησης είναι πιο εμφανής από ποτέ, καθώς η διαθεσιμότητα και η ποιότητα των δεδομένων έχουν βελτιωθεί σημαντικά. Έτσι, τα αποθετήρια μεγάλων δεδομένων επιτρέπουν την αξιοποίηση υφιστάμενων συνόλων δεδομένων για την αντιμετώπιση παρόμοιων προβλημάτων, καθιστώντας το TL την πλέον κατάλληλη προσέγγιση (Weiss et al., 2016). Εστιάζοντας στον τομέα της ενέργειας, το TL αναδεικνύεται ως η πιο δημοφιλής τεχνική για προβλήματα με ανεπαρκή ή κακής ποιότητας δεδομένα. Χαρακτηριστικό παράδειγμα αποτελεί η μέθοδος Hephaestus για την πρόβλεψη της ενέργειας σε διασταυρούμενα κτίρια, λαμβάνοντας υπόψη παράγοντες εποχικότητας και τάσεων (Ribeiro et al., 2018). Παρόμοιες μελέτες έχουν αναπτυχθεί για βραχυπρόθεσμες ενεργειακές προβλέψεις κτιρίων (Fan et al., 2020) και πρόβλεψη κατανάλωσης ενέργειας με δεδομένα κακής ποιότητας (Gao et al., 2020). Ωστόσο, λίγες μελέτες έχουν ασχοληθεί με το πρόβλημα της πρόβλεψης της Φ/Β παραγωγής με TL (Zhou et al., 2020), επιτρέποντας περιθώρια για περαιτέρω έρευνα

στον τομέα αυτό.

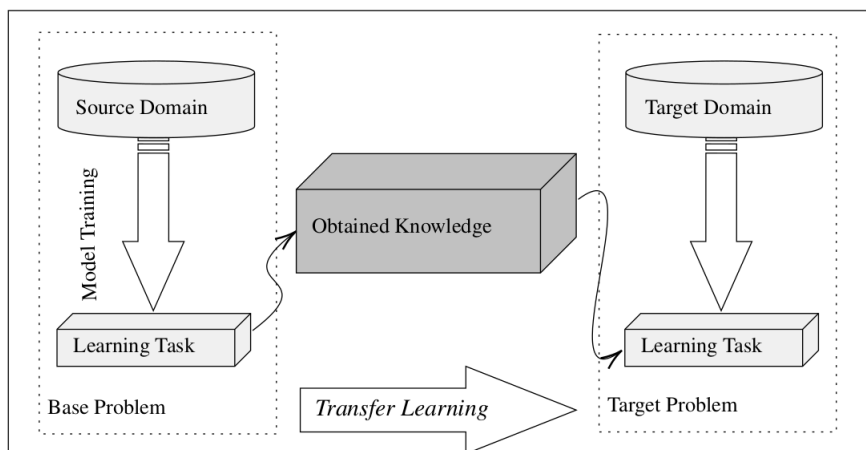
Στην παρούσα μελέτη, διερευνούμε τρεις διαφορετικές στρατηγικές TL και αξιολογούμε τον αντίκτυπο της TL στην παροχή ακριβών προβλέψεων για τη Φ/Β παραγωγή, συγκρίνοντας την αποτελεσματικότητα των παραδοσιακών μοντέλων και των μοντέλων TL σε σχέση με τη διαθεσιμότητα των δεδομένων. Τα αποτελέσματα υποδεικνύουν ότι τα μοντέλα TL υπερτερούν σημαντικά έναντι του συμβατικού, επιτυγχάνοντας βελτίωση της ακρίβειας κατά 24,8 % με 1 έτος δεδομένων εκπαίδευσης. Το χάσμα μεταξύ των μεθόδων είναι ακόμη μεγαλύτερο όταν είναι διαθέσιμα λιγότερα δεδομένα εκπαίδευσης (σύνολο εκπαίδευσης 3 μηνών), ανοίγοντας νέους δρόμους στην πρόβλεψη της παραγωγής ενέργειας των πρόσφατα εγκατεστημένων Φ/Β συστημάτων και καθιστώντας την TL ένα αξιόπιστο εργαλείο στα χέρια των αυτοπαραγωγών προς τον απώτερο στόχο της ενεργειακής εξισορρόπησης και της διαχείρισης της απόκρισης στη ζήτηση από ένα πρώιμο στάδιο.

Το υπόλοιπο της εργασίας είναι οργανωμένο ως εξής. Στη δεύτερη ενότητα (Μέθοδοι) παρουσιάζονται τα πειραματικά δεδομένα και η επεξεργασία, τα μοντέλα TL και οι προτεινόμενες αρχιτεκτονικές. Τα αποτελέσματα αυτής της μελέτης παρουσιάζονται στην τρίτη ενότητα (Αποτελέσματα), όπου περιγράφεται η απόδοση του βασικού μοντέλου, η διαδικασία επικύρωσης των προτεινόμενων στρατηγικών TL και ο αντίκτυπος της διαθεσιμότητας δεδομένων. Τέλος, η τέταρτη ενότητα συνοψίζει τα συμπεράσματα.

6.3 Προτεινόμενο Μοντέλο

6.3.1 Μεταφορά Μάθησης

Το TL είναι μια τεχνική που επικεντρώνεται στην αξιοποίηση της γνώσης που αποκτήθηκε κατά την επίλυση ενός προβλήματος για την επίλυση ενός άλλου προβλήματος με παρόμοια χαρακτηριστικά. Η γενική ιδέα της TL είναι η μεταφορά της τεχνογνωσίας ενός μοντέλου από τον τομέα προέλευσης στον τομέα στόχου, χαλαρώνοντας την υπόθεση ότι τα δεδομένα των δύο αυτών προβλημάτων πρέπει να είναι ανεξάρτητα και πανομοιότυπα κατανομημένα (Tan et al., 2018). Το TL παρέχει πολυάριθμα πλεονεκτήματα, δηλαδή μειωμένο χρόνο εκπαίδευσης (Yao and Doretto, 2010), βελτιωμένη απόδοση του TNΔ και, το σημαντικότερο, τη δυνατότητα επίτευξης υψηλής ακρίβειας με περιορισμένο όγκο δεδομένων (Huang et al., 2017). Το γενικό πλαίσιο της διαδικασίας TL παρουσιάζεται στο Σχήμα 6.1.



Σχήμα 6.1: Σχηματική αναπαράσταση της διαδικασίας μεταφοράς μάθησης.

Σύμφωνα με τον επίσημο ορισμό της TL όπως προτάθηκε από τους Pan and Yang (2009): "Given a source domain \mathcal{D}_S and learning task \mathcal{T}_S , a target domain \mathcal{D}_T and learning task \mathcal{T}_T , where $\mathcal{D}_S \neq \mathcal{D}_T$, or $\mathcal{T}_S \neq \mathcal{T}_T$, TL aims to help improve the learning of the target predictive function $f_T(\cdot)$ in \mathcal{D}_T using the knowledge in \mathcal{D}_S and \mathcal{T}_S ". Αυτός ο ορισμός γίνεται καλύτερα κατανοητός με τον ορισμό των εννοιών τομέας (*domain*) και εργασία (*task*). Το domain \mathcal{D}

αποτελείται από: ένα χώρο χαρακτηριστικών \mathcal{X} και μια οριακή κατανομή πιθανοτήτων $P(X)$, όπου $X = \{x_1, \dots, x_n\} \in \mathcal{X}$. Ο χώρος χαρακτηριστικών μπορεί να οριστεί ως μια συλλογή χαρακτηριστικών που σχετίζονται με συγκεκριμένες ιδιότητες των δεδομένων που δίνονται ως είσοδος στο μοντέλο. Δεδομένου ενός συγκεκριμένου τομέα, $\mathcal{D} = \{\mathcal{X}, P(X)\}$, μια εργασία αποτελείται από δύο συνιστώσες: ένα χώρο ετικετών \mathcal{Y} και μια αντικειμενική συνάρτηση πρόβλεψης $f : \mathcal{X} \rightarrow \mathcal{Y}$. Η αντικειμενική συνάρτηση πρόβλεψης αποσκοπεί στην πρόβλεψη της ετικέτας $f(x)$ κάθε νέου στιγμιότυπου x .

Τέλος, σύμφωνα με τους [Lu et al. \(2015\)](#) υπάρχουν τρεις κύριες κατηγορίες μεθόδων TL. Η επαγωγική TL υποθέτει ότι το έργο μάθησης στον τομέα-στόχο είναι διαφορετικό από το έργο μάθησης στον τομέα-πηγή. Το μη επιβλεπόμενο TL, υποθέτει επίσης ότι το μαθησιακό έργο στον τομέα-στόχο είναι διαφορετικό από το μαθησιακό έργο στον τομέα-πηγή, αλλά επικεντρώνεται μόνο σε μη επιβλεπόμενα προβλήματα όπως η ομαδοποίηση και η εκτίμηση πυκνότητας. Τέλος, η μεταγωγική TL υποθέτει ότι τα μαθησιακά καθήκοντα είναι τα ίδια και στους δύο τομείς, ενώ οι τομείς πηγής και στόχου είναι διαφορετικοί, αλλά σχετίζονται μεταξύ τους. Η προτεινόμενη προσέγγιση TL για το πρόβλημα της πρόβλεψης της παραγωγής Φ/B ανήκει στο πεδίο της μεταγωγικής TL, επειδή τα καθήκοντα πηγής και στόχου είναι τα ίδια (ωριαία πρόβλεψη Φ/B), ενώ τα πεδία πηγής και στόχου είναι διαφορετικά όσον αφορά την τοποθεσία, την ονομαστική ισχύ και τις καιρικές συνθήκες.

6.3.2 Το μοντέλο LSTM

Ένα από τα πιο κατάλληλα μοντέλα για την εφαρμογή της TL στο πρόβλημα της πρόβλεψης της παραγωγής Φ/B είναι το μοντέλο LSTM ([Hochreiter and Schmidhuber, 1997](#)). Αυτό οφείλεται κυρίως στο γεγονός ότι η λειτουργικότητα του LSTM εξαρτάται από την ενημέρωση του βάρους μεταξύ των νευρώνων του μοντέλου BM, επιτρέποντας τη δημιουργία προ-εκπαιδευμένων μοντέλων. Έτσι, διευκολύνεται η προ-εκπαίδευση του μοντέλου στο βασικό Φ/B , προκειμένου να χρησιμοποιηθούν τα αποθηκευμένα βάρη του προ-εκπαιδευμένου μοντέλου και να εφαρμοστεί το TL στο Φ/B -στόχο. Το ίδιο ισχύει και για άλλα NN, αλλά τα δίκτυα LSTM έχουν δείξει τις καλύτερες επιδόσεις και το ενδιαφέρον για την πρόβλεψη της ισχύος των Φ/B με τη χρήση παραλλαγών των δικτύων LSTM αυξάνεται συνεχώς τα τελευταία χρόνια ([Konstantinou et al., 2021](#)).

Το LSTM είναι μια αρχιτεκτονική RNN με την έμφυτη ικανότητα να συλλαμβάνει μακροχρόνιες εξαρτήσεις σε προβλήματα πρόβλεψης ακολουθίας ([Gers et al., 2000](#)). Σκοπός της ανάπτυξης των LSTM ήταν το πρόβλημα της εξαφανιζόμενης κλίσης, το οποίο μπορεί να περιγραφεί ως η εκθετική αύξηση (ή μείωση) του σήματος σφάλματος που διαδίδεται με αντίστροφη διάδοση ως συνάρτηση της απόστασης από το τελικό στρώμα, με αποτέλεσμα μοντέλα που είναι ασταθή και ανίκανα για αποτελεσματική μάθηση ([Hochreiter, 1998](#)). Το LSTM χρησιμοποιεί μια δομή προσθετικής κλίσης η οποία περιλαμβάνει άμεση πρόσβαση σε μια πύλη λήθης που επιτρέπει στο δίκτυο να διεγείρει την επιθυμητή συμπεριφορά από την κλίση σφάλματος ([Hochreiter et al., 2001](#)).

Η επιλογή του LSTM έναντι των παραδοσιακών αλγορίθμων MM και των feedforward NNs βασίζεται στην καταλληλότητά του για τη διατήρηση μακροχρόνιας μνήμης, η οποία είναι απαραίτητη όταν αντιμετωπίζονται προβλήματα με διαδοχικά δεδομένα με χρονική σχέση. Το LSTM είναι σε θέση να αναπαραστήσει τη δυναμική απόδοση των συστημάτων, αποτελώντας έτσι ένα από τα πιο διαδεδομένα μοντέλα για την αντιμετώπιση προβλημάτων χρονοσειρών, όπως η πρόβλεψη της παραγωγής Φ/B ([Abdel-Nasser and Mahmoud, 2019](#)). Τα LSTM παρέχουν ένα σημαντικό πλεονέκτημα έναντι άλλων μεθόδων, καθώς είναι σε θέση να ανιχνεύουν γραμμικές σχέσεις μεταξύ μη γραμμικών δεδομένων. Τέτοιες σχέσεις μπορεί να εμφανιστούν στο πρόβλημα της πρόβλεψης της Φ/B παραγωγής, μεταξύ της παραγωγής ισχύος και των μετεωρολογικών δεδομένων. Από αυτή την άποψη, το LSTM μπορεί να επωφεληθεί από τα χαρακτηριστικά και να ανιχνεύσει σχέσεις και μοτίβα που άλλα μοντέλα δεν θα ήταν σε θέση να βρουν. Επιπλέον, το LSTM έχει αξιοποιηθεί για διάφορα προβλήματα χρονοσειρών που σχετίζονται με την ενέργεια, συμπεριλαμβανομένων των προβλέψεων

κατανάλωσης ενέργειας σε κατοικίες (Kim and Cho, 2019; Kong et al., 2017), και της πρόβλεψης της ζήτησης φυσικού αερίου (Su et al., 2019). Η αρχιτεκτονική του κυττάρου LSTM απεικονίζεται στο Σχήμα ??.

Η αρχιτεκτονική του μοντέλου LSTM παρουσιάστηκε αναλυτικά στο Κεφάλαιο 5.

6.3.3 Αρχιτεκτονικές Μοντέλων

Η υψηλή ακρίβεια που επιτυγχάνεται από τα NNs σε διαφορετικά απαιτητικά προβλήματα πρόβλεψης αποδίδεται στην πολύπλοκη αρχιτεκτονική τους. Τα βαθιά NN ενσωματώνουν την έννοια της ιεραρχίας λόγω της σύνδεσης πολλαπλών επιπέδων νευρώνων. Κάθε στρώμα είναι υπεύθυνο για την επίλυση μιας μικρής εργασίας του κύριου προβλήματος και η έξοδος του μεταφέρεται στο επόμενο στρώμα (Hermans and Schrauwen, 2013). Η λύση του προβλήματος παράγεται από το τελευταίο στρώμα του δικτύου. Τα ενδιάμεσα στρώματα των βαθιών NN ονομάζονται κρυφά στρώματα. Η βασική ιδέα της εισαγωγής κρυφών στρωμάτων στην αρχιτεκτονική είναι ότι κάθε κρυφό στρώμα παράγει πιο προηγμένες αναπαραστάσεις του προβλήματος που οδηγούν σε υψηλότερα επίπεδα αφαίρεσης. Έτσι, τα βαθιά NN μπορούν να αναπαραστήσουν οποιαδήποτε μη γραμμική συνάρτηση με σχετικά λιγότερους νευρώνες από ένα δίκτυο ενός στρώματος. Το BM υποθέτει ότι ένα ιεραρχικό μοντέλο με πολλά επίπεδα είναι εκθετικά πιο αποτελεσματικό στην προσέγγιση ορισμένων συναρτήσεων από ένα πιο ρηχό (Pascanu et al., 2013).

Αυτή η προσέγγιση μπορεί επίσης να εφαρμοστεί στα LSTM. Το αρχικό μοντέλο LSTM αποτελείται από ένα μόνο στρώμα το οποίο λαμβάνει τα δεδομένα εισόδου και μεταβιβάζει το σήμα εξόδου σε ένα μόνο στρώμα εξόδου feed-forward. Ωστόσο, στην παρούσα μελέτη προτείνεται μια εναλλακτική αρχιτεκτονική, η οποία περιλαμβάνει πολλαπλά κρυφά στρώματα από πολλές μονάδες LSTM που ακολουθούνται από ένα στρώμα εξόδου feed-forward. Κάθε στρώμα παρέχει μια ακολουθία εξόδου στο επόμενο στρώμα και όχι μια ενιαία τιμή εξόδου. Αυτή η αρχιτεκτονική ονομάζεται στοιβαγμένο δίκτυο LSTM και έχει εισαχθεί από τους Graves et al. (2013) στην εφαρμογή των LSTM στην αναγνώριση ομιλίας. Σε σχέση με τα απλά δίκτυα feed-forward, τα στοιβαγμένα δίκτυα LSTM οδηγούν σε βαθύτερα μοντέλα με υψηλότερα επίπεδα ακρίβειας προσέγγισης. Επιπλέον, λόγω του γεγονότος ότι τα LSTM χρησιμοποιούνται με δεδομένα ακολουθίας (η κρυφή τους κατάσταση είναι συνάρτηση όλων των προηγούμενων κρυφών καταστάσεων), οι βαθύτερες αρχιτεκτονικές οδηγούν επίσης σε βαθύτερο επίπεδο αφαίρεσης των δεδομένων εισόδου με την πάροδο του χρόνου παρέχοντας μια αναπαράσταση της εργασίας σε διαφορετικές χρονικές κλίμακες (Chung et al., 2015; Amirul Islam et al., 2017).

Το TL αξιοποιείται μέσω της διαδικασίας επαναχρησιμοποίησης των βαρών ενός μοντέλου που έχει εκπαιδευτεί στα δεδομένα του πηγαίου τομέα για τη λεπτομερή ρύθμιση ενός νέου μοντέλου με βάση τα δεδομένα του τομέα-στόχου. Το προ-εκπαιδευμένο μοντέλο αναφέρεται ως βασικό μοντέλο, ενώ κάθε νέο μοντέλο στον τομέα-στόχο αναφέρεται ως μοντέλο TL. Τα βάρη κάθε στρώματος του βασικού μοντέλου μπορούν να υποβληθούν σε διαφορετική επεξεργασία προκειμένου να παρέχουν καλύτερη απόδοση του μοντέλου TL στον τομέα-στόχο, χρησιμοποιώντας τις ακόλουθες προσεγγίσεις: (α) να διατηρηθούν τα βάρη του στρώματος σταθερά, (β) να γίνει λεπτομερής ρύθμιση των βαρών του στρώματος με βάση τα δεδομένα του τομέα-στόχου και (γ) να εκπαιδευτούν τα βάρη του στρώματος από την αρχή με βάση τα δεδομένα του τομέα-στόχου.

Στην παρούσα μελέτη, αναπτύσσονται τρεις στρατηγικές TL και συγκρίνονται από την άποψη της ακρίβειας πρόβλεψης για το πρόβλημα της πρόβλεψης της παραγωγής Φ/Β.

- **Στρατηγική TL 1:** Στην πρώτη στρατηγική, τα βάρη των αρχικών στρωμάτων είναι παγωμένα και τα μόνα εκπαιδευσιμα βάρη είναι τα βάρη του τελευταίου κρυμμένου στρώματος. Αυτή η στρατηγική είναι γνωστή ως πάγωμα των βαρών και χρησιμοποιείται ευρέως προκειμένου να εξαχθούν χαρακτηριστικά από τον αρχικό τομέα και να μεταφερθούν στον τομέα-στόχο. Αυτό είναι ένα ευρέως χρησιμοποιούμενο σχήμα κατά την επεξεργασία εικόνων, όπου τα πρώτα στρώματα χρησιμοποιούνται ως στρώ-

ματα εξαγωγής χαρακτηριστικών και τα τελευταία στρώματα χρησιμοποιούνται για την προσαρμογή σε νέα δεδομένα.

- **TL Strategy 2:** Στη δεύτερη στρατηγική, το βασικό μοντέλο χρησιμοποιείται ως σχήμα αρχικοποίησης βάρους για το μοντέλο TL. Τα βάρη όλων των στρωμάτων του μοντέλου TL αρχικοποιούνται με βάση δεδομένα από τον τομέα προέλευσης και προσαρμόζονται με βάση δεδομένα από τον τομέα-στόχο. Αυτή η προσέγγιση χρησιμοποιείται εκτενώς σε προβλήματα όπου υπάρχει αφθονία δεδομένων στον τομέα προέλευσης, αλλά έλλειψη δεδομένων στον τομέα στόχου. Ωστόσο, ένας υψηλός βαθμός ομοιότητας μεταξύ του τομέα πηγής και του τομέα στόχου είναι απαραίτητη προϋπόθεση.
- **TL Strategy 3:** Στην τρίτη στρατηγική, τα αρχικά στρώματα του μοντέλου TL παγώνουν και το τελευταίο στρώμα εκπαιδεύεται από το μηδέν, ανοίγοντας το τελευταίο στρώμα του βασικού μοντέλου και προσθέτοντας ένα νέο στρώμα μετά τα παγωμένα στρώματα. Αυτή η προσέγγιση είναι παρόμοια με την πρώτη, αλλά διαφέρει στο γεγονός ότι τα βάρη του τελευταίου στρώματος δεν αρχικοποιούνται με βάση δεδομένα από τον αρχικό τομέα. Έτσι, το μοντέλο TL χρησιμεύει ως μηχανισμός εξαγωγής χαρακτηριστικών λόγω των παγωμένων στρωμάτων, αλλά μπορεί επίσης να προσαρμοστεί λεπτομερώς στον τομέα-στόχο λόγω της τυχαίας αρχικοποίησης των βαρών του τελευταίου στρώματος.

6.4 Μελέτη Περίπτωσης

Τα αποτελέσματα της παρούσας μελέτης παρουσιάζονται σε τρεις κατηγορίες, δηλαδή: την απόδοση πρόβλεψης του βασικού στοιβαγμένου μοντέλου LSTM, τα αποτελέσματα απόδοσης των μοντέλων TL σε σύγκριση με το συμβατικό μοντέλο στον τομέα-στόχο και τα αποτελέσματα της εφαρμογής TL με διαφορετικό όγκο διαθέσιμων δεδομένων, αντίστοιχα. Με τον όρο συμβατικό μοντέλο αναφερόμαστε στο μοντέλο LSTM στο οποίο δεν έχει εφαρμοστεί TL-σε αυτό το πλαίσιο, το συμβατικό μοντέλο LSTM βασίζεται αποκλειστικά στην εκπαίδευση με δεδομένα από το Φ/B-στόχο.

6.4.1 Σύνολο Δεδομένων

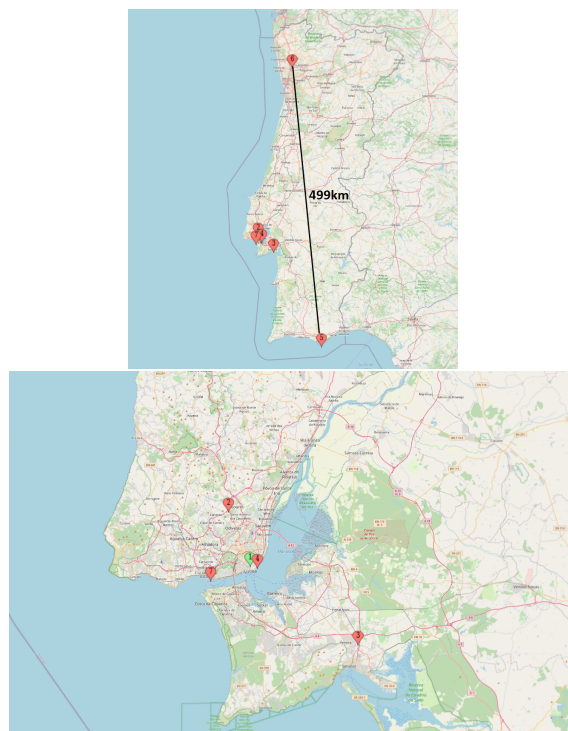
Αξιοποιούνται η ωριαία Φ/B παραγωγή και μετεωρολογικά δεδομένα (θερμοκρασία, υγρασία και ηλιακή ακτινοβολία) από 7 Φ/B συστήματα. Τα δεδομένα Φ/B παραγωγής συλλέγονται απευθείας από τα συστήματα ηλιακών συστημάτων μιας πορτογαλικής ενεργειακής κοινότητας, ενώ τα δεδομένα καιρού εξάγονται από έναν τοπικό μετεωρολογικό σταθμό (<https://www.wunderground.com>) και το Copernicus Atmosphere Data Store (<https://ads.atmosphere.copernicus.eu>). Ένα Φ/B, συγκεκριμένα ο PV_1 , χρησιμοποιείται ως βασικό μοντέλο και τα υπόλοιπα Φ/B χρησιμοποιούνται για την ανάπτυξη των μοντέλων TL. Συγκεκριμένες πληροφορίες για τις εξεταζόμενες Φ/B εγκαταστάσεις παρουσιάζονται στον Πίνακα 6.1.

PV	Location	Latitude	Longitude	Nominal(kW)	Peak(kW)	Rows	From Date	To Date
PV_1 (base)	Lisbon	38.728	-9.138	23.52	20.00	21956	01/08/2018	31/01/2021
PV_2	Lisbon	38.833	-9.191	46.00	40.00	21908	31/12/2018	01/01/2021
PV_3	Setubal	38.577	-8.872	271.53	216.00	9670	02/02/2020	10/03/2021
PV_4	Lisbon	38.725	-9.120	30.00	27.00	20588	01/08/2018	31/01/2021
PV_5	Faro	37.031	-7.893	60.48	50.00	15044	08/09/2019	30/04/2021
PV_6	Braga	41.493	-8.496	119.88	108.00	18045	10/01/2019	31/01/2021
PV_7	Lisbon	38.701	-9.236	55.65	50.00	21932	01/08/2019	31/01/2021

Πίνακας 6.1: Στοιχεία των Φ/B συστημάτων που χρησιμοποιήθηκαν για την πειραματική εφαρμογή της μελέτης.

Τα Φ/B συστήματα βρίσκονται σε 4 πόλεις της Πορτογαλίας (4 Φ/B συστήματα βρίσκονται στη Λισαβόνα- 1 βρίσκεται στη Σετούμπαλ, στο Φάρο και στη Μπράγκα, αντίστοιχα) και

τα διαθέσιμα δεδομένα κυμαίνονται από 14 έως 30 μήνες ανάλογα με το Φ/Β σύστημα. Τα επιλεγμένα Φ/Β συστήματα διαφέρουν επίσης όσον αφορά την ονομαστική και την μέγιστη ισχύ. Η ονομαστική ισχύς του Φ/Β βάσης είναι 23,52 KW, ενώ η ισχύς των Φ/Β συστημάτων του τομέα-στόχου κυμαίνεται από 30 KW έως 271,53 KW, δηλαδή πάνω από 10 φορές μεγαλύτερη από την ισχύ του Φ/Β βάσης. Το σκεπτικό πίσω από την επιλογή των συγκεκριμένων Φ/Β συστημάτων είναι να αξιολογηθεί η απόδοση του μοντέλου σε Φ/Β που βρίσκονται τόσο στην ίδια πόλη (PV_2 , PV_4 και PV_7) όσο και σε διαφορετικές πόλεις από το Φ/Β βάσης (PV_3 , PV_5 και PV_6), προκειμένου να αναφερθούν πιθανές διαφορές στην ακρίβεια πρόβλεψης των μοντέλων TL. Οι τοποθεσίες των επιθεωρημένων Φ/Β συστημάτων απεικονίζονται στο Σχήμα 6.2.



Σχήμα 6.2: Χάρτης που απεικονίζει τις τοποθεσίες των επιθεωρημένων Φ/Β συστημάτων. Τα 7 Φ/Β συστήματα βρίσκονται σε τέσσερις διαφορετικές πόλεις της Πορτογαλίας (Λισαβόνα, Setubal, Faro, Braga), επιτρέποντας την αξιολόγηση της απόδοσης του μοντέλου ανεξάρτητα από την πόλη. Η εικόνα στα δεξιά προσφέρει εστίαση στην πόλη της Λισαβόνας, όπου βρίσκονται 4 Φ/Β συστήματα (ο χάρτης δημιουργήθηκε με το <https://www.mapcustomizer.com/>, OpenStreetMap contributors)

Τα επιλεγμένα χαρακτηριστικά του στοιβαγμένου μοντέλου LSTM είναι η θερμοκρασία, η υγρασία, η ηλιακή ακτινοβολία, η Φ/Β παραγωγή, η αναπαράσταση του μήνα του έτους με κωδικοποίηση one-hot και ο μετασχηματισμός ημιτόνου/κοσιφώνου της ώρας της ημέρας. Η ακόλουθη ρουτίνα επεξεργασίας πραγματοποιείται για κάθε σύνολο δεδομένων: Πρώτον, τα δεδομένα κανονικοποιούνται στο εύρος $[0, 1]$. Δεύτερον, τα δεδομένα μετατρέπονται σε μορφή "5 εισόδων - 1 εξόδου" για να επεξεργαστούν από το μοντέλο stacked LSTM. Τρίτον, τα σύνολα δεδομένων χωρίζονται σε σύνολα εκπαίδευσης και σύνολα δοκιμής. Το βασικό μοντέλο εκπαιδεύεται σε ολόκληρο το σύνολο δεδομένων του πηγαίου τομέα. Τα μοντέλα TL εκπαιδεύονται σε δεδομένα 12 μηνών (το σύνολο εκπαίδευσης αποτελείται από 8760 ωριαίες γραμμές) και τα υπόλοιπα δεδομένα χρησιμοποιούνται για δοκιμή. Είναι προφανές ότι η περίοδος δοκιμής διαφέρει για κάθε Φ/Β-στόχο με βάση τον συνολικό αριθμό των διαθέσιμων δεδομένων- η PV_7 έχει τη μεγαλύτερη περίοδο δοκιμής, που αποτελείται από 13172 ωριαίες σειρές, ενώ η PV_3 έχει τη μικρότερη περίοδο δοκιμής, που αποτελείται από 910 ωριαίες σειρές. Τέλος, η ίδια ρουτίνα επεξεργασίας εφαρμόζεται για όλα τα Φ/Β με δεδομένα εκπαίδευσης 3,

6 και 9 μηνών διατηρώντας το σύνολο δοκιμών το ίδιο, προκειμένου να διερευνηθεί η επίδραση της TL με χαμηλή διαθεσιμότητα δεδομένων.

Τέλος, η πειραματική εφαρμογή υλοποιείται στη γλώσσα προγραμματισμού Python, αλληλεπιδρώντας με βιβλιοθήκες ανοικτού κώδικα, συμπεριλαμβανομένων των NumPy και Pandas, καθώς και με τη διεπαφή προγράμματος εφαρμογής TensorFlow (ο πηγαίος κώδικας είναι διαθέσιμος στο GitHub: [Κωδικός πηγής](#)). Ο ADAM είναι ο επιλεγμένος βελτιστοποιητής με βάση την υπάρχουσα βιβλιογραφία, ενώ ο ρυθμός μάθησης ορίζεται σε 0,001. Το μοντέλο stacked LSTM που αναπτύχθηκε αποτελείται από τρία πλήρως συνδεδεμένα ενδιάμεσα στρώματα (το πρώτο στρώμα περιλαμβάνει 24 νευρώνες, το δεύτερο στρώμα περιλαμβάνει 48 νευρώνες και το τρίτο στρώμα περιλαμβάνει 96 νευρώνες) και ακολουθείται από το στρώμα εξόδου. Ο αριθμός των εποχών ορίζεται σε 100 και το μέγεθος της δέσμης ορίζεται σε 128 με τη μέθοδο δοκιμής και σφάλματος.

6.4.2 Επίδοση Baseline Μοντέλου

Το μοντέλο stacked LSTM έχει τα ακόλουθα χαρακτηριστικά υστέρησης: (α) μετρούμενη τιμή εξόδου ισχύος, (β) θερμοκρασία αέρα, (γ) παγκόσμια οριζόντια ακτινοβολία, (δ) υγρασία, (ε) μήνας του έτους (με τη μορφή κωδικοποίησης ενός σημείου) και (στ) ώρα της ημέρας (με τη μορφή μετασχηματισμού ημιτόνου/χοσιφώνου). Τα προαναφερθέντα χαρακτηριστικά εισάγονται στο μοντέλο LSTM με τη μορφή "5 είσοδοι - 1 έξοδος" ωριαίων δεδομένων. Πιο συγκεκριμένα, μια τιμή σημείου για κάθε χαρακτηριστικό τροφοδοτείται στο μοντέλο για τις τελευταίες πέντε ώρες και προβλέπεται η ισχύς εξόδου των Φ/Β για την επόμενη ώρα (πρόβλεψη ισχύος εξόδου για μία ώρα μπροστά).

Η εξασφάλιση ενός ακριβούς βασικού μοντέλου αποτελεί προϋπόθεση για την επίτευξη ακριβών προβλέψεων στον τομέα-στόχο. Στο πλαίσιο αυτό, η απόδοση του μοντέλου LSTM για τη βάση Φ/Β αξιολογείται με την ακόλουθη διαδικασία: Το σύνολο δεδομένων PV βάσης χωρίζεται σε σύνολο εκπαίδευσης και σε σύνολο αξιολόγησης με διαχωρισμό 80-20, διατηρώντας το πρώτο 80% ως εκπαίδευση και το υπόλοιπο 20% ως δοκιμή (17563 παρατηρήσεις για τη διαδικασία εκπαίδευσης και 4391 παρατηρήσεις για σκοπούς αξιολόγησης) και το μοντέλο LSTM εκπαιδεύεται στο σύνολο εκπαίδευσης. Η ακρίβεια του μοντέλου αξιολογείται με τον υπολογισμό της ρίζας του μέσου τετραγωνικού σφάλματος (RMSE) και του μέσου απόλυτου σφάλματος (MAE) των αντίστοιχων προβλέψεων κατά την εξεταζόμενη περίοδο αξιολόγησης, καθώς και του συντελεστή προσδιορισμού R^2 μεταξύ των προβλέψεων και των πραγματικών τιμών, ως εξής:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (6.1)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (6.2)$$

$$R^2 = 1 - \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (6.3)$$

όπου y_t είναι η πραγματική τιμή της χρονοσειράς ηλιακής παραγωγής στο ωριαίο διάστημα t της περιόδου αξιολόγησης, \hat{y}_t είναι η παραγόμενη πρόβλεψη του μοντέλου και \bar{y} είναι ο μέσος όρος των πραγματικών τιμών. Εκτός από αυτές τις μετρικές σφάλματος, υπολογίζονται δύο πρόσθετες μετρικές προκειμένου να γίνει πληρέστερη η αξιολόγηση του μοντέλου: το μέσο σφάλμα μεροληψίας (MBE) και το κανονικοποιημένο μέσο τετραγωνικό σφάλμα (NRMSE). Το MBE αντιπροσωπεύει το συστηματικό σφάλμα ενός μοντέλου πρόβλεψης να υποπροβλέπει ή να υπερπροβλέπει, ενώ το NRMSE είναι κατάλληλο για τη σύγκριση μεταξύ μοντέλων

διαφορετικών κλιμάκων συνδέοντας την τιμή RMSE με το παρατηρούμενο εύρος της μεταβλητής. Οι δύο αυτές μετρικές υπολογίζονται ως εξής:

$$MBE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t) \quad (6.4)$$

$$NRMSE = \frac{RMSE}{\bar{y}} \quad (6.5)$$

Το μοντέλο επιτυγχάνει υψηλή ακρίβεια, καταφέροντας να καταγράψει αποτελεσματικά τα ημερήσια πρότυπα των πιο σημαντικών μεταβλητών, όπως αντικατοπτρίζεται από τις χρησιμοποιούμενες μετρικές ($MAE = 0.467$, $RMSE = 0.992$, $MBE = -0.097$, $nRMSE = 0.301$, $R^2 = 96.254\%$). Ωστόσο, ακόμη και αυτές οι πέντε μετρικές σφάλματος δεν αρκούν για να καταδείξουν επαρκώς τις δυνατότητες του προτεινόμενου μοντέλου σε σύγκριση με άλλα μοντέλα σε διαφορετικές γεωγραφικές τοποθεσίες. Σύμφωνα με τους [Yang et al. \(2020\)](#); [Yang \(2019b\)](#), η ακρίβεια των μοντέλων πρόβλεψης της ηλιακής ακτινοβολίας (γενικά, ο όρος "πρόβλεψη της ηλιακής ακτινοβολίας" μπορεί να αναφέρεται είτε στην πρόβλεψη της ηλιακής ακτινοβολίας είτε στην πρόβλεψη της ηλιακής ισχύος- σε όλη την παρούσα μελέτη ο όρος αναφέρεται στην πρόβλεψη της ηλιακής ισχύος) πρέπει να είναι συγκρίσιμη μεταξύ τους σε διαφορετικές τοποθεσίες και διαφορετικές χρονικές περιόδους μέσω μιας κοινής μετρικής που είναι ο δείκτης ικανότητας πρόβλεψης. Ο δείκτης ικανότητας πρόβλεψης βασίζεται στη σύγκριση του προτεινόμενου μοντέλου με ένα μοντέλο αναφοράς σε μια συγκεκριμένη μετρική σφάλματος. Ωστόσο, προκύπτουν δύο ζητήματα: Ποιο μοντέλο αναφοράς και ποια μετρική σφάλματος πρέπει να χρησιμοποιηθούν; Το πιο συνηθισμένο μοντέλο αναφοράς για την τυποποίηση της επαλήθευσης των μοντέλων πρόβλεψης της ηλιακής ακτινοβολίας είναι το μοντέλο εμμονής. Πιο συγκεκριμένα, συνιστάται ιδιαίτερα η αξιοποίηση ενός έξυπνου μοντέλου εμμονής ως μοντέλο αναφοράς, αντί της χρήσης του αφελούς (ή απλού) μοντέλου εμμονής ([Yang, 2019a](#)). Όσον αφορά τη βέλτιστη μετρική σφάλματος, το RMSE είναι η καταλληλότερη μετρική στην περίπτωση της παραγωγής ηλιακής ενέργειας, ως μια μετρική που είναι κατάλληλη για την καταγραφή μεγάλων σφαλμάτων ([Yang et al., 2020](#)). Έτσι, ο τύπος του δείκτη ικανότητας πρόβλεψης είναι ο ακόλουθος:

$$skill = 1 - \frac{RMSE_{proposed}}{RMSE_{reference}} \quad (6.6)$$


όπου $RMSE_{proposed}$ είναι η τιμή RMSE του αναπτυγμένου μοντέλου LSTM και $RMSE_{reference}$ είναι η τιμή RMSE του μοντέλου έξυπνης εμμονής.

Το τελευταίο ερώτημα που προκύπτει αφορά την επιλογή του μοντέλου έξυπνης εμμονής στην περίπτωση της πρόβλεψης της ηλιακής ενέργειας. Για προβλήματα πρόβλεψης της ηλιακής ακτινοβολίας, το μοντέλο έξυπνης εμμονής προκύπτει από την ενσωμάτωση συνθηκών clear sky στο μοντέλο αναφοράς ([Yang, 2019a](#)). Το ίδιο ισχύει και για τις προβλέψεις Φ/B ισχύος, όπου έχουν προταθεί διάφορα μοντέλα έξυπνης εμμονής ([Antonanzas et al., 2016](#)). Πιο συγκεκριμένα, ένας δείκτης clear sky έχει προταθεί από τους Engerer και Mills στην περίπτωση που τα χαρακτηριστικά του Φ/B πλαισίου είναι γνωστά ([Engerer and Mills, 2014](#)), ενώ ένα άλλο μοντέλο smart persistence που βασίζεται στην κλιμάκωση της παγκόσμιας οριζόντιας ακτινοβολίας έχει παρουσιαστεί από τους Huertas και Centeno ([Huertas Tato and Centeno Brito, 2018](#)). Στην παρούσα μελέτη, υιοθετείται ο ορισμός των Pedro και Coimbra, ο οποίος βασίζεται στην εκτίμηση της αναμενόμενης παραγωγής ισχύος υπό συνθήκες clear sky ([Pedro and Coimbra, 2012](#)). Ο τύπος του υιοθετούμενου μοντέλου έξυπνης εμμονής περιγράφεται από την ακόλουθη εξίσωση:

$$\hat{y}(t + \Delta t) = \begin{cases} y_{c-s}(t + \Delta t), & \text{if } y_{c-s}(t) = 0 \\ y_{c-s}(t + \Delta t) \frac{y(t)}{y_{c-s}(t)} & \text{otherwise} \end{cases} \quad (6.7)$$

όπου $y(t)$ είναι η μετρούμενη ισχύς εξόδου και $y_{c-s}(t)$ αντιπροσωπεύει την αναμενόμενη ισχύ εξόδου υπό συνθήκες clear sky. Ο σκοπός αυτού του μοντέλου είναι η αποσύνθεση της

παραγωγής ισχύος, υποδεικνύοντας ότι ένα μέρος της παραγωγής ισχύος σε σχέση με τις συνθήκες clear sky παραμένει το ίδιο μεταξύ μικρών χρονικών διαστημάτων. Επιπλέον, σε νυχτερινές συνθήκες η πρόβλεψη του μοντέλου έξυπνης εμμονής θεωρείται ίση με την παραγωγή ισχύος σε συνθήκες clear sky. Η προσεγγιστική συνάρτηση για το μοντέλο clear sky μπορεί να δημιουργηθεί με τη μέση τιμή παρελθουσών τιμών παραγωγής ισχύος ανάλογα με την ώρα της ημέρας (μεταξύ 0 και 23) και την ημέρα του έτους (μεταξύ 0 και 255). Το δεύτερο βήμα περιλαμβάνει τη δημιουργία της ομαλής επιφάνειας που περιβάλλει την προαναφερθείσα συνάρτηση (Pedro and Coimbra, 2012). Η παραγωγή ισχύος που αναμένεται υπό συνθήκες clear sky για το βασικό Φ/B (PV_1) ως συνάρτηση της ώρας της ημέρας και της ημέρας του έτους για το βασικό μοντέλο παρουσιάζεται στο Σχήμα 6.3.




Σχήμα 6.3: Η αναμενόμενη ισχύς σε συνθήκες clear sky για το βασικό Φ/B σύστημα ως συνάρτηση της ώρας της ημέρας (που κυμαίνεται μεταξύ 0 και 23) και της ημέρας του έτους (που κυμαίνεται μεταξύ 0 και 255)

Η απόδοση του μοντέλου έξυπνης εμμονής αντικατοπτρίζεται από τις ακόλουθες μετρικές σφάλματος: $MAE = 0.582$, $RMSE = 1.274$, $MBE = 0.029$, $nRMSE = 0.387$, $R^2 = 93.811\%$. Παρόλο που το μοντέλο έξυπνης εμμονής παρουσιάζει αρκετά καλή απόδοση σε σύγκριση με το αφελές μοντέλο εμμονής ($RMSE_{Naive} = 1.985$, $MAE_{Naive} = 1.110$), είναι προφανές ότι το LSTM υπερέχει σημαντικά του μοντέλου έξυπνης εμμονής. Αυτό αναδεικνύεται επίσης μέσω του δείκτη ικανότητας πρόβλεψης του μοντέλου LSTM, ο οποίος είναι ίσος με 0.221. Ένας θετικός δείκτης ικανότητας πρόβλεψης δείχνει ότι το προτεινόμενο μοντέλο υπερτερεί έναντι του μοντέλου έξυπνης εμμονής, ενώ ένας αρνητικός δείκτης δείχνει ότι το μοντέλο έξυπνης εμμονής αποδίδει καλύτερα.

Τέλος, το Σχήμα 6.4 απεικονίζει τα αποτελέσματα των μοντέλων πρόβλεψης (βασικό μοντέλο LSTM και μοντέλο έξυπνης εμμονής) για δύο διαφορετικές περιόδους. Μπορεί να συναχθεί το συμπέρασμα ότι το μοντέλο καταφέρνει να συλλάβει την εποχικότητα, τις τάσεις και τις μεταβολές που σχετίζονται με τις καιρικές συνθήκες τόσο στις καλοκαιρινές όσο και στις χειμερινές περιόδους και έτσι προσφέρει σημαντικά καλύτερες προβλέψεις σε σύγκριση με το μοντέλο έξυπνης εμμονής.

6.4.3 Στρατηγικές Μεταφοράς Μάθησης

Τα μοντέλα TL είναι εξοπλισμένα με τα ίδια ακριβώς χαρακτηριστικά με το βασικό μοντέλο, χρησιμοποιώντας το βασικό προ-εκπαιδευμένο μοντέλο για την επίλυση του ίδιου ακριβώς προβλήματος, με τα ίδια χαρακτηριστικά και την ίδια αναμενόμενη έξοδο, σε διαφορετικό Φ/B σύστημα. Ως εκ τούτου, τα χαρακτηριστικά των μοντέλων TL είναι τα εξής: (α) μετρούμενη



(a) Θερινή περίοδος (από 04-08-2020 έως 11-08-2020). (b) Χειμερινή περίοδος (από 18-01-2021 έως 25-01-2021)

Σχήμα 6.4: Παράδειγμα που απεικονίζει τις επιδόσεις του μοντέλου πρόβλεψης ηλιακής ενέργειας σε σύγκριση με το μοντέλο smart persistence. Ο οριζόντιος άξονας δείχνει το ωριαίο χρονικό βήμα της περιόδου αξιολόγησης, ενώ ο κατακόρυφος άξονας δείχνει την παραγωγή ηλιακής ενέργειας. Το παράδειγμα αναφέρεται σε μια τυχαία επιλεγμένη καλοκαιρινή εβδομάδα (μεταξύ των ωρών 54 και 222 του συνόλου επικύρωσης, που αντιστοιχούν στις 04-08-2020 και 11-08-2020) και σε μια τυχαία επιλεγμένη χειμερινή εβδομάδα (μεταξύ των ωρών 4060 και 4228 του συνόλου επικύρωσης, που αντιστοιχούν στις 18-01-2021 και 25-01-2021) της περιόδου αξιολόγησης.

τιμή εξόδου ισχύος, (β) θερμοκρασία αέρα, (γ) παγκόσμια οριζόντια ακτινοβολία, (δ) υγρασία, (ε) μήνας του έτους (κωδικοποίηση ενός σημείου) και (στ) ώρα της ημέρας (μετασχηματισμός ημιτόνου/κοσινούχου) και η έξοδος του μοντέλου είναι μια πρόβλεψη μιας ώρας μπροστά για την έξοδο ισχύος του Φ/B .

Η διαδικασία επικύρωσης των προτεινόμενων στρατηγικών TL εφαρμόζεται σε 6 Φ/B συστήματα, με διαφορετική ονομαστική και μέγιστη ισχύ, που βρίσκονται σε 4 πόλεις της Πορτογαλίας. Συγκρίνονται τέσσερις αρχιτεκτονικές, συμπεριλαμβανομένων των στρατηγικών TL που παρουσιάζονται, καθώς και ένα συμβατικό μοντέλο όπου δεν έχει εφαρμοστεί TL. Για τα μοντέλα TL, εφαρμόζεται προ-εκπαίδευση σε ολόκληρο το σύνολο δεδομένων του βασικού Φ/B συστήματος (δεδομένα 30 μηνών). Στη συνέχεια, τα τέσσερα μοντέλα εκπαιδεύονται χρησιμοποιώντας δεδομένα ενός έτους (8760 ώρες) και δοκιμάζονται στο υπόλοιπο σύνολο δεδομένων. Για κάθε Φ/B σύστημα το μέγεθος του συνόλου δεδομένων δοκιμής είναι διαφορετικό ανάλογα με τη διαθεσιμότητα των δεδομένων, όπως παρουσιάζεται στον Πίνακα 6.1. Η ακρίβεια των μοντέλων αξιολογείται με βάση την απόδοσή τους στα δεδομένα αξιολόγησης χρησιμοποιώντας τα $RMSE$, MBE , MAE , $NRMSE$ και R^2 .

Για κάθε μοντέλο πραγματοποιούνται 20 επαναλήψεις εκπαίδευσης, προκειμένου να εξαλειφθεί η τυχαιότητα. Αυτός ο αριθμός επαναλήψεων προτείνεται γενικά στη βιβλιογραφία. Η απόδοση πρόβλεψης για όλα τα μοντέλα παρουσιάζεται στον Πίνακα 6.2, όπου αναφέρονται οι μέσες τιμές των $RMSE$, MBE , MAE , $NRMSE$ και R^2 , παρέχοντας ορισμένες πολύ χρήσιμες πληροφορίες.

Πρώτον, αξίζει να αναφερθεί ότι όλα τα μοντέλα LSTM έχουν καλύτερες επιδόσεις από το μοντέλο έξυπνης εμμοής όσον αφορά το $RMSE$. Το γεγονός αυτό καταδεικνύει την καταλληλότητα του επιλεγμένου μοντέλου και των επιλεγμένων χαρακτηριστικών για το συγκεκριμένο πρόβλημα. Η μόνη περίπτωση που το LSTM αποδίδει χειρότερα από το μοντέλο έξυπνης εμμοής είναι για το συμβατικό LSTM του PV_2 . Ακόμη και σε αυτή την περίπτωση τα τρία μοντέλα TL έχουν χαμηλότερους δείκτες σφάλματος από το μοντέλο έξυπνης εμμοής. Ο δείκτης ικανότητας πρόβλεψης κυμαίνεται μεταξύ -0.15 (είναι αρνητικός στην περίπτωση του PV_2) και 0.48 για το συμβατικό μοντέλο, ενώ κυμαίνεται μεταξύ 0.28 και 0.56 για τις στρατηγικές TL. Η μέση ποσοστιαία αύξηση του δείκτη ικανότητας πρόβλεψης μεταξύ του συμβατικού και του μοντέλου TL είναι 16.3% . Τέλος, ο δείκτης MBE δείχνει ότι κανένα από τα μοντέλα που αναπτύχθηκαν δεν παρουσιάζει ενδείξεις μεροληψίας.

Όσον αφορά τη σύγκριση μεταξύ του συμβατικού LSTM και των τριών μοντέλων TL, ο αντίκτυπος του TL είναι εμφανής, καθώς οι στρατηγικές TL έχουν καλύτερη ακρίβεια από τη συμβατική και για τα έξι Φ/B . Τα διαγράμματα που παρουσιάζονται στο Σχήμα 6.5 δείχ-

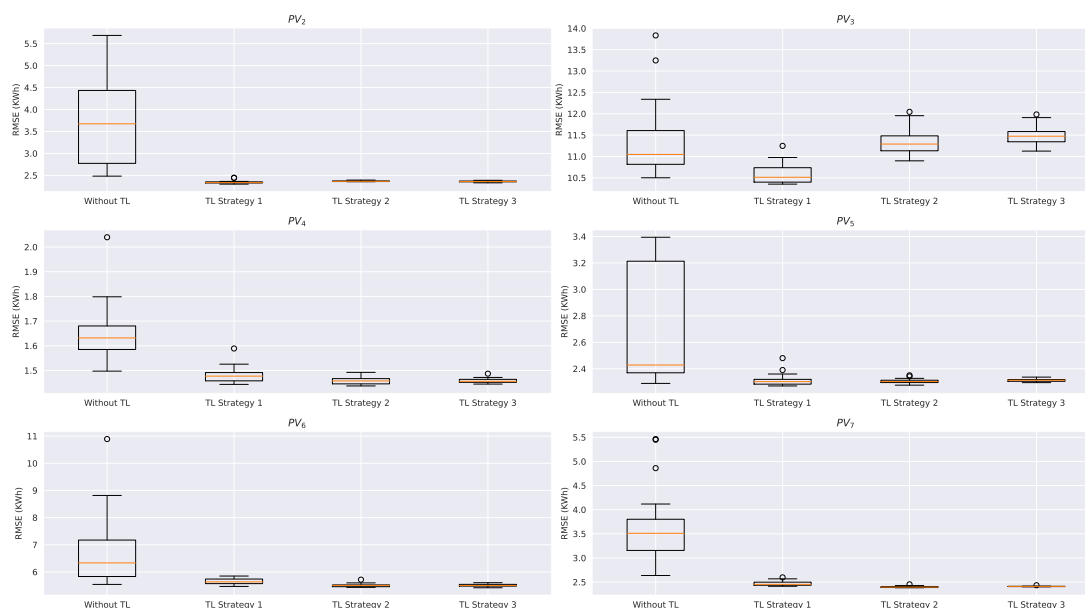
PV	Metric	Without TL	Smart Persistence	TL 1	TL 2	TL 3
PV_2	<i>RMSE</i> (KWh)	3.77	3.27	2.34	2.37	2.36
	<i>MBE</i> (KWh)	-0.25	0.17	0.16	0.06	0.05
	<i>MAE</i> (KWh)	1.81	1.38	1.11	1.11	1.12
	<i>nRMSE</i> (%)	53.14	46.18	33.06	33.38	33.28
	R^2 (%)	87.74	91.37	95.57	95.49	95.51
PV_3	<i>RMSE</i>	11.39	17.32	10.59	11.35	11.48
	<i>MBE</i>	0.83	0.02	0.79	0.81	0.80
	<i>MAE</i>	6.01	6.49	5.29	5.94	5.85
	<i>nRMSE</i>	40.78	62.15	37.94	40.63	41.13
	R^2	93.60	85.27	94.49	93.68	93.53
PV_4	<i>RMSE</i>	1.65	2.69	1.48	1.46	1.46
	<i>MBE</i>	-0.01	-0.82	0.11	0.06	0.07
	<i>MAE</i>	0.81	1.32	0.70	0.69	0.70
	<i>nRMSE</i>	35.57	57.84	31.94	31.42	31.51
	R^2	94.46	85.40	95.55	95.70	95.68
PV_5	<i>RMSE</i>	2.66	5.27	2.31	2.31	2.31
	<i>MBE</i>	-0.08	0.35	-0.04	-0.11	-0.16
	<i>MAE</i>	1.37	1.52	1.13	1.15	1.15
	<i>nRMSE</i>	31.68	62.75	27.56	27.46	27.54
	R^2	95.17	81.51	96.43	96.46	96.44
PV_6	<i>RMSE</i>	6.75	8.59	5.65	5.50	5.51
	<i>MBE</i>	1.35	-0.04	0.94	0.43	0.56
	<i>MAE</i>	3.54	4.25	2.74	2.79	2.77
	<i>nRMSE</i>	40.92	52.11	34.23	33.37	33.40
	R^2	92.72	88.58	95.07	95.33	95.31
PV_7	<i>RMSE</i>	3.64	4.59	2.47	2.40	2.41
	<i>MBE</i>	-0.16	0.15	0.24	-0.02	0.03
	<i>MAE</i>	1.75	1.64	1.15	1.11	1.12
	<i>nRMSE</i>	40.87	51.49	27.78	26.97	27.08
	R^2	92.23	88.19	96.56	96.76	96.74

Πίνακας 6.2: Μέση απόδοση πρόβλεψης (ακρίβεια) του μοντέλου έξυπνης εμμονής και των στοιβαγμένων μοντέλων LSTM με και χωρίς TL. Τα *RMSE*, *MBE* και *MAE* μετρώνται σε KWh, ενώ για τα R^2 και *nRMSE* δίνεται το ποσοστό για κάθε μοντέλο.

νουν επίσης ότι το συμβατικό LSTM έχει μεγαλύτερη μέση τιμή RMSE σε όλα τα Φ/B συστήματα-στόχους, ενώ επιδεικνύει επίσης μεγαλύτερη διακύμανση σε σύγκριση με τα μοντέλα TL. Πράγματι, τα μοντέλα που χρησιμοποιούνται χωρίς TL υποφέρουν από μεγάλη διακύμανση, προσφέροντας σημαντικά διαφορετική ακρίβεια σε κάθε επανάληψη. Αντιθέτως, τα μοντέλα που εκπαιδεύονται με τις τρεις στρατηγικές TL παρουσιάζουν σχεδόν μηδενική διακύμανση, ενώ παράλληλα επιτυγχάνουν ακριβέστερες, μη προκατειλημμένες προβλέψεις. Ένα αξιοσημείωτο σημείο είναι ότι για το PV_3 , όπου η περίοδος αξιολόγησης είναι μόνο 38 ημέρες (910 ωριαίες σημειακές προβλέψεις), τα τρία μοντέλα TL δεν φαίνεται να υπερτερούν του συμβατικού μοντέλου στον βαθμό που υπερτερούν για τα άλλα Φ/B. Αυτό οφείλεται στο γεγονός ότι η αξιολόγηση πραγματοποιείται αποκλειστικά τον Μάρτιο (χειμερινή περίοδος), όπου το πρόβλημα είναι πιο σύνθετο, καθώς τα καιρικά φαινόμενα συχνά διαταράσσονται, ενώ ένα άλλο σημάδι που καταδεικνύει τη δυσκολία πρόβλεψης στο PV_3 είναι ότι ούτε το μοντέλο έξυπνης εμμονής είναι σε θέση να κάνει καλύτερες προβλέψεις.

6.4.4 Επιπτώσεις Διαθεσιμότητας Δεδομένων

Όπως αναφέρθηκε στην εισαγωγική ενότητα, ένα ημερολογιακό έτος δεδομένων είναι το ελάχιστο χρονικό διάστημα για να εκπαιδευτεί επαρκώς ένα μοντέλο, ώστε να ενσωματώσει όλα τα εποχικά και καιρικά πρότυπα του προβλήματος. Επίσης, τα αποτελέσματα που παρουσιάστηκαν δείχνουν ότι τα μοντέλα TL μπορούν να αποδώσουν καλύτερα από τα συμβα-

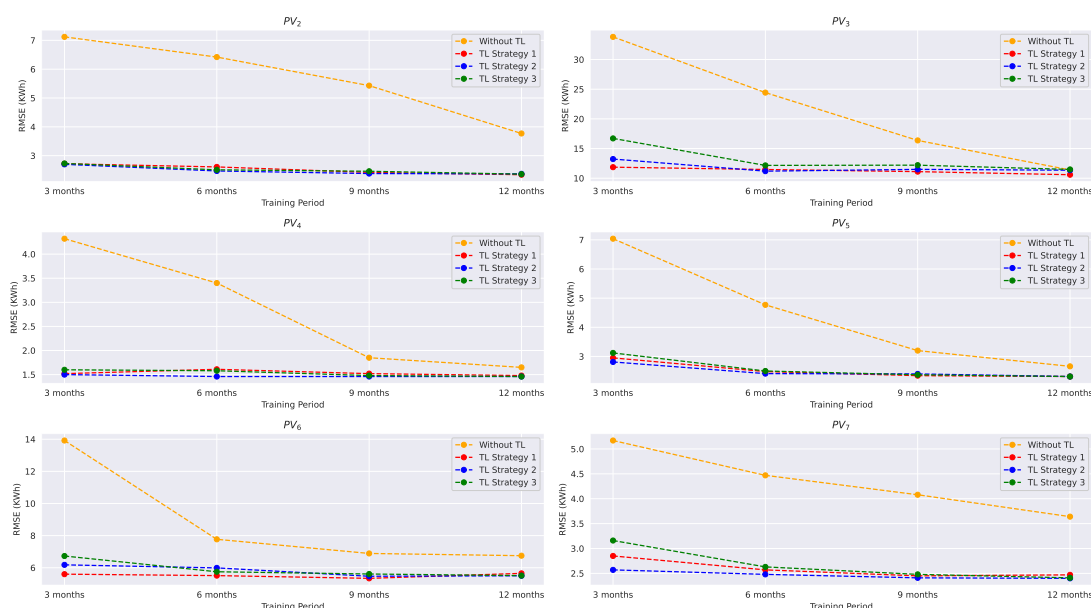


Σχήμα 6.5: Boxplot που συνοψίζει την απόδοση των τεσσάρων στοίβαγμένων μοντέλων LSTM για τα έξι Φ/Β με βάση το RMSE. Η βάση συμβολίζει το μοντέλο στο οποίο δεν έχει εφαρμοστεί TL, ενώ οι TL1, TL2, TL3 συμβολίζουν τις τρεις στρατηγικές TL, αντίστοιχα.

ικά μοντέλα λαμβάνοντας υπόψη ένα σενάριο όπου είναι διαθέσιμα δεδομένα εκπαίδευσης ενός έτους, ενώ τα συμβατικά μοντέλα εξακολουθούν να είναι καλύτερα από τα μοντέλα αναφοράς smart persistence. Ωστόσο, η εφαρμογή της TL προσφέρει τη δυνατότητα να ληφθούν αξιόπιστα και ακριβή μοντέλα πρόβλεψης, ακόμη και όταν τα διαθέσιμα δεδομένα εκπαίδευσης για τον τομέα-στόχο είναι λιγότερα από ένα έτος. Σε αυτό το πλαίσιο, οι προτεινόμενες αρχιτεκτονικές συγκρίνονται στις Φ/Β στόχους για διαφορετικές περιόδους εκπαίδευσης, δηλαδή 3 μήνες, 6 μήνες και 9 μήνες διαθέσιμων δεδομένων. Πρέπει να σημειωθεί ότι, αν και η περίοδος εκπαίδευσης έχει αλλάξει, η περίοδος δοκιμής έχει παραμείνει η ίδια για λόγους σύγκρισης μεταξύ των διαφόρων σεναρίων.

Στο Σχήμα 6.6 παρουσιάζεται ο δείκτης RMSE των τεσσάρων μοντέλων στα τέσσερα προαναφερθέντα σενάρια διαφορετικών περιόδων εκπαίδευσης. Τα αποτελέσματα δείχνουν ότι τα μοντέλα TL είναι πιο ανθεκτικά λαμβάνοντας υπόψη διαφορετικούς όγκους δεδομένων εκπαίδευσης και ότι η απόδοσή τους βελτιώνεται ελαφρώς όταν είναι διαθέσιμα περισσότερα δεδομένα. Αυτό μπορεί να συμβάλει στην προγενέστερη εκπαίδευσή τους στο βασικό Φ/Β κατά τη διάρκεια 3 ετών ωριαίων δεδομένων. Από την άλλη πλευρά, ο αντίκτυπος της έλλειψης δεδομένων είναι εμφανής για το συμβατικό μοντέλο LSTM, το οποίο βελτιώνεται ριζικά όταν αυξάνεται η περίοδος εκπαίδευσης και εντοπίζει νέα εποχικά και καιρικά μοτίβα. Αξίζει να σημειωθεί ότι κανένα από τα εκπαιδευμένα συμβατικά μοντέλα 3 μηνών δεν ξεπερνά το μοντέλο smart persistence, ενώ μόνο τρία εκπαιδευμένα συμβατικά μοντέλα 6 μηνών καταφέρνουν να επιτύχουν καλύτερη ακρίβεια σε σύγκριση με το μοντέλο smart persistence. Το ίδιο δεν ισχύει για τα εκπαιδευμένα μοντέλα TL 3 μηνών, τα οποία έχουν χαμηλότερο RMSE σε σύγκριση τόσο με το συμβατικό LSTM όσο και με το μοντέλο έξυπνης εμμονής.

Τέλος, η διαφορά όσον αφορά το RMSE μεταξύ του συμβατικού μοντέλου και του μοντέλου TL με τις καλύτερες επιδόσεις μειώνεται όσο περισσότερα δεδομένα εκπαίδευσης γίνονται διαθέσιμα. Αυτό είναι εμφανές και για τα έξι Φ/Β-στόχους. Για παράδειγμα, η διαφορά ως προς το RMSE στο PV₅ περιορίζεται από 150,5% (μοντέλα εκπαίδευσης 3 μηνών) σε 15,1%, δηλαδή περίπου 10 φορές χαμηλότερα. Τα ίδια μοτίβα μείωσης εντοπίζονται και στα άλλα πέντε Φ/Β συστήματα, υπογραμμίζοντας περαιτέρω τη σημασία της TL, ιδίως όταν είναι διαθέσιμα δεδομένα λιγότερα από ένα ημερολογιακό έτος.



Σχήμα 6.6: Συγκριτική απόδοση των τεσσάρων μοντέλων με βάση το δείκτη RMSE για περίοδο εκπαίδευσης 3 μηνών, 6 μηνών, 9 μηνών και 12 μηνών για τα έξι Φ/Β του τομέα-στόχου.

6.5 Συμπεράσματα

Η συλλογή επαρκών δεδομένων από πρόσφατα εγκατεστημένους ηλιακούς σταθμούς είναι μια μακρά διαδικασία. Η επείγουσα ανάγκη για ακριβείς προβλέψεις παραγωγής Φ/Β οδήγησε στην ιδέα της αξιοποίησης ηλιακών συστημάτων με επαρκή δεδομένα για την παροχή ακριβών προβλέψεων για τους πρόσφατα εγκατεστημένους. Ο σκοπός της μελέτης αυτής είναι να προσδιοριστεί κατά πόσον το TL μπορεί να χρησιμοποιηθεί αποτελεσματικά για την παροχή προβλέψεων Φ/Β παραγωγής για εγκαταστάσεις με περιορισμένο όγκο δεδομένων. Αναπτύσσονται τρεις στρατηγικές TL που βασίζονται σε μια στοιβαγμένη αρχιτεκτονική LSTM και συγκρίνονται με μια προσέγγιση χωρίς TL. Η μεθοδολογία που παρουσιάζεται δοκιμάζεται σε Φ/Β συστήματα παραγωγής ενέργειας σε διαφορετικές πόλεις και με διαφορετική ονομαστική ισχύ. Τα ευρήματα της πειραματικής εφαρμογής δείχνουν ότι και οι τρεις στρατηγικές TL υπερτερούν σημαντικά της προσέγγισης χωρίς TL όσον αφορά την ακρίβεια πρόβλεψης, η οποία αξιολογείται με διάφορους δείκτες σφάλματος.

Επιπλέον, τα μοντέλα συγκρίνονται με ένα μοντέλο έξυπνης εμμονής που βασίζεται στην παραγωγή ισχύος σε συνθήκες clear sky. Τα μοντέλα που εκπαιδεύονται με τις τρεις στρατηγικές TL υπερτερούν σημαντικά έναντι του μοντέλου αναφοράς, έχοντας βαθμολογία ικανότητας πρόβλεψης μεταξύ 0,28 και 0,56 που θεωρείται ικανοποιητική από την υπάρχουσα βιβλιογραφία. Στον αντίποδα, το μοντέλο LSTM χωρίς TL εμφανίζει περιορισμένη ακρίβεια πρόβλεψης, η οποία ποσοτικοποιείται με μια μέση μείωση του δείκτη ικανότητας πρόβλεψης κατά 16,3%. Τα προαναφερθέντα αποτελέσματα αντιστοιχούν στο σενάριο προσομοίωσης στο οποίο είναι διαθέσιμο ένα ημερολογιακό έτος δεδομένων. Τα αποτελέσματα πρόσθετων πειραμάτων που χρησιμοποιούν ποικίλους όγκους δεδομένων εκπαίδευσης υποδηλώνουν ότι όσο λιγότερα δεδομένα είναι διαθέσιμα, τόσο μεγαλύτερο είναι το χάσμα μεταξύ των στρατηγικών TL και της προσέγγισης χωρίς TL, γεγονός που καθιστά περαιτέρω αναγκαία τη χρήση της TL. Ειδικά στο σενάριο που είναι διαθέσιμα δεδομένα 3 μηνών για εκπαίδευση, το χάσμα μεταξύ του συμβατικού μοντέλου και των TL αυξάνεται σημαντικά, ενώ το συμβατικό LSTM αποτυγχάνει να ξεπεράσει ακόμη και το μοντέλο αναφοράς.

Τέλος, μια από τις σημαντικότερες παραμέτρους στην έννοια της TL είναι η δυνατότητα αναπαραγωγής των στρατηγικών TL που παρουσιάζονται. Προκειμένου να αξιολογηθεί αυτή η πτυχή, η πειραματική εφαρμογή πραγματοποιήθηκε σε τρία Φ/Β συστήματα που βρίσκονται

στην ίδια πόλη με το βασικό Φ/Β και σε τρία Φ/Β που βρίσκονται σε διαφορετικές πόλεις. Αυτό επιτρέπει τη σύγκριση μεταξύ των δύο ομάδων όσον αφορά την ακρίβεια πρόβλεψης. Ωστόσο, το γεγονός ότι τα εν λόγω Φ/Β βρίσκονται σε διαφορετικές πόλεις και έχουν διαφορετική ονομαστική ισχύ υποδεικνύει ότι η σύγκριση πρέπει να πραγματοποιηθεί στον δείκτη ικανότητας πρόβλεψης, ώστε να ευθυγραμμιστεί με τις προτεινόμενες κατευθυντήριες γραμμές επαλήθευσης για τις ντετερμινιστικές ηλιακές προβλέψεις. Έτσι, ο μέσος δείκτης ικανότητας πρόβλεψης για Φ/Β στην ίδια πόλη είναι 0.4, ενώ η αντίστοιχη τιμή για Φ/Β σε διαφορετικές πόλεις είναι 0.43. Αυτό αποτελεί αναμφίβολα ένδειξη ότι η ακρίβεια πρόβλεψης των μοντέλων δεν επηρεάζεται από τη γεωγραφική απόσταση μεταξύ της βάσης και του Φ/Β στόχου.

Η παρούσα μελέτη αποτελεί το πρώτο βήμα προς την ενίσχυση της κατανόησης της επίδρασης της TL στην πρόβλεψη της ισχύος των ηλιακών εγκαταστάσεων. Οι μελλοντικές εργασίες μπορούν να επικεντρωθούν στην αξιολόγηση της επίδρασης του όγκου δεδομένων εκπαίδευσης του βασικού μοντέλου, διερευνώντας κατά πόσον η εκπαίδευση των βασικών μοντέλων με περισσότερα δεδομένα ή με δεδομένα από διαφορετικές ηλιακές εγκαταστάσεις θα μπορούσε να βελτιώσει περαιτέρω την ακρίβεια πρόβλεψης. Αυτό θα μπορούσε να οδηγήσει στην εξέλιξη διακρατικών μοντέλων και στην ανταλλαγή δεδομένων μεταξύ των ενεργειακών κοινοτήτων, με στόχο την προώθηση της συμμετοχικότητας σε περιβάλλοντα έξυπνων πόλεων. Θα πρέπει επίσης να διεξαχθούν περαιτέρω μελέτες, οι οποίες θα λαμβάνουν υπόψη τις διαφορές των γεωγραφικών χαρακτηριστικών μεταξύ του τομέα βάσης και του τομέα-στόχου (π.χ. υψόμετρο, προσανατολισμός ηλιακών εγκαταστάσεων). Τέλος, η προοπτική της δυνατότητας χρήσης του TL για την πρόβλεψη της ισχύος των ηλιακών εγκαταστάσεων, χρησιμεύει ως συνεχές κίνητρο για μελλοντική έρευνα σχετικά με τη μεταφορά γνώσεων σε παρόμοια προβλήματα, όπως η πρόβλεψη της ενέργειας σε διασταυρούμενα κτίρια, η πρόβλεψη της αιολικής ισχύος και η πρόβλεψη της παραγωγής υδραυλικών εγκαταστάσεων, μεταξύ άλλων.

Βιβλιογραφία

- Abdel-Nasser, M. and Mahmoud, K. (2019). Accurate photovoltaic power forecasting models using deep lstm-rnn. *Neural Computing and Applications*, 31(7):2727–2740.
- Ahmad, M. W., Mourshed, M., and Rezgui, Y. (2018). Tree-based ensemble methods for predicting pv power generation and their comparison with support vector regression. *Energy*, 164:465–474.
- Amirul Islam, M., Rochan, M., Bruce, N. D., and Wang, Y. (2017). Gated feedback refinement network for dense image labeling. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3751–3759.
- Antonanzas, J., Osorio, N., Escobar, R., Urraca, R., Martinez-de Pison, F. J., and Antonanzas-Torres, F. (2016). Review of photovoltaic power forecasting. *Solar energy*, 136:78–111.
- Bacher, P., Madsen, H., and Nielsen, H. A. (2009). Online short-term solar power forecasting. *Solar energy*, 83(10):1772–1783.
- Chung, J., Gulcehre, C., Cho, K., and Bengio, Y. (2015). Gated feedback recurrent neural networks. In *International conference on machine learning*, pages 2067–2075. PMLR.
- Dong, Z., Yang, D., Reindl, T., and Walsh, W. M. (2013). Short-term solar irradiance forecasting using exponential smoothing state space model. *Energy*, 55:1104–1113.
- Dumitru, C.-D., Gligor, A., and Enachescu, C. (2016). Solar photovoltaic energy production forecast using neural networks. *Procedia Technology*, 22:808–815.
- Engerer, N. and Mills, F. (2014). Kpv: A clear-sky index for photovoltaics. *Solar energy*, 105:679–693.
- Fan, C., Sun, Y., Xiao, F., Ma, J., Lee, D., Wang, J., and Tseng, Y. C. (2020). Statistical investigations of transfer learning-based methodology for short-term building energy predictions. *Applied Energy*, 262:114499.
- Gao, Y., Ruan, Y., Fang, C., and Yin, S. (2020). Deep learning and transfer learning models of energy consumption forecasting for a building with poor information data. *Energy and Buildings*, 223:110156.
- Gers, F. A., Schmidhuber, J., and Cummins, F. (2000). Learning to forget: Continual prediction with lstm. *Neural computation*, 12(10):2451–2471.
- Ghobakhloo, M. and Fathi, M. (2021). Industry 4.0 and opportunities for energy sustainability. *Journal of Cleaner Production*, 295:126427.
- Gjorgievski, V. Z., Cundeva, S., and Georghiou, G. E. (2021). Social arrangements, technical designs and impacts of energy communities: A review. *Renewable Energy*, 169:1138–1156.
- Gómez-Navarro, T., Brazzini, T., Alfonso-Solar, D., and Vargas-Salgado, C. (2021). Analysis of the potential for pv rooftop prosumer production: Technical, economic and environmental assessment for the city of valencia (spain). *Renewable Energy*, 174:372–381.
- Graves, A. (2013). Generating sequences with recurrent neural networks. *arXiv preprint arXiv:1308.0850*.

- Graves, A., Mohamed, A.-r., and Hinton, G. (2013). Speech recognition with deep recurrent neural networks. In *2013 IEEE international conference on acoustics, speech and signal processing*, pages 6645–6649. Ieee.
- Hermans, M. and Schrauwen, B. (2013). Training and analysing deep recurrent neural networks. *Advances in neural information processing systems*, 26:190–198.
- Hochreiter, S. (1998). The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 6(02):107–116.
- Hochreiter, S., Bengio, Y., Frasconi, P., Schmidhuber, J., et al. (2001). Gradient flow in recurrent nets: the difficulty of learning long-term dependencies.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8):1735–1780.
- Huang, R., Huang, T., Gadh, R., and Li, N. (2012). Solar generation prediction using the arma model in a laboratory-level micro-grid. In *2012 IEEE third international conference on smart grid communications (SmartGridComm)*, pages 528–533. IEEE.
- Huang, Z., Pan, Z., and Lei, B. (2017). Transfer learning with deep convolutional neural network for sar target classification with limited labeled data. *Remote Sensing*, 9(9):907.
- Huertas Tato, J. and Centeno Brito, M. (2018). Using smart persistence and random forests to predict photovoltaic energy production. *Energies*, 12(1):100.
- Kim, T.-Y. and Cho, S.-B. (2019). Predicting residential energy consumption using cnn-lstm neural networks. *Energy*, 182:72–81.
- Kolokotsa, D. (2016). The role of smart grids in the building sector. *Energy and Buildings*, 116:703–708.
- Kong, W., Dong, Z. Y., Jia, Y., Hill, D. J., Xu, Y., and Zhang, Y. (2017). Short-term residential load forecasting based on lstm recurrent neural network. *IEEE Transactions on Smart Grid*, 10(1):841–851.
- Konstantinou, M., Peratikou, S., and Charalambides, A. G. (2021). Solar photovoltaic forecasting of power output using lstm networks. *Atmosphere*, 12(1):124.
- Lu, J., Behbood, V., Hao, P., Zuo, H., Xue, S., and Zhang, G. (2015). Transfer learning using computational intelligence: A survey. *Knowledge-Based Systems*, 80:14–23.
- Marinakos, V., Doukas, H., Tsapelas, J., Mouzakitis, S., Sicilia, Á., Madrazo, L., and Sgouridis, S. (2020). From big data to smart energy services: An application for intelligent energy management. *Future Generation Computer Systems*, 110:572–586.
- Miranda, R. F., Szklo, A., and Schaeffer, R. (2015). Technical-economic potential of pv systems on brazilian rooftops. *Renewable Energy*, 75:694–713.
- Ng, K. K., Chen, C.-H., Lee, C. K., Jiao, J. R., and Yang, Z.-X. (2021). A systematic literature review on intelligent automation: Aligning concepts from theory, practice, and future perspectives. *Advanced Engineering Informatics*, 47:101246.
- Niu, D., Wang, K., Sun, L., Wu, J., and Xu, X. (2020). Short-term photovoltaic power generation forecasting based on random forest feature selection and ceemd: A case study. *Applied Soft Computing*, 93:106389.

- Nizetić, S., Djilali, N., Papadopoulos, A., and Rodrigues, J. J. (2019). Smart technologies for promotion of energy efficiency, utilization of sustainable resources and waste management. *Journal of cleaner production*, 231:565–591.
- Ogliari, E., Dolara, A., Manzolini, G., and Leva, S. (2017). Physical and hybrid methods comparison for the day ahead pv output power forecast. *Renewable Energy*, 113:11–21.
- Olah, C. (2015). Understanding lstm networks, 2015. URL <http://colah.github.io/posts/2015-08-Understanding-LSTMs>, 19:1–19.
- Pan, S. J. and Yang, Q. (2009). A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, 22(10):1345–1359.
- Pascanu, R., Gulcehre, C., Cho, K., and Bengio, Y. (2013). How to construct deep recurrent neural networks. *arXiv preprint arXiv:1312.6026*.
- Pedro, H. T. and Coimbra, C. F. (2012). Assessment of forecasting techniques for solar power production with no exogenous inputs. *Solar Energy*, 86(7):2017–2028.
- Pena-Bello, A., Parra, D., Herberz, M., Tiefenbeck, V., Patel, M. K., and Hahnel, U. J. (2021). Integration of prosumer peer-to-peer trading decisions into energy community modelling. *Nature Energy*, pages 1–9.
- Persson, C., Bacher, P., Shiga, T., and Madsen, H. (2017). Multi-site solar power forecasting using gradient boosted regression trees. *Solar Energy*, 150:423–436.
- Pira, M. (2021). A novel taxonomy of smart sustainable city indicators. *Humanities and Social Sciences Communications*, 8(1):1–10.
- Ribeiro, M., Grolinger, K., ElYamany, H. F., Higashino, W. A., and Capretz, M. A. (2018). Transfer learning with seasonal and trend adjustment for cross-building energy forecasting. *Energy and Buildings*, 165:352–363.
- Sarmas, E., Spiliotis, E., Marinakis, V., Tzanes, G., Kaldellis, J. K., and Doukas, H. (2022). ML-based energy management of water pumping systems for the application of peak shaving in small-scale islands. *Sustainable Cities and Society*, page 103873.
- Su, H., Zio, E., Zhang, J., Xu, M., Li, X., and Zhang, Z. (2019). A hybrid hourly natural gas demand forecasting method based on the integration of wavelet transform and enhanced deep-rnn model. *Energy*, 178:585–597.
- Sun, X., Bright, J. M., Gueymard, C. A., Acord, B., Wang, P., and Engerer, N. A. (2019). Worldwide performance assessment of 75 global clear-sky irradiance models using principal component analysis. *Renewable and Sustainable Energy Reviews*, 111:550–570.
- Sun, X., Bright, J. M., Gueymard, C. A., Bai, X., Acord, B., and Wang, P. (2021). World-wide performance assessment of 95 direct and diffuse clear-sky irradiance models using principal component analysis. *Renewable and Sustainable Energy Reviews*, 135:110087.
- Svirejeva-Hopkins, A., Schellnhuber, H. J., and Pomaz, V. L. (2004). Urbanised territories as a specific component of the global carbon cycle. *Ecological Modelling*, 173(2-3):295–312.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., and Liu, C. (2018). A survey on deep transfer learning. In *International conference on artificial neural networks*, pages 270–279. Springer.

- Torrey, L. and Shavlik, J. (2010). Transfer learning. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques*, pages 242–264. IGI global.
- Tripathy, D. S., Prusty, B. R., and Bingi, K. (2022). A k-nearest neighbor-based averaging model for probabilistic pv generation forecasting. *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, page e2983.
- VanDeventer, W., Jamei, E., Thirunavukkarasu, G. S., Seyedmahmoudian, M., Soon, T. K., Horan, B., Mekhilef, S., and Stojcevski, A. (2019). Short-term pv power forecasting using hybrid gasvm technique. *Renewable energy*, 140:367–379.
- Wang, F., Xuan, Z., Zhen, Z., Li, K., Wang, T., and Shi, M. (2020). A day-ahead pv power forecasting method based on lstm-rnn model and time correlation modification under partial daily pattern prediction framework. *Energy Conversion and Management*, 212:112766.
- Weiss, K., Khoshgoftaar, T. M., and Wang, D. (2016). A survey of transfer learning. *Journal of Big data*, 3(1):1–40.
- Yang, D. (2019a). A guideline to solar forecasting research practice: Reproducible, operational, probabilistic or physically-based, ensemble, and skill (ropes). *Journal of Renewable and Sustainable Energy*, 11(2):022701.
- Yang, D. (2019b). Making reference solar forecasts with climatology, persistence, and their optimal convex combination. *Solar Energy*, 193:981–985.
- Yang, D., Alessandrini, S., Antonanzas, J., Antonanzas-Torres, F., Badescu, V., Beyer, H. G., Blaga, R., Boland, J., Bright, J. M., Coimbra, C. F., et al. (2020). Verification of deterministic solar forecasts. *Solar Energy*, 210:20–37.
- Yao, Y. and Doretto, G. (2010). Boosting for transfer learning with multiple sources. In *2010 IEEE computer society conference on computer vision and pattern recognition*, pages 1855–1862. IEEE.
- Yona, A., Senjyu, T., Saber, A. Y., Funabashi, T., Sekine, H., and Kim, C.-H. (2008). Application of neural network to 24-hour-ahead generating power forecasting for pv system. In *2008 IEEE Power and Energy Society General Meeting-Conversion and Delivery of Electrical Energy in the 21st Century*, pages 1–6. IEEE.
- Zamo, M., Mestre, O., Arbogast, P., and Pannekoucke, O. (2014). A benchmark of statistical regression methods for short-term forecasting of photovoltaic electricity production, part i: Deterministic forecast of hourly production. *Solar Energy*, 105:792–803.
- Zhou, S., Zhou, L., Mao, M., and Xi, X. (2020). Transfer learning for photovoltaic power forecasting with long short-term memory neural network. In *2020 IEEE International Conference on Big Data and Smart Computing (BigComp)*, pages 125–132. IEEE.

Κεφάλαιο 7

Μοντέλο Πρόβλεψης Ενεργειακής Κατανάλωσης Κτιρίων για την Εκτίμηση της Εξοικονόμησης Ενέργειας

7.1 Εισαγωγή

Παρά το σημαντικό μερίδιο που κατέχει στην παγκόσμια συνολική τελική κατανάλωση ενέργειας (35%) και στις εκπομπές CO_2 που σχετίζονται με την ενέργεια (38%) το 2019, ο κτιριακός τομέας διατηρεί σταθερό επίπεδο στην παγκόσμια κατανάλωση ενέργειας και στις εκπομπές από το 2018 (?). Ωστόσο, η λειτουργική κατανάλωση ενέργειας των κτιρίων σε παγκόσμια κλίμακα εξακολουθεί να ανέρχεται σε περίπου 130 EJ, αποτελώντας περίπου το 30% της συνολικής τελικής κατανάλωσης, ενώ η κατανάλωση ηλεκτρικής ενέργειας στα κτίρια αντιπροσωπεύει πλέον περίπου το 55% της παγκόσμιας κατανάλωσης ηλεκτρικής ενέργειας (IEA, 2020a). Υπό το πρίσμα αυτών των στατιστικών στοιχείων, η μείωση της κατανάλωσης ενέργειας και των εκπομπών στον κτιριακό τομέα αναδεικνύεται σε καίρια πρόκληση για την αντιμετώπιση της κλιματικής αλλαγής. Στο πλαίσιο αυτό, η εφαρμογή μέτρων ανακαίνισης κτιρίων αναδεικνύεται ως μια πολλά υποσχόμενη οδός για την επίτευξη των στόχων αυτών (Ürge-Vorsatz et al., 2007). Η αναβάθμιση των υφιστάμενων κτιρίων με ενεργειακά αποδοτικά συστήματα, όπως η ενισχυμένη μόνωση και ο φωτισμός, παρέχει τη δυνατότητα σημαντικής εξοικονόμησης ενέργειας και μείωσης των εκπομπών αερίων του θερμοκηπίου. Ωστόσο, παρά τα μελλοντικά οφέλη, η πρόοδος της ανακαίνισης των κτιρίων είναι υποτονική, με αποτέλεσμα ένα σημαντικό τμήμα του κτιριακού αποθέματος να παραμένει ενεργειακά αναποτελεσματικό. Επιπλέον, η πανδημία COVID-19 υπογράμμισε τον κρίσιμο ρόλο των υγιεινών και βιώσιμων κτιρίων, ενισχύοντας έτσι τον επείγοντα χαρακτήρα της δράσης σε αυτόν τον τομέα. Οι κυβερνήσεις και οι φορείς χάραξης πολιτικής διαδραματίζουν κρίσιμο ρόλο στην παροχή κινήτρων για την ανακαίνιση των κτιρίων μέσω της εφαρμογής κανονισμών, μηχανισμών χρηματοδότησης και άλλων μέσων πολιτικής (Bertoldi et al., 2021). Τέτοιες προσπάθειες μπορούν να διαδραματίσουν καθοριστικό ρόλο στην απελευθέρωση του δυναμικού της ανακαίνισης κτιρίων ως κεντρικής στρατηγικής για τη μείωση της κατανάλωσης ενέργειας, τον μετριασμό της κλιματικής αλλαγής και τη δημιουργία ενός υγιέστερου και πιο βιώσιμου δομημένου περιβάλλοντος για το μέλλον (IEA, 2020b).

Τα ECM αποτελούν θεμελιώδες μέσο για τη μείωση της κατανάλωσης ενέργειας και των εκπομπών αερίων του θερμοκηπίου σε διάφορους τομείς, συμπεριλαμβανομένων των κτιρίων, της βιομηχανίας και των μεταφορών (Lundström and Wallin, 2016). Τα μέτρα αυτά περιλαμβάνουν ένα φάσμα παρεμβάσεων, όπως αναβαθμίσεις εξοπλισμού, βελτιώσεις στη μόνωση, στα συστήματα φωτισμού και στην εφαρμογή ενεργειακά αποδοτικών πρακτικών. Ωστόσο, η διασφάλιση της αποτελεσματικότητας των ECM απαιτεί την ακριβή μέτρηση και επαλήθευση

(M&V) της προκύπτουσας εξοικονόμησης ενέργειας. Η σημασία της M&V έχει αυξηθεί σημαντικά ως απάντηση στις ενεργειακές πολιτικές που έχουν θεσπιστεί παγκοσμίως. Η οδηγία της Ευρωπαϊκής Ένωσης για την ενεργειακή απόδοση, για παράδειγμα, επιβάλλει στα κράτη μέλη να επιτύχουν επιμέρους προόδους στην ενεργειακή απόδοση, απαιτώντας έτσι την ακριβή και αξιόπιστη εκτίμηση της εξοικονόμησης ενέργειας που προέρχεται από διάφορες ECM για την αποτελεσματική εκτέλεση της οδηγίας (Balaras et al., 2016). Ο βαθμός στον οποίο η εξοικονόμηση ενέργειας μπορεί να ποσοτικοποιηθεί αξιόπιστα εξαρτάται από την παρουσία αβεβαιότητας, καθιστώντας την ανάλυση αβεβαιότητας απαραίτητο βήμα για την ακριβή εκτίμηση της εξοικονόμησης ενέργειας.

Προκειμένου να εκτιμηθεί η εξοικονόμηση ενέργειας που προκύπτει από ένα ECM, πρέπει να διεξαχθεί συγκριτική ανάλυση μεταξύ της κατανάλωσης ενέργειας κατά την περίοδο αναφοράς (μετά το ECM) και της υποθετικής κατανάλωσης που θα είχε πραγματοποιηθεί ελλείψει του ECM. Αυτή η σύγκριση είναι συνήθως γνωστή ως προσαρμοσμένη γραμμή βάσης. Κατά συνέπεια, καθίσταται αναγκαία η τυποποίηση της κατανάλωσης μετά την EKM ώστε να ευθυγραμμιστεί με τις συνθήκες πριν την EKM (Osés et al., 2016). Για τη διευκόλυνση αυτής της διαδικασίας κανονικοποίησης χρησιμοποιείται συνήθως η ανάπτυξη ενός μοντέλου βασικής γραμμής με τη χρήση μηχανικών ή στατιστικών μεθοδολογιών. Επιπλέον, για να εξασφαλιστεί η αξιοπιστία και η εγκυρότητα της εκτιμώμενης εξοικονόμησης ενέργειας, είναι ζωτικής σημασίας να ενσωματωθεί ένα ποσοτικοποιημένο μέτρο αβεβαιότητας, το οποίο χρησιμεύει ως δείκτης της ακρίβειας που σχετίζεται με την εκτίμηση της εξοικονόμησης (Granderson et al., 2016).

Ο ακριβής ποσοτικός προσδιορισμός της εξοικονόμησης ενέργειας αποτελεί σημαντική πρόκληση λόγω της πολυπλοκότητας, που απαιτεί την εξέταση πολλαπλών μεταβλητών και εγγενών αβεβαιοτήτων. Ως αποτέλεσμα, η M&V της εξοικονόμησης ενέργειας έχει συγκεντρώσει αυξανόμενη προσοχή τα τελευταία χρόνια, ωθούμενη από τη φιλοδοξία να βελτιωθεί η αξιοπιστία και η ακρίβεια των εκτιμήσεων της εξοικονόμησης ενέργειας. Η ουσία της πρόκλησης έγκειται στην ανάπτυξη ολοκληρωμένων μοντέλων που περιλαμβάνουν ένα ευρύ φάσμα μεταβλητών που επηρεάζουν την ενεργειακή κατανάλωση, καλύπτοντας τις κλιματικές συνθήκες, τα πρότυπα χρήσης και την απόδοση των επιμέρους ενεργειακών συστημάτων. Η έλευση της ψηφιοποίησης στο χώρο των κτιρίων, συνοδευόμενη από τον πολλαπλασιασμό των συσκευών του Διαδικτύου των Πραγμάτων (IoT) που καταγράφουν εκτεταμένα σύνολα δεδομένων, επιφυλάσσει μεγάλες δυνατότητες για την προώθηση της ανάπτυξης εξελεγχόμενων μοντέλων μηχανικής μάθησης (ML) για την εκτίμηση της εξοικονόμησης ενέργειας (Tsiatsis et al., 2018; Granell et al., 2020). Αυτά τα μοντέλα ML διαθέτουν την ικανότητα να ενσωματώνουν ένα ευρύ φάσμα μεταβλητών και πηγών δεδομένων, επιτρέποντας έτσι ακριβέστερες και πιο αξιόπιστες εκτιμήσεις εξοικονόμησης ενέργειας. Η υιοθέτηση των μοντέλων ML για την εκτίμηση της εξοικονόμησης ενέργειας παρουσιάζει μια συναρπαστική ευκαιρία για την ενίσχυση της αποτελεσματικότητας και των αποτελεσμάτων των ECM, διευκολύνοντας έτσι την επίτευξη των φιλοδοξιών στόχων της ενεργειακής πολιτικής (Agrawal et al., 2023). Παρόλα αυτά, η επιτυχής ανάπτυξη τέτοιων μοντέλων απαιτεί πρόσβαση σε δεδομένα υψηλής ποιότητας και την τεχνογνωσία ικανών επαγγελματιών που γνωρίζουν καλά τις τεχνικές ανάλυσης δεδομένων και μοντελοποίησης.

Το παρόν κεφάλαιο αποσκοπεί στην αντιμετώπιση των προκλήσεων που αφορούν την ακριβή εκτίμηση της εξοικονόμησης ενέργειας μέσω μιας συγκριτικής ανάλυσης διαφόρων μοντέλων ML που χρησιμοποιούνται στη βασική ενεργειακή μοντελοποίηση. Η καινοτομία της παρούσας μελέτης έγκειται στη χρήση μοντέλων ML, τα οποία αποσκοπούν στην πλήρη αξιοποίηση του πλούτου των υψηλής ποιότητας μεγάλων δεδομένων που είναι διαθέσιμα για τον χαρακτηρισμό της κατανάλωσης ενέργειας στα κτίρια. Ειδικότερα, η έρευνα αποσκοπεί να διακρίνει κατά πόσον η εφαρμογή συνόλων που περιλαμβάνουν αυτά τα μοντέλα ML μπορεί να αυξήσει περαιτέρω την ακρίβεια της εκτίμησης της εξοικονόμησης ενέργειας. Επιπλέον, η παρούσα μελέτη διεξάγει εκτεταμένες δοκιμές σε ένα σημαντικό σύμπλεγμα κτιρίων του πραγματικού κόσμου που βρίσκονται στη Λετονία, προσφέροντας έτσι πολύτιμες πληροφορίες σχετικά με τη δυνατότητα γενίκευσης των προτεινόμενων μοντέλων σε πρακτικές εφαρμογές.

Εμβραθύνοντας στις δυνατότητες των μοντέλων DL και των συνόλων για την εκτίμηση της εξοικονόμησης ενέργειας, η παρούσα ερευνητική προσπάθεια συμβάλλει στην προώθηση πιο αποτελεσματικών ECM, τα οποία είναι απαραίτητα για την επίτευξη των σημερινών φιλόδοξων στόχων της ενεργειακής πολιτικής.

Οι συνεισφορές του παρόντος κεφαλαίου συνοψίζονται ως εξής:

- Η μελέτη προτείνει και συγκρίνει διαφορετικά μοντέλα ML για την εκτίμηση της βασικής κατανάλωσης ενέργειας σε κτίρια, αξιοποιώντας υψηλής ποιότητας μεγάλα δεδομένα που είναι διαθέσιμα από συσκευές IoT.
- Η μελέτη διερευνά τις δυνατότητες των συνόλων μοντέλων ML για την περαιτέρω αύξηση της ακρίβειας της εκτίμησης της κατανάλωσης ενέργειας.
- Τα προτεινόμενα μοντέλα δοκιμάζονται σε ένα μεγάλο σύμπλεγμα πραγματικών κτιρίων στη Λετονία, παρέχοντας πολύτιμες πληροφορίες σχετικά με την αποτελεσματικότητα και τη δυνατότητα γενίκευσης των μοντέλων σε πρακτικές εφαρμογές.

Το υπόλοιπο κεφάλαιο είναι οργανωμένο ως εξής. Στην ενότητα 7.2 παρουσιάζεται το πλαίσιο του προβλήματος και η βιβλιογραφική ανασκόπηση. Στην ενότητα 7.3 περιγράφεται η μεθοδολογία που αναπτύχθηκε. Στην ενότητα 7.4 παρουσιάζεται μια πειραματική εφαρμογή που βασίζεται σε μια πραγματική μελέτη περίπτωσης στη Λετονία. Τέλος, στην ενότητα 7.5 παρατίθενται συμπερασματικές παρατηρήσεις.

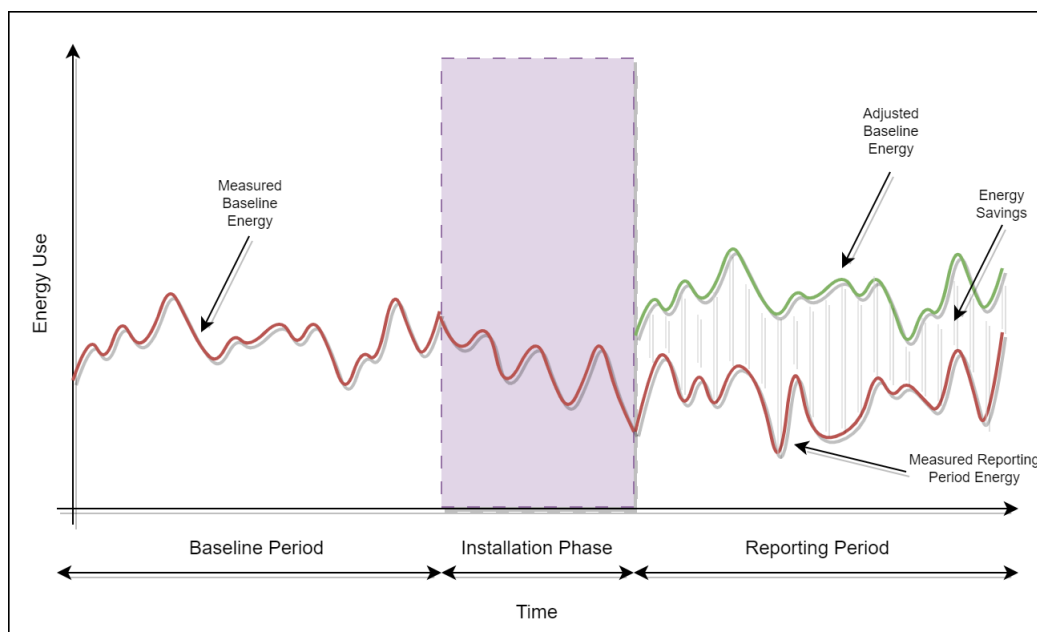
7.2 Αναλυτική Διατύπωση Προβλήματος

7.2.1 Μοντελοποίηση Baseline Κατανάλωσης

Οι νομοθετικές προσπάθειες έχουν επικεντρωθεί κυρίως στην εφαρμογή ECMs, με στόχο τη μείωση της κατανάλωσης ενέργειας. Η αποτελεσματικότητα αυτής της προσπάθειας εξαρτάται σε μεγάλο βαθμό από την ακρίβεια της M&V που διεξάγεται για κάθε επιμέρους ECM, εξασφαλίζοντας μια αξιόπιστη εκτίμηση της εξοικονόμησης ενέργειας. Ωστόσο, προκύπτει μια σημαντική ανησυχία σχετικά με την πιθανή υπερεκτίμηση της εξοικονόμησης σε επίπεδο έργου, η οποία θα μπορούσε να εμποδίσει τις προσπάθειες μετριασμού της κλιματικής αλλαγής. Κατά συνέπεια, υπάρχει επείγουσα ανάγκη για μια μεθοδολογία ικανή να ξεπεράσει τα εμπόδια που εμποδίζουν την ακριβή M&V σε κτιριακές εγκαταστάσεις, περιλαμβάνοντας προκλήσεις που σχετίζονται με το κόστος, τους περιορισμούς πόρων και τους χρονικούς περιορισμούς. Προηγούμενες έρευνες έχουν αναγνωρίσει τις δυνατότητες του ML ως βιώσιμο εργαλείο για την αντιμετώπιση αυτών των προκλήσεων, αναδεικνύοντας την καταλληλότητά του στο συγκεκριμένο πλαίσιο (Gallagher et al., 2018).

Στο πλαίσιο των έργων M&V, είναι εμφανείς τρεις διακριτές σημαντικές περίοδοι, δηλαδή η περίοδος αναφοράς, η περίοδος υλοποίησης και η περίοδος υποβολής εκθέσεων. Οι περίοδοι αυτές είναι διαδοχικά οργανωμένες, ωστόσο η διάρκειά τους ποικίλλει ανάλογα με τις συγκεκριμένες παραμέτρους του έργου. Πριν από την εφαρμογή των MAI, η περίοδος βάσης καθορίζει ένα σημείο αναφοράς, ενώ η περίοδος αναφοράς ακολουθεί μετά την εφαρμογή των MAI. Μια κρίσιμη εργασία στο πλαίσιο της διαδικασίας M&V περιλαμβάνει την εκτίμηση της προσαρμοσμένης γραμμής βάσης κατά την περίοδο αναφοράς με την κανονικοποίηση της κατανάλωσης ενέργειας σε συνθήκες βάσης. Συνήθως, χρησιμοποιούνται μηχανικές ή στατιστικές μεθοδολογίες για την κατασκευή ενός μοντέλου γραμμής βάσης ικανό να επιτύχει αυτή την κανονικοποίηση. Κατά συνέπεια, πρέπει να αναγνωριστεί ότι η M&V είναι μια εγγενώς ανακριβής πειθαρχία και η διατήρηση της ακρίβειας καθ' όλη τη διάρκεια της διαδικασίας είναι πρωταρχικής σημασίας για την επιτυχία της. Οι πρωταρχικές πηγές αβεβαιότητας στη M&V περιλαμβάνουν τη δειγματοληψία, τη μέτρηση και τη μοντελοποίηση. Για να αντιμετωπιστεί αυτό, το Διεθνές Πρωτόκολλο Μέτρησης και Επαλήθευσης της Απόδοσης (IPMVP) περιγράφει ένα μεθοδολογικό πλαίσιο για την ποσοτικοποίηση της αβεβαιότητας σε ένα έργο, με

το ελάχιστο αποδεκτό επίπεδο αβεβαιότητας να ορίζεται ως το όριο όπου η εξοικονόμηση υπερβαίνει το διπλάσιο του τυπικού σφάλματος της τιμής βάσης.



Σχήμα 7.1: Υπολογισμός εξοικονόμησης ενέργειας σύμφωνα με το πλαίσιο IPMVP. Η εξοικονόμηση μπορεί να εκτιμηθεί με μετρήσεις πριν και μετά την εγκατάσταση του ECM, αλλά απαιτείται επίσης κανονικοποίηση της ενέργειας βάσης για την ενσωμάτωση των καιρικών και άλλων επιδράσεων.

Η IPMVP χρησιμεύει ως η επικρατούσα και παγκοσμίως υιοθετημένη μεθοδολογία για την M&V, η οποία περιλαμβάνει τέσσερις διαφορετικές προσεγγίσεις που ανταποκρίνονται σε ένα ευρύ φάσμα δράσεων αναβάθμισης. Οι επιλογές A και B καθορίζουν ένα όριο έργου που απομονώνει τη μετασκευή και περιλαμβάνει τον επηρεαζόμενο εξοπλισμό. Η επιλογή Γ υιοθετεί μια ολοκληρωμένη προσέγγιση ολόκληρου του κτιρίου, κατάλληλη για σενάρια όπου η εξοικονόμηση υπερβαίνει το 10 % της συνολικής κατανάλωσης ενέργειας της εγκατάστασης. Η επιλογή Δ περιλαμβάνει μια βαθμονομημένη προσομοίωση των ενεργειακών συστημάτων, η οποία αποδεικνύεται επωφελής σε περιπτώσεις όπου δεν υπάρχουν δεδομένα βάσης. Συμπληρωματικά με το IPMVP, η κατευθυντήρια γραμμή 14 της ASHRAE και το ISO50015 προσφέρουν μεθοδολογίες που βασίζονται στις βασικές αρχές του, παρέχοντας ισχυρά πλαίσια. Ωστόσο, ένα αξιοσημείωτο μειονέκτημα αυτών των γενικευμένων μεθοδολογιών είναι η αναγνωρισμένη έλλειψη καθοδήγησης σχετικά με τη διαδικασία υπολογισμού.

Ο προσδιορισμός της εξοικονόμησης μπορεί να περιλαμβάνει είτε ολόκληρη την εγκατάσταση είτε ένα συγκεκριμένο τμήμα της, ανάλογα με τα χαρακτηριστικά των μέτρων ενεργειακής απόδοσης (MEA) και τον επιδιωκόμενο σκοπό της αναφοράς. Για να απομονωθεί ο εξοπλισμός και η σχετική χρήση ενέργειας που επηρεάζεται από τα MEA από τον εξοπλισμό που δεν επηρεάζεται, καθορίζεται ένα όριο μέτρησης. Εντός αυτού του ορίου, όλη η ενέργεια που καταναλώνεται ή παράγεται πρέπει να μετράται ή να εκτιμάται με τη χρήση μετρητών. Είναι ζωτικής σημασίας να λαμβάνονται υπόψη όλες οι ροές ενέργειας κατά μήκος του ορίου μέτρησης, συμπεριλαμβανομένων των περιπτώσεων όπου η ενέργεια μπορεί να ρέει αντίστροφα, όπως στην περίπτωση της επιτόπιας ηλιακής παραγωγής. Η επιλογή ενός ορίου μέτρησης ευθυγραμμίζεται με μία ή περισσότερες από τις τέσσερις επιλογές του IPMVP, οι οποίες επηρεάζουν το επίπεδο λεπτομέρειας της αναφερόμενης εξοικονόμησης και των απαιτούμενων μετρήσεων. Η επιλογή των επιλογών θα πρέπει να λαμβάνει υπόψη το σκοπό της αναφοράς M&V.

Εάν ο στόχος της αναφοράς είναι να επαληθευτεί η εξοικονόμηση που προκύπτει από τον αντίκτυπο των HEM στον εξοπλισμό, ένα όριο μέτρησης θα πρέπει να περιλαμβάνει τον

συγκεκριμένο εξοπλισμό, επιτρέποντας τον καθορισμό των απαιτήσεων μέτρησης εντός του ορίου. Η προσέγγιση αυτή αντιστοιχεί στην επιλογή απομόνωσης της μετασκευής (επιλογή A ή B). Εάν ο στόχος υποβολής εκθέσεων περιλαμβάνει την επαλήθευση ή/και τη διαχείριση της συνολικής ενεργειακής απόδοσης ολόκληρης της εγκατάστασης ή την επικύρωση της εξοικονόμησης που προκύπτει από πολλαπλά EEM με αλληλεπιδραστικές επιδράσεις, οι μετρητές που μετρούν την παροχή ενέργειας σε ολόκληρη την εγκατάσταση μπορούν να χρησιμοποιηθούν για την αξιολόγηση της απόδοσης και της εξοικονόμησης. Στην περίπτωση αυτή, το όριο μέτρησης περιλαμβάνει ολόκληρη την εγκατάσταση και η προσέγγιση που χρησιμοποιείται είναι η επιλογή Γ: Ολόκληρη εγκατάσταση. Σε περιπτώσεις όπου υπάρχουν αναξιόπιστα ή μη διαθέσιμα δεδομένα για την περίοδο αναφοράς ή την περίοδο αναφοράς (π.χ. νέα κατασκευαστικά έργα), μπορούν να χρησιμοποιηθούν βαθμονομημένα μοντέλα προσομοίωσης για την παροχή ενεργειακών δεδομένων είτε για ένα τμήμα είτε για το σύνολο της εγκατάστασης. Το όριο μέτρησης μπορεί να οριοθετηθεί αναλόγως και η προσέγγιση που χρησιμοποιείται είναι η επιλογή Δ: βαθμονομημένη προσομοίωση.

7.2.2 Συσχετιζόμενη Βιβλιογραφία

Στη βιβλιογραφία έχουν δοκιμαστεί διάφορες προσεγγίσεις για τη μοντελοποίηση της κατανάλωσης των κτιρίων κατά την περίοδο αναφοράς. Είναι προφανές ότι οι προσεγγίσεις ενεργειακής μοντελοποίησης που βασίζονται στην ML υπερτερούν των παραδοσιακών προσεγγίσεων γραμμικής παλινδρόμησης (Ye et al., 2020; Mustapa et al., 2020) και η καταλληλότητά τους αποδεικνύεται σε ένα ευρύ φάσμα μελετών στον εμπορικό τομέα (Granderson et al., 2016; Ekici and Aksoy, 2009; Wong et al., 2010; Li et al., 2009; Neto and Fiorelli, 2008; Karatasou et al., 2006; Haberl and Thamilseran, 1996), οικιακές (Edwards et al., 2012; Jain et al., 2014; Agenis-Nevers et al., 2021) καθώς και βιομηχανικές (Gallagher et al., 2018; Kissock and Eger, 2008; Rossi and Velázquez, 2015) εφαρμογές. Για την εύρεση της βέλτιστης προσέγγισης ML και λαμβάνοντας υπόψη τις ποικίλες επιπτώσεις των χαρακτηριστικών (όπως οι επιλεγμένες μεταβλητές εισόδου, η ποσότητα και η ποιότητα των διαθέσιμων δεδομένων εκπαίδευσης, η κοκχομετρία των δεδομένων και των προβλέψεων κ.λπ.) στην απόδοση του μοντέλου, είναι σημαντικό να συγκριθούν οι διάφορες τεχνικές μοντελοποίησης στο πλαίσιο των μοναδικών συνθηκών του έργου και υπό τις ίδιες συνθήκες.

Υπό αυτή την προοπτική, υπάρχουν πολλές μελέτες που συγκρίνουν διαφορετικές τεχνικές ML στο πλαίσιο της ίδιας εφαρμογής. Gallagher et al. (2018) εφάρμοσε έξι τεχνικές ML, δηλαδή παλινδρόμηση ελαχίστων τετραγώνων με δύο και πολλές μεταβλητές, δέντρα αποφάσεων, k-κοντινότερους γείτονες, τεχνητά νευρωνικά δίκτυα και μηχανές διανυσμάτων υποστήριξης, για την M&V της εξοικονόμησης ενέργειας στο πλαίσιο βιομηχανικών κτιρίων (βιοϊατρική μονάδα παραγωγής). Το βέλτιστο μοντέλο ήταν ένα μονοστρωματικό νευρωνικό δίκτυο τροφοδότησης προς τα εμπρός, το οποίο εκπαιδεύτηκε με μηνιαία δεδομένα και παρουσίασε μείωση του σφάλματος κατά 51

Πίνακας 7.1: Ανασκόπηση της βιβλιογραφίας σχετικά με τις μελέτες βασικής ενεργειακής μοντελοποίησης.

#	Author (Έτος)	Μοντέλα	Μετρικές	Τύπος Κτιρίου
1	Touzani et al. (2018)	GBM	R2, CV(RMSE)	Commercial
2	Grillone et al. (2021)	GBM	CV(RMSE)	Commercial
3	Li et al. (2022)	iTrAdaBoost	MAPE, RMSE, MAE	Educational
4	Kapp et al. (2023)	SVM	RMSE, MAE	Industrial
5	Agenis-Nevers et al. (2021)	LR, OLS, KNN, SVM	MASE, MAPB	Commercial
6	Gallagher et al. (2018)	OLS, DT, KNN, SVM, ANN	med(absRTE), CV(RMSE), NMBE	Industrial
7	Mustapa et al. (2020)	NARX-ANN	MSE, RMSE	Educational
8	Ye et al. (2020)	LR, ANN	MSE	Residential
9	Granderson et al. (2016)	KNN, DT, RF	NMBE, CV(RMSE)	Multiple
10	Ekici and Aksoy (2009)	ANN	SSE, MSE	Multiple
11	Wong et al. (2010)	ANN	CV(RMSE)	Commercial
12	Li et al. (2009)	BPNN, RBFNN, GRNN, SVM	RMSE, MRE	Commercial
13	Neto and Fiorelli (2008)	ANN, EnergyPlus	SE	Commercial
14	Karatasou et al. (2006)	ANN	CV(RMSE), MBE	Commercial
15	Rossi and Velázquez (2015)	ANN	R2, RMSE, MAE	CHP Plant
16	Díaz et al. (2018)	Gaussian Mixture	R2	Commercial

Η ακρίβεια των εκτιμήσεων εξοικονόμησης εξαρτάται επίσης από την επιλογή των μεταβλ-

ητών εισόδου του μοντέλου. Οι παράγοντες που επηρεάζουν περισσότερο την ενεργειακή κατανάλωση των κτιρίων θα πρέπει να επιλέγονται και να ενσωματώνονται με τις καταλληλότερες μετρήσεις στα βασικά μοντέλα. Οι παράγοντες αυτοί μπορεί να αφορούν το κλίμα και τις καιρικές συνθήκες, όπως η υγρασία, οι ημέρες ψύξης ή θερμότητας, η ταχύτητα του ανέμου, η ηλιακή ακτινοβολία (Díaz et al., 2018; Kapp et al., 2023), ο τύπος και η ένταση της χρήσης, συμπεριλαμβανομένων των επιπέδων πληρότητας, ο τύπος του κτιρίου, ο αριθμός των εργασιμών ημερών ανά μήνα, το πρόγραμμα του κτιρίου - επίπεδο παραγωγής, πρόγραμμα λειτουργίας (Kapp et al., 2023), η χρονική περίοδος χρήσης ανάλογα με τη χρονική κοκκομετρία του μοντέλου (εποχή, μήνας του έτους, καθημερινή ημέρα/ Σαββατοκύριακο, ώρα της ημέρας), τα χαρακτηριστικά του κτιρίου, συμπεριλαμβανομένου του συνολικού συντελεστή θερμικών απωλειών του κτιρίου, του προσανατολισμού, του πάχους μόνωσης (Ekici and Aksoy, 2009) ή οποιοδήποτε άλλο διασυνδεδεμένο σύνολο των προαναφερθέντων μεταβλητών. Κάθε ένας από τους παραπάνω παράγοντες μπορεί να μεταφραστεί σε μεταβλητές του μοντέλου με διαφορετικούς τρόπους.

Αναφερόμαστε ενδεικτικά στην υγρασία του εξωτερικού αέρα, στη θερμοκρασία σημείου δρόσου ή υγρού βολβού και στην ενθαλπία ως εναλλακτικούς τρόπους μοντελοποίησης της υγρασίας (Price, 2010). Κάθε μία από τις παραπάνω μεταβλητές θα μπορούσε επίσης να αλληλεπιδράσει μεταξύ τους και να οδηγήσει στην εισαγωγή νέων κλιματικών μεταβλητών, όπως η "ενθαλπία υγρού αέρα", όταν αναμειγνύονται η θερμοκρασία και η υγρασία, και η "δυναμική εξατμισοδιαπνοή" που προτάθηκε από την Agenis-Nevers et al. (2021) ως συνάρτηση της πίεσης του αέρα, της υγρασίας, της θερμοκρασίας, της ταχύτητας του ανέμου, της ηλιακής ακτινοβολίας και άλλων. Το Agenis-Nevers et al. (2021) πρότεινε επίσης μια αυτοματοποιημένη μέθοδο επιλογής για τον εντοπισμό των καλύτερων συνόλων μεταβλητών για τα κτίρια που αναλύθηκαν. Νέα χαρακτηριστικά του μοντέλου εισάγονται επίσης στην εργασία του Catalina et al. (2013), ο οποίος χρησιμοποίησε τον παγκόσμιο συντελεστή απώλειας θερμότητας του κτιρίου, τη νότια ισοδύναμη επιφάνεια και τη διαφορά μεταξύ της εσωτερικής θερμοκρασίας του σημείου ρύθμισης και της ηλιακής θερμοκρασίας για την πρόβλεψη της ζήτησης ενέργειας θέρμανσης.

Άλλες παράμετροι που επηρεάζουν την απόδοση της πρόβλεψης είναι η περίοδος εκπαίδευσης του μοντέλου και η συχνότητα μετρήσεων και προβλέψεων. Gallagher et al. (2018) διερεύνησε πώς τα χαρακτηριστικά της περιόδου εκπαίδευσης θα μπορούσαν να επηρεάσουν την απόδοση του μοντέλου. Διαπιστώθηκε ότι η χρήση μεγαλύτερης συχνότητας μετρήσεων μείωσε τη διασπορά του σφάλματος στα εξεταζόμενα μοντέλα. Ωστόσο, η περαιτέρω ανάλυση απέδειξε ότι η χρήση πιο λεπτομερών δεδομένων δεν ωφέλησε πάντα την απόδοση του μοντέλου. Στην ανάλυση της Jain et al. (2014) για κτίρια πολυκατοικιών, σε μια κλίμακα συχνότητας από 10 λεπτά έως ημερήσιες μετρήσεις, μια ωριαία κοκκομετρία παρείχε τα καλύτερα αποτελέσματα όσον αφορά την απόδοση πρόβλεψης. Στην εργασία του Agenis-Nevers et al. (2021) εξετάστηκαν επίσης μοντέλα με διαφορετική συχνότητα μετρήσεων (χρησιμοποιούνται μηνιαίες και ημερήσιες τιμές κατανάλωσης), αλλά αυτά εφαρμόστηκαν σε διαφορετικά κτίρια και δεν μπορούν να συγκριθούν. Σε κάθε περίπτωση, κατά την επιλογή των παραμέτρων και της διαμόρφωσης του μοντέλου, είναι σημαντικό να ληφθεί υπόψη ότι σε πραγματικά πρακτικά σενάρια, η ποιότητα των διαθέσιμων συνόλων δεδομένων, η συχνότητα δειγματοληψίας και η ανάλυση τους μπορεί να διαφέρουν.

7.3 Προτεινόμενο Μοντέλο

Σε αυτή την ενότητα παρουσιάζουμε την προτεινόμενη μεθοδολογία για τη μοντελοποίηση της ενέργειας βάσης. Αρχικά, παρουσιάζονται τα επιλεγμένα μοντέλα ML (RF, XGBoost και LightGBM) για την πρόβλεψη της ενέργειας βάσης. Δεύτερον, παρουσιάζεται το συνολικό μεθοδολογικό πλαίσιο, τονίζοντας την ανάγκη για συσσωμάτωση διαφορετικών μοντέλων ML, η οποία μπορεί να οδηγήσει σε καλύτερες προβλέψεις.

7.3.1 Αρχιτεκτονική Μοντέλου

Στον τομέα της πρόβλεψης, είναι ευρέως αποδεκτό ότι κανένα μεμονωμένο μοντέλο δεν μπορεί να ξεπεράσει σταθερά όλα τα διαθέσιμα μοντέλα όσον αφορά την προβλεπτική απόδοση (Petropoulos et al., 2022). Αυτή η αντίληψη ισχύει και για τον τομέα της μοντελοποίησης M&V και της βασικής ενέργειας. Κατά συνέπεια, οι προγνώστες έχουν καταφύγει στο συνδυασμό των προβλέψεων που παράγονται από πολλαπλά μοντέλα, καθένα από τα οποία χρησιμοποιεί διαφορετικές παραδοχές και διαθέτει διαφορετική δομική διαμόρφωση, σε μια προσπάθεια να βελτιώσουν τη συνολική ακρίβεια των προβλέψεων. Η βασική αρχή που διέπει τους συνδυασμούς προβλέψεων έγκειται στην προσδοκία ότι τα σφάλματα που είναι εγγενή σε διαφορετικά μοντέλα θα αντισταθμίσουν το ένα το άλλο, με αποτέλεσμα ακριβέστερες προβλέψεις από εκείνες που παράγονται από μεμονωμένες προσεγγίσεις πρόβλεψης. Έχουν προταθεί πολυάριθμα σχήματα για το συνδυασμό προβλέψεων, τα οποία περιλαμβάνουν τόσο απλουστευτικές μεθόδους όπως ο μέσος όρος (π.χ. μέσος όρος, διάμεσος ή τρόπος) όσο και πιο εξελιγμένες τεχνικές (π.χ. αξιοποίηση των σφαλμάτων πρόβλεψης εντός και εκτός δείγματος, κριτήρια πληροφόρησης, θεωρία πιθανοτήτων του Μπέιζ και μεθοδολογίες γραμμικής ή μη γραμμικής παλινδρόμησης).

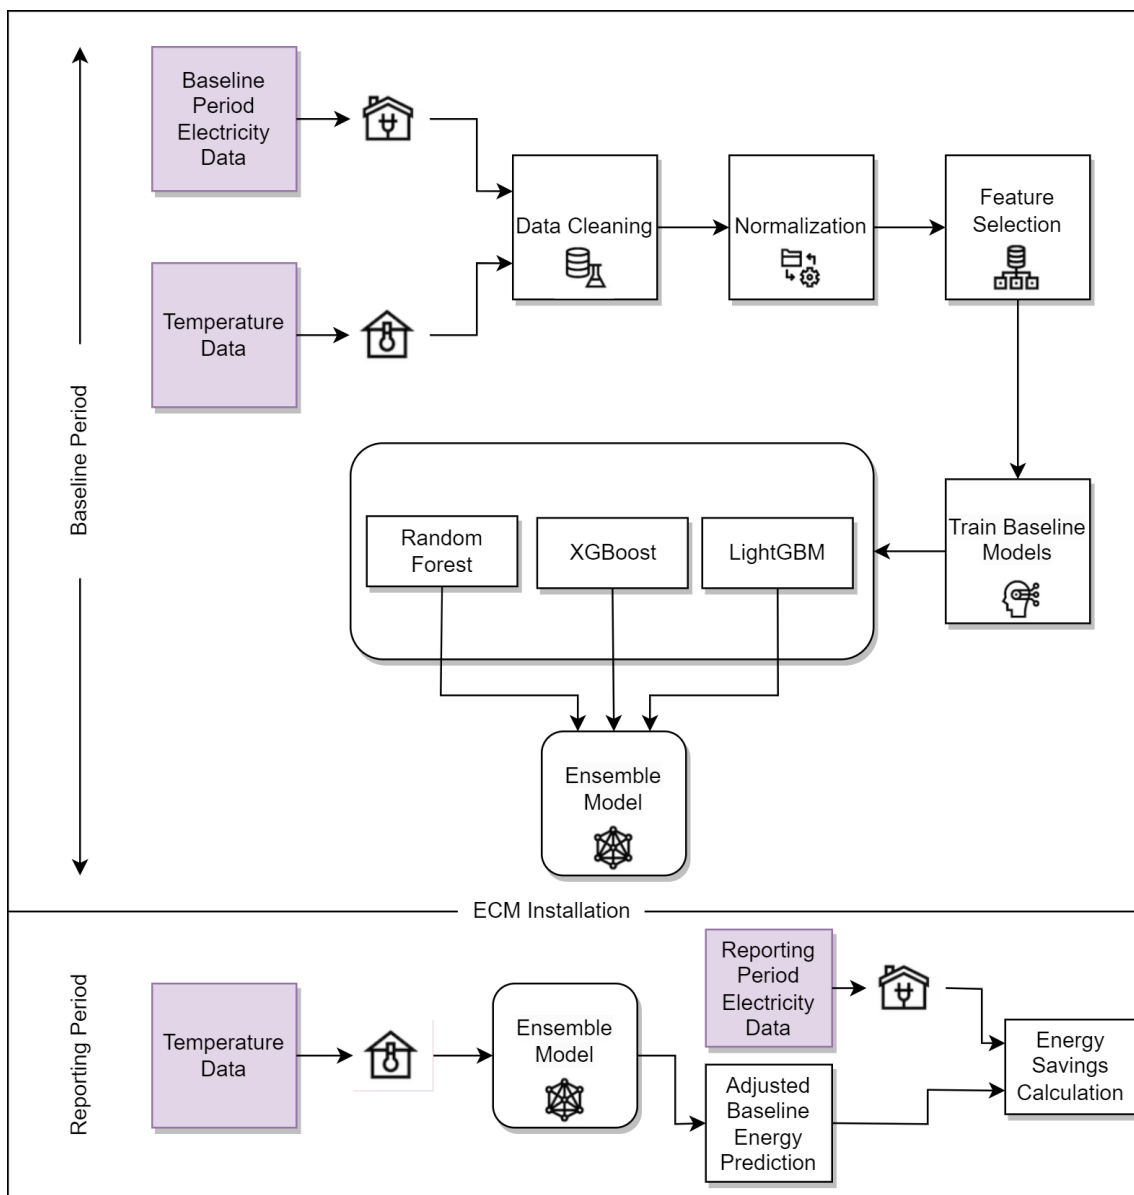
Στο πλαίσιο της έρευνάς μας, η οποία διερευνά την πρόβλεψη της βασικής γραμμής ενέργειας μετά την εφαρμογή των ECMs, έχουμε επινοήσει ένα μοντέλο συνόλου στοίβαξης. Το προτεινόμενο μοντέλο συνόλου αποτελείται από τρία μοντέλα που βασίζονται σε ML, δηλαδή τα RF, XGBoost και LightGBM. Καθένα από αυτά τα μοντέλα διαθέτει διακριτά πλεονεκτήματα και χαρακτηριστικά, αποτυπώνοντας ποικίλες πτυχές των υποκείμενων προτύπων κατανάλωσης ενέργειας. Αξιοποιώντας τη συλλογική προβλεπτική δύναμη αυτών των μοντέλων, ο στόχος μας είναι να βελτιστοποιήσουμε την ακρίβεια των βασικών προβλέψεων ενέργειας. Το μοντέλο συνόλου στοίβαξης λειτουργεί με τη συγχέντρωση των προβλέψεων που παράγονται από τα επιμέρους μοντέλα ML. Ωστόσο, για να βελτιώσουμε περαιτέρω τη διαδικασία συγχώνευσης, εισάγουμε ένα βήμα φιλτραρίσματος που χρησιμοποιεί ένα μοντέλο σύνοψης με βάση το μέσο όρο, όπως φαίνεται στο Σχήμα 7.2. Αυτό το συμπληρωματικό επίπεδο διευκολύνει τη βέλτιστη συγχώνευση των προβλέψεων που προέρχονται από τα βασικά μοντέλα, αξιοποιώντας τα μοναδικά πλεονεκτήματα που παρουσιάζει κάθε μοντέλο. Μέσω αυτής της επαναληπτικής διαδικασίας, το μοντέλο συνόλου στοίβαξης αξιοποιεί τις συμπληρωματικές δυνατότητες των επιμέρους μοντέλων ML, με αποτέλεσμα μια πρόβλεψη συνόλου που χαρακτηρίζεται από βελτιωμένη ακρίβεια και ευρωστία. Η υιοθέτηση αυτής της προσέγγισης του συνόλου στοίβαξης στη μελέτη μας αποτελεί αξιοσημείωτη συμβολή στον τομέα της M&V και της βασικής ενεργειακής μοντελοποίησης. Με την αποτελεσματική ενσωμάτωση της εμπειρογνομosύνης και των γνώσεων που προέρχονται από διαφορετικά μοντέλα ML, το προτεινόμενο μοντέλο στοχεύει στην αντιμετώπιση των περιορισμών που είναι εγγενείς στα μεμονωμένα μοντέλα, βελτιώνοντας έτσι την ακρίβεια της εκτίμησης της εξοικονόμησης ενέργειας.

7.3.2 Baseline Μοντέλα Παλινδρόμησης

Random Forest

Ο αλγόριθμος Random Forest (RF) είναι μια εξαιρετικά δημοφιλής και εκτεταμένα χρησιμοποιούμενη τεχνική στο πεδίο της επιστήμης των δεδομένων (Breiman, 2001). Αποτελεί έναν αλγόριθμο ML με επίβλεψη που βρίσκει εφαρμογές σε πλήθος προβλημάτων ταξινόμησης και παλινδρόμησης. Μέσω της κατασκευής δέντρων απόφασης σε διακριτά δείγματα και της επακόλουθης συγχέντρωσης των προβλέψεών τους μέσω πλειοψηφικής ψηφοφορίας ή μέσου όρου, ο αλγόριθμος RF επιτυγχάνει εξαιρετικά επίπεδα ακρίβειας.

Ένα βασικό πλεονέκτημα του RF έγκειται στην ικανότητά του να αντιμετωπίζει σύνολα δεδομένων που περιλαμβάνουν τόσο συνεχείς όσο και κατηγορικές μεταβλητές. Αυτή η έμφυτη ευελιξία τον καθιστά ιδιαίτερα κατάλληλο για ένα ευρύ φάσμα εργασιών ταξινόμησης και παλινδρόμησης. Στο επερχόμενο σεμινάριο, θα ξεκινήσουμε την εξερεύνηση των περίπλοκων



Σχήμα 7.2: Το προτεινόμενο μεθοδολογικό πλαίσιο για την εκτίμηση της εξοικονόμησης ενέργειας με βάση μοντέλα ML και ensembling.

εσωτερικών λειτουργιών του αλγορίθμου RF, επιδεικνύοντας ταυτόχρονα την εφαρμογή του σε ένα συναρπαστικό πρόβλημα ταξινόμησης.

Στο επίκεντρο του αλγορίθμου RF βρίσκεται η μάθηση συνόλου, μια έννοια καθοριστική για τη λειτουργία του. Η μάθηση συνόλου συνδυάζει πολλαπλά μοντέλα, αποφεύγοντας την εξάρτηση από ένα μοναχικό μοντέλο. Μέσα στα όρια του αλγορίθμου RF, αυτή η τεχνική ensemble υιοθετεί τις αρχές του bagging (Breiman, 1996). Κατά συνέπεια, διαμορφώνει διάφορα υποσύνολα εκπαίδευσης από το αρχικό σύνολο δεδομένων, χρησιμοποιώντας δειγματοληψία με αντικατάσταση. Κάθε ένα από αυτά τα υποσύνολα δημιουργεί την εκπαίδευση ενός ανεξάρτητου μοντέλου δέντρου αποφάσεων, με αποκορύφωμα την τελική πρόβλεψη που πραγματοποιείται μέσω της συνάντρωσης όλων των προβλέψεων του δέντρου αποφάσεων (Prasad et al., 2006).

Το RF παρέχει πολλά πλεονεκτήματα στους επαγγελματίες του. Παρουσιάζει ικανότητες στον αποτελεσματικό χειρισμό μη γραμμικών σχέσεων και θορυβωδών συνόλων δεδομένων (Strobl et al., 2009). Επιπλέον, διαθέτει μειωμένη απαίτηση για προεπεξεργασία δεδομένων, γεγονός που τον διαφοροποιεί από ορισμένους εναλλακτικούς αλγορίθμους. Είναι σημαντικό, ωστόσο, να αναγνωρίσουμε ότι ο RF θυσιάζει την ερμηνευσιμότητα των μεμονωμένων δέν-

τρων προς όφελος της ενισχυμένης ακρίβειας πρόβλεψης, ενώ λόγω της πολυπλοκότητας του αλγορίθμου, είναι επιβεβλημένος ένας πολύ εκτεταμένος συντονισμός των παραμέτρων. Ο αλγόριθμος Random Forest (RF) είναι μια εξαιρετικά δημοφιλής και εκτεταμένα χρησιμοποιούμενη τεχνική στον τομέα της επιστήμης των δεδομένων (Breiman, 2001). Αποτελεί έναν αλγόριθμο ML με επίβλεψη που βρίσκει εφαρμογές σε πλήθος προβλημάτων ταξινόμησης και παλινδρόμησης. Μέσω της κατασκευής δέντρων απόφασης σε διακριτά δείγματα και της επακόλουθης συγκέντρωσης των προβλέψεών τους μέσω πλειοψηφικής ψηφοφορίας ή μέσου όρου, ο αλγόριθμος RF επιτυγχάνει εξαιρετικά επίπεδα ακρίβειας.

XGBoost

Το Gradient boosting (GB) αναδεικνύεται ως ένας ευέλικτος αλγόριθμος μάθησης συνόλου, που καλύπτει τόσο εργασίες παλινδρόμησης όσο και ταξινόμησης (Natekin and Knoll, 2013). Ο θεμελιώδης στόχος του περιστρέφεται γύρω από την κατασκευή ενός μοντέλου "ισχυρού μαθητή" μέσω της επαναληπτικής συγχώνευσης πολλαπλών μοντέλων "αδύναμου μαθητή". Κάθε επόμενο μοντέλο στοχεύει στη διόρθωση των σφαλμάτων πρόβλεψης του προηγούμενου (Schapire, 2003). Ακολουθώντας μια μεθοδολογία παρόμοια με άλλες τεχνικές boosting, η GB χρησιμοποιεί δέντρα αποφάσεων (παλινδρομείς ή ταξινομητές) που εκπαιδεύονται στην αρνητική κλίση της συνάρτησης απώλειας σε κάθε στάδιο. Αυτή η προσέγγιση επιτρέπει στα νεοπροστιθέμενα μοντέλα να αντιμετωπίσουν τις συγκεκριμένες ελλείψεις των προηγούμενων μοντέλων, με αποτέλεσμα τη συνολική βελτίωση της απόδοσης. Μόλις όλα τα μεμονωμένα δέντρα ενσωματωθούν στο σύνολο, το τελικό μοντέλο αναλαμβάνει την πρόβλεψη νέων δειγμάτων.

Το XGBoost, μια βελτιστοποιημένη παραλλαγή του GB, ανήκει στην οικογένεια GB, αλλά διακρίνεται μέσω της ενσωμάτωσης προηγμένων τεχνικών κανονικοποίησης, δηλαδή των $L1$ και $L2$ κανονικοποίησης, αυξάνοντας τις δυνατότητες γενίκευσης των μοντέλων που προκύπτουν. Λειτουργώντας ως αποδοτική υλοποίηση του αλγορίθμου GB, το XGBoost προσφέρει ανώτερες υπολογιστικές επιδόσεις σε σύγκριση με τα παραδοσιακά μοντέλα GB. Επιπλέον, μειώνει τους χρόνους εκπαίδευσης μέσω παραλληλισμού σε συστοιχίες (Chen and Guestrin, 2016). Παρόμοια με το RF, το XGBoost συγκεντρώνει επίσης σύνολα από μοντέλα δέντρων απόφασης. Ωστόσο, η κύρια απόκλιση έγκειται στη διαδοχική προσθήκη δέντρων στο σύνολο, με στόχο την ελαχιστοποίηση των σφαλμάτων πρόβλεψης από προηγούμενα μοντέλα (αυτή η διάκριση αντιπροσωπεύει επίσης τη θεμελιώδη διαφορά μεταξύ bagging και boosting). Ο όρος "gradient boosting" προέρχεται από την υιοθέτηση του αλγορίθμου βελτιστοποίησης gradient descent για την ελαχιστοποίηση των σφαλμάτων.

Το XGBoost διαθέτει αρκετά πλεονεκτήματα που έχουν εδραιώσει τη θέση του ως ένα από τα σημαντικότερα μοντέλα για το GB. Όπως αναφέρθηκε προηγουμένως, χρησιμοποιεί μια προσαρμοσμένη τεχνική κλαδέματος για δέντρα απόφασης, με αποτέλεσμα την επιτάχυνση της εκπαίδευσης και τον βελτιωμένο χειρισμό ογκωδών συνόλων δεδομένων (Wade (2020)). Μεταξύ των βελτιστοποιήσεών του, το XGBoost αξιοποιεί έναν προσεγγιστικό άπληστο αλγόριθμο σταθμισμένων χβαντιλίων κατά τη διάρκεια της διάσπασης των κόμβων, παρακάμπτοντας την αξιολόγηση όλων των πιθανών διασπάσεων. Επιπλέον, διαμερίζει τα δεδομένα σε μικρότερα τμήματα, διευκολύνοντας την παράλληλη επεξεργασία των δειγμάτων, ενώ αξιοποιεί τη μνήμη κρυφής μνήμης για την επιτάχυνση των υπολογισμών (Wen et al., 2019). Αυτά τα χαρακτηριστικά έχουν συμβάλει στην ευρεία υιοθέτησή του σε ποικίλες εφαρμογές ταξινόμησης και παλινδρόμησης κατά την τελευταία δεκαετία.

Ανάλογα με το RF, το XGBoost βασίζεται σε ένα κρίσιμο σύνολο υπερπαραμέτρων για την επίτευξη προβλέψεων υψηλής ακρίβειας. Αυτές οι υπερπαραμέτροι περιλαμβάνουν πτυχές που δεν σχετίζονται μόνο με τη διαδικασία GB, όπως ο αριθμός των δέντρων που χρησιμοποιούνται κατά την εκπαίδευση, αλλά και με τη δομή κάθε μεμονωμένου δέντρου. Στις αξιοσημείωτες παραμέτρους περιλαμβάνονται το βάθος του δέντρου και η ελάχιστη μείωση των απωλειών που είναι απαραίτητη για την περαιτέρω κατάτμηση των κόμβων. Για την παρούσα μελέτη χρησιμοποιήθηκε η αρχική βιβλιοθήκη υλοποίησης XGBoost.

LightGBM

Το LightGBM, που εισήχθη από την [Ke et al. \(2017\)](#), είναι ένα αξιολογούμενο πλαίσιο GB παρόμοιο με το XGBoost. Ενώ και τα δύο βασίζονται στον αλγόριθμο GB και χρησιμοποιούν δέντρα αποφάσεων, το LightGBM δίνει προτεραιότητα στις επιδόσεις, την επεκτασιμότητα και την αποδοτικότητα μνήμης. Αποκλίνει από το XGBoost στην κατασκευή του δέντρου αποφάσεων, χρησιμοποιώντας μια στρατηγική κατά φύλλο που επιλέγει το φύλλο με τη μεγαλύτερη μείωση των απωλειών. Το LightGBM χρησιμοποιεί επίσης έναν αλγόριθμο μάθησης με βάση το ιστόγραμμα για τον προσδιορισμό των βέλτιστων σημείων διαχωρισμού, βελτιώνοντας την αποδοτικότητα και μειώνοντας τις απαιτήσεις μνήμης. Αυτό το πλαίσιο έχει αναπτυχθεί από ερευνητές της Microsoft, είναι ένα πλαίσιο και συνδυάζει δέντρα αποφάσεων διαδοχικά, όπου κάθε νέο δέντρο βελτιώνει το μοντέλο προσαρμόζοντας τα υπολείμματα από το προηγούμενο δέντρο. Το LightGBM έχει επιτύχει αξιολογούμενη ακρίβεια σε διαγωνισμούς ML ([Makridakis et al., 2022](#)).

Το κίνητρο πίσω από το LightGBM προέρχεται από τη διαδικασία κατασκευής δέντρων απόφασης, η οποία περιλαμβάνει διαχωρισμό των παρατηρήσεων με βάση τις τιμές των χαρακτηριστικών για τη μείωση της τυχαιότητας και την αύξηση του κέρδους πληροφορίας. Η εύρεση του καλύτερου διαχωρισμού, που οδηγεί στο μεγαλύτερο κέρδος πληροφορίας, είναι η πιο χρονοβόρα πτυχή της εκμάθησης δέντρων ([Jin et al., 2020](#)). Άλλες υλοποιήσεις gradient boosting χρησιμοποιούν δύο αλγόριθμους για την εύρεση των καλύτερων διαχωρισμών: προ-ταξινομημένους και βασισμένους στο ιστόγραμμα. Ο αλγόριθμος προ-ταξινόμησης περιλαμβάνει την ταξινόμηση των τιμών των χαρακτηριστικών και την αξιολόγηση όλων των πιθανών σημείων διάσπασης, ενώ ο αλγόριθμος με βάση το ιστόγραμμα διακριτοποιεί τα συνεχή χαρακτηριστικά σε bins για τη δημιουργία ιστογραμμάτων χαρακτηριστικών. Ο LightGBM αποσκοπεί στην αντιμετώπιση του ζητήματος της αποδοτικότητας, ιδίως με μεγάλα σύνολα δεδομένων.

Το κίνητρο πίσω από το LightGBM είναι η βελτίωση της αποτελεσματικότητας της δημιουργίας δέντρων αποφάσεων. Η διαδικασία περιλαμβάνει τον διαχωρισμό των παρατηρήσεων με βάση τις τιμές των χαρακτηριστικών για τη μείωση της τυχαιότητας και την αύξηση του κέρδους πληροφορίας. Η εύρεση του καλύτερου διαχωρισμού, ο οποίος μεγιστοποιεί το κέρδος πληροφορίας, είναι χρονοβόρα. Άλλες υλοποιήσεις δέντρων απόφασης με ενίσχυση κλίσης χρησιμοποιούν αλγόριθμους που βασίζονται σε προ-ταξινόμησης ή ιστογράμματα για την εύρεση διαχωρισμών. Το LightGBM αντιμετωπίζει ζητήματα αποδοτικότητας, ειδικά με μεγάλα σύνολα δεδομένων ([Al Daoud, 2019](#)). Για την ενίσχυση της αποδοτικότητας, το LightGBM ενσωματώνει δύο τεχνικές: Gradient One-Side Sampling (GOSS) και Exclusive Feature Bundling (EFB). Η GOSS δίνει προτεραιότητα στις περιπτώσεις με μεγαλύτερες κλίσεις για να επιταχύνει το κέρδος πληροφορίας, ενώ η EFB μειώνει τον αριθμό των χαρακτηριστικών ομαδοποιώντας αμοιβαία αποκλειόμενα χαρακτηριστικά. Αυτές οι τεχνικές καθιστούν το LightGBM αποτελεσματικό για εργασίες κατάταξης, ταξινόμησης και παλινδρόμησης.

7.4 Μελέτη Περίπτωσης


Αυτή η ενότητα παρέχει μια εκτεταμένη πειραματική εφαρμογή της προτεινόμενης μεθοδολογίας σε δεδομένα που προέρχονται από πραγματικά έργα ανακαίνισης. Περιγράφεται λεπτομερώς η διαδικασία εκπαίδευσης των βασικών μεθόδων ταξινόμησης, συμπεριλαμβανομένης της τελειοποίησης των υπερπαραμέτρων τους, και ακολουθεί η αξιολόγηση του μοντέλου μετα-μάθησης. Τέλος, παρουσιάζονται και συζητούνται τα αποτελέσματα της εφαρμογής.

7.4.1 Σύνολο Δεδομένων

Σε αυτό το υποκεφάλαιο, θα παρουσιάσουμε το σύνολο δεδομένων που χρησιμοποιήθηκε για την εφαρμογή της προτεινόμενης μεθοδολογίας σε πειραματικό περιβάλλον. Η αξιολόγηση περιελάμβανε συνολικά 8 πραγματικά κτίρια και θα εμβαθύνουμε στη μετρική ακρίβεια των μοντέλων στο επόμενο υποκεφάλαιο. Για τους σκοπούς αυτής της ενότητας, θα επικεντρωθούμε στην ανάλυση του συνόλου δεδομένων ενός συγκεκριμένου κτιρίου: μιας δημόσιας βιβλιοθήκης που βρίσκεται στην πόλη Gulbene, η οποία βρίσκεται στη βορειοανατολική Λετονία. Είναι σημαντικό να σημειωθεί ότι παρόμοιες ανακαινίσεις έχουν πραγματοποιηθεί και στα υπόλοιπα 7 κτίρια. Οι ανακαινίσεις αυτές περιελάμβαναν μόνωση εξωτερικών τοίχων, μόνωση καπακιών, εκσυγχρονισμό του συστήματος αποχέτευσης, αντικατάσταση θυρών και παραθύρων και αποκατάσταση της μόνωσης των σωληνώσεων του συστήματος θέρμανσης.


Το σύνολο δεδομένων αποτελείται από δεδομένα κατανάλωσης ηλεκτρικής ενέργειας διάρκειας 1,5 έτους, τα οποία συλλέγονται με ωριαία συχνότητα με τη χρήση έξυπνων μετρητών που είναι εγκατεστημένοι στο κτίριο. Επιπλέον, λήφθηκαν ωριαία μετεωρολογικά δεδομένα από μετεωρολογικό σταθμό στην Aluksne, η οποία είναι μια κοντινή πόλη στην Gulbene. Για να διασφαλιστεί η ποιότητα και η αξιοπιστία του συνόλου δεδομένων, πραγματοποιήθηκε ένα στάδιο προεπεξεργασίας. Αυτό περιελάμβανε την αφαίρεση των ακραίων τιμών και την αντιμετώπιση των δεδομένων που λείπουν. Στην περίπτωση ελλιπών δεδομένων, εφαρμόσαμε γραμμική παρεμβολή, αντικαθιστώντας τις ελλιπείς τιμές με παρεμβαλλόμενες τιμές με βάση δεδομένα από την ίδια ώρα της προηγούμενης και της επόμενης ημέρας.

Το σύνολο δεδομένων παρέχει μια σταθερή βάση για την ανάλυση των προτύπων κατανάλωσης ενέργειας και την εξέταση της συσχέτισής τους με τις διακυμάνσεις της θερμοκρασίας. Το Σχήμα 7.3 παρέχει μια οπτική αναπαράσταση της χρονικής διακύμανσης της θερμοκρασίας και της κατανάλωσης ηλεκτρικής ενέργειας. Στο επάνω μέρος του σχήματος παρουσιάζονται οι τιμές της θερμοκρασίας, ενώ στο κάτω μέρος η κατανάλωση ηλεκτρικής ενέργειας. Αυτό το διάγραμμα μας επιτρέπει να διακρίνουμε τυχόν αξιοσημείωτα μοτίβα, τάσεις ή συσχετίσεις που μπορεί να υπάρχουν μεταξύ αυτών των δύο μεταβλητών.



Σχήμα 7.3: Χρονοσειρές της θερμοκρασίας (μπλε χρώμα) και της κατανάλωσης ηλεκτρικής ενέργειας (πράσινο χρώμα) με την πάροδο του χρόνου.

Το σχήμα 7.4 απεικονίζει τη συνδυασμένη κατανομή της θερμοκρασίας και της κατανάλωσης ηλεκτρικής ενέργειας σε ένα ενιαίο διάγραμμα. Η συχνότητα των τιμών θερμοκρασίας απεικονίζεται στον αριστερό άξονα y, ενώ η συχνότητα των τιμών κατανάλωσης ηλεκτρικής ενέργειας στον δεξιό άξονα y. Ο άξονας x εμφανίζει τα αντίστοιχα εύρη της θερμοκρασίας και της ηλεκτρικής ενέργειας. Αυτή η απεικόνιση ιστογράμματος μας επιτρέπει να εξετάσουμε την κατανομή των δεδομένων και να εντοπίσουμε τυχόν εξέχουσες κορυφές ή μοτίβα.




Σχήμα 7.4: Ιστόγραμμα θερμοκρασίας και ηλεκτρικής ενέργειας που παρουσιάζει την κατανομή των χρονοσειρών θερμοκρασίας και ηλεκτρικής ενέργειας για ένα συγκεκριμένο κτίριο.”

Το σχήμα 7.5 απεικονίζει τη συσχέτιση μεταξύ της θερμοκρασίας και της κατανάλωσης ηλεκτρικής ενέργειας μέσω ενός κοινού διαγράμματος. Αυτό το διάγραμμα συνδυάζει ένα διάγραμμα διασποράς και ένα ιστογράμμα για να προσφέρει μια ολοκληρωμένη εικόνα της κοινής κατανομής αυτών των μεταβλητών. Τα εξαγωνικά bins απεικονίζουν την πυκνότητα των σημείων δεδομένων, με το χρώμα να υποδεικνύει το επίπεδο πυκνότητας. Με την εξέταση αυτού του διαγράμματος, μπορούμε να αποκτήσουμε γνώσεις σχετικά με τις πιθανές συσχετίσεις ή σχέσεις μεταξύ της θερμοκρασίας και της κατανάλωσης ηλεκτρικής ενέργειας.

Τέλος, είναι εμφανές ότι η χρονοσειρά κατανάλωσης ηλεκτρικής ενέργειας παρουσιάζει σημαντική αυτοσυσχέτιση. Η παρατήρηση αυτή υποστηρίζεται από το Σχήμα 7.6, το οποίο παρουσιάζει την εποχική αποσύνθεση των δεδομένων της χρονοσειράς ηλεκτρικής ενέργειας. Η αποσύνθεση αποκαλύπτει διακριτές συνιστώσες της κατανάλωσης ηλεκτρικής ενέργειας: τάση, εποχικότητα και κατάλοιπα. Το ανώτερο υποδιάγραμμα αντιπροσωπεύει τις παρατηρούμενες τιμές ηλεκτρικής ενέργειας, ενώ το δεύτερο υποδιάγραμμα απεικονίζει τη συνιστώσα της τάσης. Τα κατώτερα υποδιαγράμματα απεικονίζουν τις συνιστώσες της εποχικότητας και των υπολειμμάτων. Αυτή η αποσύνθεση ενισχύει την κατανόηση των εγγενών μοτίβων και διακυμάνσεων στα δεδομένα κατανάλωσης ηλεκτρικής ενέργειας, επιβεβαιώνοντας την παρουσία έντονης ημερήσιας και εβδομαδιαίας αυτοσυσχέτισης.

7.4.2 Πειραματικός Σχεδιασμός

Σε αυτό το υποκεφάλαιο, περιγράφουμε τη διαδικασία εκπαίδευσης του μοντέλου πρόβλεψης της κατανάλωσης ηλεκτρικής ενέργειας και παρέχουμε μια επισκόπηση των χαρακτηριστικών του. Το σύνολο δεδομένων που χρησιμοποιείται για σκοπούς εκπαίδευσης και δοκιμής



Σχήμα 7.5: Το κοινό διάγραμμα της θερμοκρασίας και της ηλεκτρικής ενέργειας αναδεικνύει τη συσχέτιση μεταξύ των δύο χρονοσειρών.


αποτελείται από δεδομένα κατανάλωσης ηλεκτρικής ενέργειας διάρκειας 1,5 έτους, με ένα έτος να διατίθεται για την εκπαίδευση του μοντέλου και τα υπόλοιπα δεδομένα να προορίζονται για δοκιμή.

Το μοντέλο πρόβλεψης της κατανάλωσης ηλεκτρικής ενέργειας έχει σχεδιαστεί για να παρέχει ωριαίες προβλέψεις για την κατανάλωση ενέργειας του επιλεγμένου κτιρίου-στόχου. Η επιλογή για ωριαία δεδομένα εξόδου έγινε για να διασφαλιστούν ευθυγραμμισμένες σημειακές προβλέψεις για την προσαρμοσμένη ενέργεια αναφοράς και τη μετρούμενη ενέργεια της περιόδου αναφοράς, αξιοποιώντας τις αξιόπιστες ωριαίες μετρήσεις που παρέχουν οι έξυπνοι μετρητές. Το μοντέλο ενσωματώνει καιρικά και εποχιακά χαρακτηριστικά, συγκεκριμένα περιλαμβάνει την εξωτερική θερμοκρασία του αέρα, την ώρα της ημέρας, την ημέρα της εβδομάδας, την καθημερινή ημέρα ή το Σαββατοκύριακο (δυναμική μεταβλητή), τον μήνα του έτους και τον δείκτη περιόδου διακοπών (δυναμική μεταβλητή). Η εξέταση των περιόδων διακοπών είναι ιδιαίτερα σημαντική για τα κτίρια γραφείων, καθώς τείνουν να έχουν χαμηλότερη κατανάλωση ενέργειας κατά τη διάρκεια αυτών των περιόδων. Για την παρούσα μελέτη, ο Αύγουστος και τα Χριστούγεννα θεωρήθηκαν ως οι μοναδικές περίοδοι διακοπών.

Τα μοντέλα πρόβλεψης που αναπτύχθηκαν αξιολογούνται χρησιμοποιώντας τρεις μετρικές σφάλματος: το μέσο απόλυτο σφάλμα (MAE), τον συντελεστή διακύμανσης του μέσου τετραγωνικού σφάλματος (CVRMSE) και το κανονικοποιημένο μέσο σφάλμα μεροληψίας (NMBE). Το MAE μετρά τις μεμονωμένες διαφορές μεταξύ των πραγματικών και των προβλεπόμενων τιμών και υπολογίζεται ως εξής:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Το CVRMSE, που συνιστάται από την ASHRAE 14 (Ashrae, 2020), είναι μια κανονικοποιημένη έκδοση του δείκτη μέσου τετραγωνικού σφάλματος (RMSE). Υπολογίζεται ως το RMSE διαιρεμένο με τη μέση τιμή κατανάλωσης και δίνεται από την ακόλουθη εξίσωση:



Σχήμα 7.6: Αποσύνθεση της χρονοσειράς κατανάλωσης ηλεκτρικής ενέργειας.

$$\text{CVRMSE} = \frac{1}{\bar{y}} \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}$$

Το κανονικοποιημένο μέσο σφάλμα μεροληψίας (NMBE) μετρά τη μέση μεροληψία μεταξύ των πραγματικών και των προβλεπόμενων τιμών, κανονικοποιημένη με τη μέση τιμή κατανάλωσης. Υπολογίζεται ως εξής:

$$\text{NMBE} = \frac{1}{\bar{y}} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right)$$

Αυτές οι μετρικές σφάλματος παρέχουν πολύτιμες πληροφορίες σχετικά με την ακρίβεια και την απόδοση των μοντέλων πρόβλεψης, επιτρέποντάς μας να αξιολογήσουμε την ποιότητα των προβλέψεων και να συγκρίνουμε διαφορετικές προσεγγίσεις.

Τέλος, η τελειοποίηση των μοντέλων ML είναι ένα απαραίτητο βήμα για την επίτευξη βέλτιστης απόδοσης. Σε αυτή την ενότητα, εμβαθύνουμε στη διαδικασία τελειοποίησης και συζητάμε τις συγκεκριμένες υπερπαραμέτρους που επιλέχθηκαν για τα RF, XGBoost και LightGBM.

Για το RF, ο αριθμός των εκτιμητών ορίστηκε σε 200 για να επιτευχθεί μια ισορροπία μεταξύ της πολυπλοκότητας του μοντέλου και των υπολογιστικών πόρων. Το μέγιστο βάθος των 10 επιλέχθηκε σχολαστικά για να καταγραφούν περίπλοκες συναρτήσεις χωρίς να υποκύψουμε σε υπερπροσαρμογή. Για την προώθηση της ενισχυμένης γενίκευσης, η υπερπαραμέτρος μέγιστων χαρακτηριστικών διαμορφώθηκε ως "sqrt", λαμβάνοντας υπόψη την τετραγωνική ρίζα του συνολικού αριθμού των χαρακτηριστικών. Αυτή η προσέγγιση επιτρέπει στο μοντέλο να αποφεύγει την αδικαιολόγητη εξάρτηση από οποιοδήποτε μεμονωμένο χαρακτηριστικό. Ενεργοποιήθηκε το bootstrapping με τη ρύθμιση της υπερπαραμέτρου bootstrap σε True, εισάγοντας ποικιλομορφία στα δεδομένα εκπαίδευσης και βελτιώνοντας την ευρωστία του μοντέλου.

Στην περίπτωση του XGBoost, χρησιμοποιήθηκαν 500 εκτιμητές για να δοθούν στο μοντέλο μεγαλύτερες ευκαιρίες εκμάθησης σύνθετων μοτίβων. Επιλέχθηκε μέγιστο βάθος 6

για να επιτευχθεί ισορροπία μεταξύ της καταγραφής πολύπλοκων σχέσεων και της αποφυγής της υπερβολικής προσαρμογής. Ο ρυθμός μάθησης ορίστηκε στο 0,1 για να διευκολυνθούν οι σχολαστικές ενημερώσεις των βαρών, οδηγώντας σε καλύτερη σύγκλιση και βελτιωμένη γενίκευση.

Για το LightGBM, χρησιμοποιήθηκαν 300 εκτιμητές για να μπορέσει το μοντέλο να μάθει περίπλοκα μοτίβα, αν και με μεγαλύτερους χρόνους εκπαίδευσης. Επιλέχθηκε μέγιστο βάθος 8 για να αποφευχθεί η υπερπροσαρμογή, ευθυγραμμιζόμενο με τις βέλτιστες πρακτικές για το RF και το XGBoost. Ο αριθμός των φύλλων ορίστηκε σε 64, που αντιστοιχεί σε $2^{\text{Μέγιστο βάθος}}$, επιτυγχάνοντας μια ισορροπία μεταξύ της πολυπλοκότητας του μοντέλου και της υπερπροσαρμογής. Επιλέχθηκε ένας ρυθμός μάθησης 0,05 για να διευκολυνθεί η προσεκτική ενημέρωση των βαρών, προωθώντας την καλύτερη σύγκλιση και μειώνοντας τον κίνδυνο αποκλίνουσας συμπεριφοράς.

7.4.3 Αποτελέσματα

Η αξιολόγηση των επιδόσεων περιελάμβανε την αξιολόγηση πέντε διαφορετικών μοντέλων για την πρόβλεψη της κατανάλωσης ηλεκτρικής ενέργειας σε οκτώ κτίρια που βρίσκονται στη Λετονία. Τα μοντέλα αυτά περιλάμβαναν ένα τεχνητό νευρωνικό δίκτυο (ANN) βασισμένο στη βαθιά μάθηση, καθώς και τα RF, XGBoost, LightGBM και ένα μοντέλο συνόλου που συνδυάζει όλα τα μεμονωμένα μοντέλα που βασίζονται σε δέντρα.

Τα πειραματικά αποτελέσματα παρουσιάζονται στον πίνακα 7.2. Αξίζει να σημειωθεί ότι το μοντέλο συνόλου υπερτερεί σταθερά έναντι των RF, XGBoost και LightGBM σε όλα τα κτίρια. Αυτό το συνολικό μοντέλο παρουσίασε ανώτερη προβλεπτική απόδοση, όπως υποδεικνύεται από τις σταθερά χαμηλότερες τιμές CV(RMSE). Τα ευρήματα αυτά υπογραμμίζουν την αποτελεσματικότητα του συνδυασμού πολλαπλών μοντέλων για τη βελτίωση της ακρίβειας της πρόβλεψης της κατανάλωσης ηλεκτρικής ενέργειας.

Αξίζει να σημειωθεί ότι η απόδοση του μοντέλου βαθιάς μάθησης παρουσίασε μεταβλητότητα ανάλογα με τα μεμονωμένα κτίρια που εξετάστηκαν. Ενώ το ANN επέδειξε ανώτερες επιδόσεις σε σύγκριση με τα RF, XGBoost και LightGBM σε ορισμένες περιπτώσεις, τα αποτελέσματά του ήταν παρόμοια ή ελαφρώς κατώτερα σε άλλες περιπτώσεις. Η παρατήρηση αυτή υποδεικνύει ότι η αποτελεσματικότητα των αρχιτεκτονικών βαθιάς μάθησης, όπως η ANN, για την πρόβλεψη της κατανάλωσης ηλεκτρικής ενέργειας μπορεί να επηρεάζεται από τα ξεχωριστά χαρακτηριστικά του κτιρίου και του συνόλου δεδομένων που αναλύονται.

Τα ευρήματα αυτά αναδεικνύουν τους περιορισμούς της στήριξης αποκλειστικά στη βαθιά μάθηση για την πρόβλεψη της κατανάλωσης ηλεκτρικής ενέργειας. Είναι προφανές ότι μια πιο αποτελεσματική προσέγγιση περιλαμβάνει τη χρήση μοντέλων συνόλου που ενσωματώνουν μεθόδους μη βαθιάς μάθησης. Συνδυάζοντας διαφορετικά μοντέλα, τα σύνολα προσφέρουν μια στιβαρή και αξιόπιστη λύση για ακριβή πρόβλεψη. Αυτό υπογραμμίζει τη σημασία της εξέτασης ενός ποικίλου φάσματος μοντέλων και της προσαρμογής της διαμόρφωσης του συνόλου ώστε να ταιριάζει σε συγκεκριμένα σενάρια κτιρίων.

Παρόλο που τα μοντέλα βαθιάς μάθησης, όπως το ANN, έχουν δείξει υποσχέσεις σε ορισμένες περιπτώσεις, το μοντέλο του συνόλου υπερτερεί σταθερά έναντι τόσο της βαθιάς μάθησης όσο και άλλων μεμονωμένων μοντέλων. Αυτό υπογραμμίζει τη σημαντική αξία των συνόλων για την επίτευξη ακριβών και αποτελεσματικών προβλέψεων κατανάλωσης ενέργειας. Τα αποτελέσματα της παρούσας μελέτης παρέχουν πολύτιμες πληροφορίες σχετικά με την επιλογή και τη διαμόρφωση μοντέλων για την πρόβλεψη της κατανάλωσης ηλεκτρικής ενέργειας, συμβάλλοντας έτσι στη βελτίωση των στρατηγικών διαχείρισης της ενέργειας και στην αύξηση της ενεργειακής απόδοσης των κτιρίων.

7.5 Συμπεράσματα

Η εκτίμηση της εξοικονόμησης ενέργειας από δράσεις αναβάθμισης στον κτιριακό τομέα είναι πολύ σημαντική για διάφορους λόγους. Επίσης, η αξιοποίηση των μοντέλων ML επιτρέπει

Πίνακας 7.2: Σύγκριση μετρικών για κάθε κτίριο με τη χρήση διαφορετικών μοντέλων πρόβλεψης.

Building	Error Metric	ML Models				
		ANN	RF	XGBoost	LightGBM	Ensemble
Building 1	CV(RMSE)	0.10	0.12	0.13	0.11	0.10
	NMBE	-0.02	-0.01	-0.03	-0.02	-0.01
	MAE	5.25	5.28	5.23	5.27	5.23
Building 2	CV(RMSE)	0.11	0.12	0.11	0.10	0.10
	NMBE	-0.01	-0.02	-0.01	0.00	0.00
	MAE	4.92	4.95	4.88	4.91	4.91
Building 3	CV(RMSE)	0.09	0.11	0.12	0.10	0.09
	NMBE	-0.01	-0.03	-0.02	-0.01	-0.01
	MAE	6.03	6.08	5.97	6.02	6.02
Building 4	CV(RMSE)	0.14	0.15	0.16	0.14	0.13
	NMBE	0.01	0.02	0.03	0.01	0.00
	MAE	5.70	5.73	5.65	5.69	5.70
Building 5	CV(RMSE)	0.12	0.13	0.14	0.12	0.12
	NMBE	-0.02	-0.01	-0.03	-0.02	-0.02
	MAE	6.18	6.22	6.15	6.19	6.19
Building 6	CV(RMSE)	0.13	0.15	0.15	0.14	0.12
	NMBE	-0.02	-0.01	-0.03	-0.02	-0.01
	MAE	5.42	5.45	5.38	5.41	5.39
Building 7	CV(RMSE)	0.10	0.12	0.11	0.09	0.09
	NMBE	0.00	0.01	-0.01	0.00	0.00
	MAE	4.97	5.00	4.96	4.95	4.95
Building 8	CV(RMSE)	0.08	0.10	0.11	0.09	0.08
	NMBE	-0.01	-0.02	-0.03	-0.02	-0.01
	MAE	5.88	5.92	5.84	5.89	5.85

τη βελτιστοποίηση της κατανάλωσης ενέργειας και τη βελτίωση της συνολικής ενεργειακής απόδοσης των κτιρίων, οδηγώντας σε οικονομικά και περιβαλλοντικά οφέλη. Η παρούσα εργασία αποδεικνύει ότι η απόδοση ενός μοντέλου συνόλου είναι ανώτερη από οποιοδήποτε νέο μεμονωμένο μοντέλο που βασίζεται σε δέντρα. Η προσέγγιση ensemble συνδυάζει πολλαπλά μοντέλα για να επιτύχει αυξημένη ακρίβεια και ευρωστία στην εκτίμηση της εξοικονόμησης ενέργειας. Αυτό υπογραμμίζει τη σημασία της αξιοποίησης τεχνικών συνόλου για την αξιοποίηση της προβλεπτικής δύναμης διαφορετικών αλγορίθμων και τη βελτίωση της συνολικής απόδοσης. Η επιτυχία του μοντέλου συνόλου μπορεί να αποδοθεί στη συμπληρωματική φύση των μοντέλων που το απαρτίζουν, η οποία μετριάζει τις επιμέρους αδυναμίες και ενισχύει τη συνολική προβλεπτική ικανότητα. Με την ενσωμάτωση των διαφορετικών προοπτικών και στρατηγικών μάθησης των XGBoost, RF και LightGBM, το μοντέλο συνόλου συλλαμβάνει αποτελεσματικά πολύπλοκα πρότυπα και σχέσεις εντός των ενεργειακών δεδομένων, με αποτέλεσμα ακριβέστερες εκτιμήσεις.

Για να προχωρήσουμε μπροστά, η πρόοδος στον τομέα της εκτίμησης της εξοικονόμησης ενέργειας στα κτίρια απαιτεί διάφορα κρίσιμα βήματα. Πρώτα απ' όλα, η τυποποίηση των πρωτοκόλλων συλλογής δεδομένων είναι επιτακτική ανάγκη για να εξασφαλιστεί η συνοχή και η συγκρισιμότητα μεταξύ των μελετών. Αυτό περιλαμβάνει την εναρμόνιση των μορφοτύπων δεδομένων, τον ορισμό κοινών μεταβλητών και την καθιέρωση τυποποιημένων διαδικασιών M&V. Η τυποποίηση διευκολύνει την ανταλλαγή δεδομένων, τις συνεργατικές μεθοδολογίες και την αναπαραγωγή και επικύρωση των αποτελεσμάτων μεταξύ ερευνητών και επαγγελ-

ματιών.

Τέλος, είναι απαραίτητη η επίτευξη συναίνεσης σχετικά με τις μετρικές σφάλματος για την αξιολόγηση των μοντέλων εκτίμησης της εξοικονόμησης ενέργειας. Ενώ η παρούσα μελέτη εξέτασε διάφορες μετρικές σφάλματος, όπως το CV(RMSE), το NMBE και το MAE, είναι ζωτικής σημασίας να καθιερωθεί ένα τυποποιημένο σύνολο μετρικών ειδικά προσαρμοσμένο στην εκτίμηση της εξοικονόμησης ενέργειας. Αυτό επιτρέπει ουσιαστικές συγκρίσεις, συγκριτική αξιολόγηση και παρέχει ένα κοινό πλαίσιο για την αξιολόγηση της ακρίβειας των μοντέλων, προωθώντας την ανάπτυξη βέλτιστων πρακτικών στον τομέα.

Βιβλιογραφία

- Agenis-Nevers, M., Wang, Y., Dugachard, M., Salvazet, R., Becker, G., and Chenu, D. (2021). Measurement and verification for multiple buildings: An innovative baseline model selection framework applied to real energy performance contracts. *Energy and Buildings*, 249:111183.
- Agrawal, R., De Tommasi, L., Lyons, P., Zanoni, S., Papagiannis, G., Karakosta, C., Papapostolou, A., Durand, A., Martinez, L., Fragidis, G., et al. (2023). Challenges and opportunities for improving energy efficiency in smes: learnings from seven european projects. *Energy Efficiency*, 16(3):17.
- Al Daoud, E. (2019). Comparison between xgboost, lightgbm and catboost using a home credit dataset. *International Journal of Computer and Information Engineering*, 13(1):6–10.
- Balaras, C. A., Dascalaki, E. G., Droutsas, K. G., and Kontoyiannidis, S. (2016). Empirical assessment of calculated and actual heating energy use in hellenic residential buildings. *Applied Energy*, 164:115–132.
- Bertoldi, P., Economidou, M., Palermo, V., Boza-Kiss, B., and Todeschi, V. (2021). How to finance energy renovation of residential buildings: Review of current and emerging financing instruments in the eu. *Wiley Interdisciplinary Reviews: Energy and Environment*, 10(1):e384.
- Breiman, L. (1996). Bagging predictors. *Machine learning*, 24(2):123–140.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1):5–32.
- Catalina, T., Iordache, V., and Caracaleanu, B. (2013). Multiple regression model for fast prediction of the heating energy demand. *Energy and buildings*, 57:302–312.
- Chen, T. and Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '16, pages 785–794, New York, NY, USA. ACM.
- Díaz, J. A., Ramos, J. S., Delgado, M. C. G., García, D. H., Montoya, F. G., and Domínguez, S. Á. (2018). A daily baseline model based on transfer functions for the verification of energy saving. a case study of the administration room at the palacio de la madraza, granada. *Applied Energy*, 224:538–549.
- Edwards, R. E., New, J., and Parker, L. E. (2012). Predicting future hourly residential electrical consumption: A machine learning case study. *Energy and Buildings*, 49:591–603.
- Ekici, B. B. and Aksoy, U. T. (2009). Prediction of building energy consumption by using artificial neural networks. *Advances in Engineering Software*, 40(5):356–362.
- Gallagher, C. V., Bruton, K., Leahy, K., and O’Sullivan, D. T. (2018). The suitability of machine learning to minimise uncertainty in the measurement and verification of energy savings. *Energy and Buildings*, 158:647–655.
- Granderson, J., Touzani, S., Custodio, C., Sohn, M. D., Jump, D., and Fernandes, S. (2016). Accuracy of automated measurement and verification (m&v) techniques for energy savings in commercial buildings. *Applied Energy*, 173:296–308.
- Granell, C., Kamilaris, A., Kotsev, A., Ostermann, F. O., and Trilles, S. (2020). Internet of things. *Manual of digital earth*, pages 387–423.

- Grillone, B., Mor, G., Danov, S., Cipriano, J., and Sumper, A. (2021). A data-driven methodology for enhanced measurement and verification of energy efficiency savings in commercial buildings. *Applied Energy*, 301:117502.
- Haberl, J. S. and Thamilsaran, S. (1996). Great energy predictor shootout ii: Measuring retrofit savings—overview and discussion of results.
- IEA, I. (2020a). Energy technology perspectives 2020. *International Energy Agency*.
- IEA, U. (2020b). 2020 global status report for buildings and construction: Tech. rep.
- Jain, R. K., Smith, K. M., Culligan, P. J., and Taylor, J. E. (2014). Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy. *Applied Energy*, 123:168–178.
- Jin, D., Lu, Y., Qin, J., Cheng, Z., and Mao, Z. (2020). Swiftids: Real-time intrusion detection system based on lightgbm and parallel intrusion detection mechanism. *Computers & Security*, 97:101984.
- Kapp, S., Choi, J.-K., and Hong, T. (2023). Predicting industrial building energy consumption with statistical and machine-learning models informed by physical system parameters. *Renewable and Sustainable Energy Reviews*, 172:113045.
- Karatasou, S., Santamouris, M., and Geros, V. (2006). Modeling and predicting building’s energy use with artificial neural networks: Methods and results. *Energy and buildings*, 38(8):949–958.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., and Liu, T.-Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. *Advances in neural information processing systems*, 30.
- Kissock, J. K. and Eger, C. (2008). Measuring industrial energy savings. *Applied Energy*, 85(5):347–361.
- Li, K., Wei, B., Tang, Q., and Liu, Y. (2022). A data-efficient building electricity load forecasting method based on maximum mean discrepancy and improved tradaboost algorithm. *Energies*, 15(23):8780.
- Li, Q., Meng, Q., Cai, J., Yoshino, H., and Mochida, A. (2009). Predicting hourly cooling load in the building: A comparison of support vector machine and different artificial neural networks. *Energy Conversion and Management*, 50(1):90–96.
- Lundström, L. and Wallin, F. (2016). Heat demand profiles of energy conservation measures in buildings and their impact on a district heating system. *Applied energy*, 161:290–299.
- Makridakis, S., Spiliotis, E., and Assimakopoulos, V. (2022). M5 accuracy competition: Results, findings, and conclusions. *International Journal of Forecasting*.
- Mustapa, R. F., Dahlan, N. Y., Yassin, A. I. M., and Nordin, A. H. M. (2020). Quantification of energy savings from an awareness program using narx-ann in an educational building. *Energy and Buildings*, 215:109899.
- Natekin, A. and Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in neurorobotics*, 7:21.

- Neto, A. H. and Fiorelli, F. A. S. (2008). Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption. *Energy and buildings*, 40(12):2169–2176.
- Oses, N., Legarretaetxebarria, A., Quartulli, M., García, I., and Serrano, M. (2016). Uncertainty reduction in measuring and verification of energy savings by statistical learning in manufacturing environments. *International Journal on Interactive Design and Manufacturing (IJIDeM)*, 10:291–299.
- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Ben Taieb, S., Bergmeir, C., Bessa, R. J., Bijak, J., Boylan, J. E., Browell, J., Carnevale, C., Castle, J. L., Cirillo, P., Clements, M. P., Cordeiro, C., Cyrino Oliveira, F. L., De Baets, S., Dokumentov, A., Ellison, J., Fiszeder, P., Franses, P. H., Frazier, D. T., Gilliland, M., Gönül, M. S., Goodwin, P., Grossi, L., Grushka-Cockayne, Y., Guidolin, M., Guidolin, M., Gunter, U., Guo, X., Guseo, R., Harvey, N., Hendry, D. F., Hollyman, R., Januschowski, T., Jeon, J., Jose, V. R. R., Kang, Y., Koehler, A. B., Kolassa, S., Kourentzes, N., Leva, S., Li, F., Litsiou, K., Makridakis, S., Martin, G. M., Martinez, A. B., Meeran, S., Modis, T., Nikolopoulos, K., Önköl, D., Paccagnini, A., Panagiotelis, A., Panapakidis, I., Pavía, J. M., Pedio, M., Pedregal, D. J., Pinson, P., Ramos, P., Rappach, D. E., Reade, J. J., Rostami-Tabar, B., Rubaszek, M., Sermpinis, G., Shang, H. L., Spiliotis, E., Syntetos, A. A., Talagala, P. D., Talagala, T. S., Tashman, L., Thomakos, D., Thorarindottir, T., Todini, E., Trapero Arenas, J. R., Wang, X., Winkler, R. L., Yusupova, A., and Ziel, F. (2022). Forecasting: theory and practice. *International Journal of Forecasting*, 38(3):705–871.
- Prasad, A. M., Iverson, L. R., and Liaw, A. (2006). Newer classification and regression tree techniques: bagging and random forests for ecological prediction. *Ecosystems*, 9(2):181–199.
- Price, P. (2010). Methods for analyzing electric load shape and its variability. Technical report, Lawrence Berkeley National Lab.(LBNL), Berkeley, CA (United States).
- Rossi, F. and Velázquez, D. (2015). A methodology for energy savings verification in industry with application for a chp (combined heat and power) plant. *Energy*, 89:528–544.
- Schapire, R. E. (2003). The boosting approach to machine learning: An overview. *Non-linear estimation and classification*, pages 149–171.
- Strobl, C., Malley, J., and Tutz, G. (2009). An introduction to recursive partitioning: rationale, application, and characteristics of classification and regression trees, bagging, and random forests. *Psychological methods*, 14(4):323.
- Touzani, S., Granderson, J., and Fernandes, S. (2018). Gradient boosting machine for modeling the energy consumption of commercial buildings. *Energy and Buildings*, 158:1533–1543.
- Tsiatsis, V., Karnouskos, S., Holler, J., Boyle, D., and Mulligan, C. (2018). *Internet of Things: technologies and applications for a new age of intelligence*. Academic Press.
- Ürge-Vorsatz, D., Danny Harvey, L., Mirasgedis, S., and Levine, M. D. (2007). Mitigating co2 emissions from energy use in the world’s buildings. *Building Research & Information*, 35(4):379–398.
- Wade, C. (2020). *Hands-On Gradient Boosting with XGBoost and scikit-learn: Perform accessible machine learning and extreme gradient boosting with Python*. Packt Publishing Ltd.

- Wen, Z., Shi, J., He, B., Chen, J., Ramamohanarao, K., and Li, Q. (2019). Exploiting gpus for efficient gradient boosting decision tree training. *IEEE Transactions on Parallel and Distributed Systems*, 30(12):2706–2717.
- Wong, S. L., Wan, K. K., and Lam, T. N. (2010). Artificial neural networks for energy analysis of office buildings with daylighting. *Applied Energy*, 87(2):551–557.
- Ye, K., Demirezen, G., Fung, A., and Janssen, E. (2020). The use of artificial neural networks (ann) in the prediction of energy consumption of air-source heat pump in retrofit residential housing. In *IOP Conference Series: Earth and Environmental Science*, volume 463, page 012165. IOP Publishing.

Κεφάλαιο 8

Μοντέλο Μετα-μάθησης για την Αξιολόγηση Επενδύσεων Ενεργειακής Αποδοτικότητας

8.1 Εισαγωγή

Το κεφάλαιο αυτό εστιάζει στο πρόβλημα της αξιολόγησης της δυναμικής επενδύσεων ενεργειακής αποδοτικότητας (*Energy Efficiency - EE*) όσον αφορά το κόστος της ανακαίνισης και την εξοικονόμηση ενέργειας που αποφέρει. Δεδομένης της έλλειψης ώριμων πληροφοριακών συστημάτων για την υποστήριξη τέτοιων αποφάσεων, αρκετά έργα ανακαίνισης αποτυγχάνουν σήμερα να λάβουν οικονομική στήριξη από τα χρηματοδοτικά ιδρύματα, θέτοντας έτσι σε κίνδυνο τους παγκόσμιους περιβαλλοντικούς στόχους που έχουν τεθεί για τις επόμενες δεκαετίες. Στο πλαίσιο αυτό, προτείνεται μια μεθοδολογία η οποία φιλοδοξεί να ανοίξει το δρόμο προς τον ακριβή εντοπισμό ελκυστικών έργων EE και τον προσδιορισμό των κεφαλαίων που πρέπει να επενδυθούν ανά περίπτωση. Συνεπώς, εξετάζονται κρίσιμα επενδυτικά χαρακτηριστικά έργων που έχουν ολοκληρωθεί στο παρελθόν και χρησιμοποιούνται μέθοδοι MM για να προβλέψουμε τη δυναμική μελλοντικών έργων.

Η κλιματική αλλαγή επηρεάζει ήδη τη ζωή μας και θέτει σε κίνδυνο το οικοσύστημα της Γης. Οι επιστήμονες, οι κυβερνήσεις και τα ιδρύματα προειδοποιούν ότι βρισκόμαστε σε μια αχαρτογράφητη περιοχή γεμάτη αβεβαιότητα. Η τελευταία προσπάθεια να μειωθούν οι εκπομπές CO₂ και να επιβληθούν ορισμένα όρια στον ρυθμό αύξησης της θερμοκρασίας ήταν η Συμφωνία των Παρισίων ([Doukas et al., 2018](#)). Σύμφωνα με τη συμφωνία αυτή, η μέση αύξηση της παγκόσμιας θερμοκρασίας θα πρέπει να διατηρηθεί κάτω από τους 2°C τις επόμενες δεκαετίες. Για την επίτευξη αυτού του στόχου, ο Διεθνής Οργανισμός Ανανεώσιμων Πηγών Ενέργειας (*IRENA*) προτείνει ότι απαιτείται πλήρης απεξάρτηση του ενεργειακού τομέα από τον άνθρακα έως το 2050 ([IRENA, 2015](#)). Η αλλαγή του ενεργειακού μείγματος και η μετάβαση σε μια “πράσινη” ενεργειακή εποχή δεν είναι όμως ομοιογενής σε όλη την υφήλιο-διαφορετικές χώρες συναντούν διαφορετικές συνθήκες ανάπτυξης, δηλαδή διαφορετικό ιστορικό και πολιτισμικό υπόβαθρο καθώς και διαφορετικά οικονομικά, κοινωνικά, πολιτικά και περιβαλλοντικά πλαίσια ([Sarrica et al., 2016](#)). Με άλλα λόγια, η επίτευξη των στόχων που έχουν τεθεί σε παγκόσμιο επίπεδο εξαρτάται από τις δράσεις των επιμέρους χωρών ή τομέων, οι οποίες δεν δρουν πάντα αρμονικά κατά των εκπομπών αερίων του θερμοκηπίου. Αυτά τα εμπόδια στην ενεργειακή μετάβαση ενισχύουν τη σημασία συμπληρωματικών μονοπατιών για τον μετριασμό του ενεργειακού αποτυπώματος, όπως αυτά της μείωσης της κατανάλωσης ενέργειας. Αυτή η οδός περιλαμβάνει την προώθηση των επενδύσεων EE, ιδίως στα κτίρια, καθώς και την προθυμία των πολιτών να συμμετάσχουν σε κοινοτικά έργα ανανεώσιμων πηγών ενέργειας, η οποία επηρεάζεται από πολλούς παράγοντες σύμφωνα με την [Kalkbrenner and Roosen \(2016\)](#). Οι σημαντικότεροι είναι η περιβαλλοντική ευαισθητοποίηση και η προοπτική ενεργειακής αυτόαρκειας ([Boon and Dieperink, 2014](#)), αν και η προθυμία μπορεί επίσης

να επηρεαστεί από κοινωνικούς παράγοντες, όπως η εμπιστοσύνη και οι κοινωνικοί κανόνες (Thøgersen and Grønhøj, 2010). Από την άλλη πλευρά, η δυσκολία των μεγαλύτερων γενεών να υιοθετήσουν συνήθειες φιλικές προς το κλίμα (Abreu et al., 2020), καθιστά αναγκαία την υιοθέτηση πιο αποδοτικών τεχνολογιών. Από την άποψη αυτή, οι έξυπνες πόλεις και τα έργα ανακαίνισης κτιρίων είναι κρίσιμα για την εποχή της πράσινης ενέργειας.

Σύμφωνα με τον Διεθνή Οργανισμό Ενέργειας, η εφαρμογή πολιτικών ΕΕ θα μπορούσε να οδηγήσει σε σχεδόν 36% των αποφευγόμενων εκπομπών αερίων του θερμοκηπίου μέχρι το 2050 (IEA, 2009, 2021). Η συντριπτική πλειονότητα αυτής της μείωσης αναμένεται να προέλθει από έργα ανακαίνισης κτιρίων (Taylor et al., 2010). Ωστόσο, πέρα από τις θεωρητικές προσδοκίες, στην πράξη, οι επενδύσεις ΕΕ αντιμετωπίζουν ορισμένα εμπόδια- τα έργα ΕΕ είναι συχνά κατακερματισμένα και το κόστος και η εξοικονόμηση ενέργειας είναι εκ των προτέρων άγνωστα ή δύσκολο να εκτιμηθούν με ακρίβεια. Έτσι, οι ενδιαφερόμενοι φορείς (ιδιωτικά χρηματοπιστωτικά ιδρύματα, επενδυτικά ταμεία, εθνικές και περιφερειακές αρχές, καθώς και πάροχοι ενεργειακών λύσεων) δεν διαθέτουν ώριμα εργαλεία λήψης αποφάσεων που θα μπορούσαν να προβλέψουν τη χρησιμότητα των μελλοντικών έργων ΕΕ και να τους βοηθήσουν να κατευθύνουν τις ενέργειές τους με μεγαλύτερη αξιοπιστία. Επιπλέον, οι αναπτυσσόμενες χώρες, οι οποίες έχουν τεράστιο δυναμικό για να αυξήσουν την αποδοτικότητά τους όσον αφορά την εξοικονόμηση ενέργειας, έχουν αντιμετωπίσει διάφορα εμπόδια, συμπεριλαμβανομένης της έλλειψης πρόσβασης σε κατάλληλους χρηματοδοτικούς μηχανισμούς (Painuly et al., 2003).

Όταν πρόκειται για τη χρηματοδότηση επενδύσεων ΕΕ μεγάλης κλίμακας, ένα από τα εμπόδια που υπάρχουν είναι η πιθανή έλλειψη επαρκούς όγκου δεδομένων¹ που θα μπορούσε να επιτρέψει την αξιολόγηση της χρησιμότητάς τους, αλλά, το σημαντικότερο, το γεγονός ότι ακόμη και όταν υπάρχουν τέτοια δεδομένα και είναι άμεσα διαθέσιμα προς χρήση, δεν αξιοποιούνται πάντα με συστηματικό τρόπο ώστε να υποστηρίζουν αποτελεσματικά τη λήψη αποφάσεων. Για παράδειγμα, οι φορείς χρηματοδότησης χρησιμοποιούν επί του παρόντος διαφορετικές μεθόδους, πρότυπα και πηγές δεδομένων για να αξιολογήσουν τον κίνδυνο και την αποδοτικότητα των μελλοντικών επενδύσεων (Hayes et al., 2011), καθώς και διαφορετικούς δείκτες για να λάβουν υπόψη την οικονομική δομή, το κλίμα και τη γεωγραφία τους, μεταξύ άλλων παραγόντων που επηρεάζουν. Σύμφωνα με το Painuly (2001), τα εμπόδια για τις ανανεώσιμες πηγές ενέργειας μπορεί να διαφέρουν ανάλογα με τις τεχνολογίες και τις χώρες. Ιδιαίτερα η ΕΕ έχει αναγνωρίσει αυτό το πρόβλημα, χρηματοδοτώντας ερευνητικά έργα που στοχεύουν στην απομείωση του κινδύνου των επενδύσεων σε ΑΠΕ, όπως τα *EEnvest*, *Triple-A* και *Quest: 2050*, μεταξύ άλλων (Loureiro et al., 2020). Ως αποτέλεσμα, τα έργα ΕΕ συχνά θεωρούνται ότι ενσωματώνουν υψηλότερους κινδύνους και τα χρηματοδοτικά ιδρύματα τείνουν να επικεντρώνονται σε άλλους τύπους έργων ή παραδοσιακές επενδύσεις (Sarkar and Singh, 2010).

Σε αυτή την έρευνα προσφέρουμε μια μεθοδολογία βασισμένη στα δεδομένα για το πρόβλημα της αξιολόγησης των επενδύσεων ΕΕ. Με κίνητρο τις πρόσφατες εξελίξεις στον τομέα της ΜΜ και την επιτυχή χρήση της σε προβλήματα ταξινόμησης, προτείνουμε τη χρήση ενός μοντέλου μετα-μάθησης² το οποίο προβλέπει τη χρησιμότητα των μελλοντικών έργων ΕΕ από την άποψη του κόστους και της εξοικονόμησης ενέργειας που επιτυγχάνεται. Χρησιμοποιώντας ένα πλούσιο σύνολο δεδομένων που αποτυπώνει (i) το κόστος ανακαίνισης, (ii) την τρέχουσα ενεργειακή κατανάλωση του κτιρίου, (iii) τα ειδικά χαρακτηριστικά του κτιρίου, καθώς και (iv) την αναμενόμενη και (v) την πραγματοποιηθείσα εξοικονόμηση ενέργειας από πολλαπλά έργα ΕΕ που έχουν ολοκληρωθεί στο παρελθόν, εκπαιδεύουμε διάφορες μεθόδους ταξινόμησης για τον προσδιορισμό της ελκυστικότητας των μελλοντικών επενδύσεων ΕΕ (υψηλή, μεσαία ή χαμηλή). Στη συνέχεια, χρησιμοποιείται ένας μετα-μαθητής για να καθορίσει ποιος ταξινομητής θα πρέπει να επιλεγεί ιδιαίτερα για την πραγματοποίηση της πρόβ-

¹Για παράδειγμα, πολλά από τα έργα που χρηματοδοτούνται σήμερα είναι μικρής κλίμακας ή σε πιλοτικό επίπεδο, καθιστώντας τη συγκριτική αξιολόγηση ένα δύσκολο έργο

²Η μετα-μάθηση περιλαμβάνει τη χρήση μεθόδων ΜΜ με στόχο να μάθουμε πώς να επιλέγουμε ή να συνδυάζουμε καλύτερα τις προβλέψεις που γίνονται από άλλες μεθόδους ΜΜ.

λήψης σύμφωνα με τις ιδιαιτερότητες του εξεταζόμενου έργου, βελτιώνοντας έτσι περαιτέρω την ακρίβεια των αποτελεσμάτων μας. Επιδεικνύουμε τα πλεονεκτήματα της προσέγγισής μας και αναδεικνύουμε πώς μπορεί να χρησιμοποιηθεί στην πράξη για να βοηθήσει τους ενδιαφερόμενους φορείς να διαφοροποιήσουν τις επενδύσεις τους σε ΕΕ με βάση την αναμενόμενη χρησιμότητά τους.

Οι συνεισφορές της μελέτης μας συνοψίζονται ως εξής:

- Προσφέρουμε ένα νέο μοντέλο MM που αξιολογεί τη χρησιμότητα των μελλοντικών έργων ΕΕ από την άποψη του κόστους και της υλοποιημένης εξοικονόμησης ενέργειας με συστηματικό τρόπο, βοηθώντας έτσι τα χρηματοδοτικά ιδρύματα στη λήψη αποφάσεων. Το μοντέλο μας είναι εύκολο να αναπαραχθεί και επομένως μπορεί να ενσωματωθεί στα υφιστάμενα συστήματα των ινστιτούτων με χαμηλό κόστος.
- Αντί να ταξινομούμε τις μελλοντικές επενδύσεις ΕΕ χρησιμοποιώντας συγκεκριμένους δείκτες που εκτιμούν θεωρητικά την αποδοτικότητά τους, βασίζουμε τις προτάσεις μας στην πραγματοποιηθείσα χρησιμότητα πολλαπλών, παρόμοιων έργων ΕΕ που έχουν ολοκληρωθεί στο παρελθόν, μαθαίνοντας έτσι εμπειρικά από την επιτυχία και τους περιορισμούς τους και προσαρμόζοντας τις προτάσεις μας σύμφωνα με τα ιδιαίτερα χαρακτηριστικά κάθε νέας επένδυσης.
- Για να μετριάσουμε τους υποκείμενους κινδύνους της χρήσης ενός μόνο ταξινομητή (π.χ. όσον αφορά την ακρίβεια και την ανθεκτικότητα όταν πρόκειται για μικρά, ανισόροπα ή θορυβώδη σύνολα δεδομένων) για την αξιολόγηση μελλοντικών επενδύσεων ΕΕ, προτείνουμε τη χρήση ενός μετα-μαθητή ο οποίος είναι υπεύθυνος για τον εντοπισμό του ταξινομητή που αναμένεται να οδηγήσει στις πιο αξιόπιστες προβλέψεις.
- Παρέχουμε τις προβλέψεις της ταξινόμησής μας με τη μορφή πιθανοτήτων για να λάβουμε υπόψη την αβεβαιότητα και χρησιμοποιούμε αυτά τα αποτελέσματα για να διατυπώσουμε δυναμικά συστάσεις σχετικά με το ποσοστό της επιχορηγούμενης χρηματοδότησης που θα πρέπει να λάβουν οι μελλοντικές επενδύσεις ΕΕ.

Το υπόλοιπο κεφάλαιο οργανώνεται ως εξής. Στην ενότητα 8.2 παρουσιάζεται το πλαίσιο του προβλήματος και η βιβλιογραφική ανασκόπηση. Στην ενότητα 8.3 περιγράφεται η μεθοδολογία που αναπτύχθηκε. Στην ενότητα 8.4 παρουσιάζεται μια πειραματική εφαρμογή που βασίζεται σε μια πραγματική μελέτη περίπτωσης στη Λετονία. Τέλος, στην ενότητα 8.5 παρέχονται συμπερασματικές παρατηρήσεις.

8.2 Αναλυτική Διατύπωση Προβλήματος

Είναι γενικά αποδεκτό ότι η χρήση ενέργειας στα κτίρια μπορεί να μειωθεί σημαντικά μέσω της υιοθέτησης των υφιστάμενων τεχνολογιών εξοικονόμησης ενέργειας. Ωστόσο, τα έργα ΕΕ ενδέχεται να εξακολουθούν να αντιμετωπίζουν δυσκολίες στη χρηματοδότησή τους λόγω της αβεβαιότητας και της έλλειψης ολοκληρωμένης μεθοδολογίας για την αξιολόγηση και τη σύγκριση του δυναμικού τους (Jensen et al., 2018). Πιο συγκεκριμένα, Intrachooto and Horayangkura (2007) έχουν εντοπίσει την αλληλεξάρτηση των συνιστωσών ανακαίνισης, την κερδοσκοπική οικονομική απόδοση και τη νοοτροπία του χαμηλότερου κόστους ως τους κύριους παράγοντες από τους οποίους προκύπτουν τα χρηματοδοτικά εμπόδια. Επί του παρόντος, οι ανακαίνισεις ΕΕ σε κτίρια αξιολογούνται από τους παραδοσιακούς μηχανισμούς παροχής επενδύσεων που έχουν αναπτυχθεί από μεγάλα χρηματοδοτικά ιδρύματα και τράπεζες. Αν και αρκετά έργα έχουν χρηματοδοτηθεί μέσω αυτής της διαδικασίας, πολλές δυνατότητες μπορούν ακόμη να αξιοποιηθούν (Taylor et al., 2008).

Τα τελευταία χρόνια, η αυξανόμενη υιοθέτηση τεχνολογιών πληροφορικής και επικοινωνιών, όπως το διαδίκτυο των πραγμάτων και η τεχνητή νοημοσύνη, κατέστησαν δυνατή την απόκτηση μεγάλου όγκου ετερογενών δεδομένων που μπορούν να οδηγήσουν σε νέες λύσεις και αναλύσεις (Marinakos, 2020). Πιο συγκεκριμένα, στον τομέα της χρηματοδότησης της

ΕΕ είναι πλέον δυνατή η συλλογή δεδομένων από έξυπνους μετρητές μετά την υλοποίηση ανακαινίσεων και η λήψη διορατικών πληροφοριών σχετικά με την πραγματική τους απόδοση. Ωστόσο, η χρηματοδότηση της ΕΕ στα κτίρια παραμένει σχετικά ανεπαρκώς διερευνημένη και υποεπενδεδυμένη, σύμφωνα με το [Zhang et al. \(2019\)](#). Κατά συνέπεια, οι μελλοντικές μελέτες θα πρέπει να επικεντρωθούν στην εφαρμογή μεθόδων και τεχνικών τεχνητής νοημοσύνης ([Debrah et al., 2021](#)), καθώς και στη βέλτιστη αξιοποίηση των διαθέσιμων δεδομένων προς την κατεύθυνση της παροχής εργαλείων που αξιολογούν με ακρίβεια τις επενδύσεις ΕΕ ([Jensen and Maslesa, 2015](#)).

Ελάχιστες ερευνητικές εργασίες έχουν επιχειρήσει να παράσχουν μια πρόβλεψη ταξινόμησης³ πλαίσιο για την υποστήριξη της χρηματοδοτικής κοινότητας για τον εντοπισμό ευμερούων μελλοντικών έργων ανακαίνισης ([Doukas, 2018](#)). Μια βιβλιογραφική ανασκόπηση για τις προσεγγίσεις αξιολόγησης της ΕΕ μπορεί να βρεθεί στο [Tuominen et al. \(2015\)](#) όπου οι συγγραφείς κατέληξαν στο συμπέρασμα ότι οι οικονομικοί δείκτες συχνά παραβλέπονται ή καλύπτονται επιφανειακά όταν διερευνάται η ΕΕ. Σύμφωνα με την ίδια μελέτη, η περίοδος αποπληρωμής και ο μετριασμός του κόστους είναι οι δύο πιο συχνοί οικονομικοί στόχοι που εξετάζονται. Στις [Stocker et al. \(2015\)](#), [de Vasconcelos et al. \(2016\)](#) και [Ortiz et al. \(2016\)](#) ο αναγνώστης μπορεί να βρει μελέτες που σχετίζονται με τη βέλτιστη ανάλυση κόστους για την ενεργειακή ανακαίνιση οικιστικών κτιρίων στις περιπτώσεις των Άλπεων, της Πορτογαλίας και της Καταλονίας, αντίστοιχα. Εκτός από το κόστος και την περίοδο απόσβεσης, ο οικονομικός κίνδυνος των έργων χρησιμοποιείται επίσης ως συμπληρωματικός στόχος ([Forouli et al., 2019](#)). Ωστόσο, σε αντίθεση με μια διαισθητική προσέγγιση, η οικονομική αποδοτικότητα είναι υποσύνολο της ίδιας της έννοιας της ΕΕ- η ΕΕ συνήθως αλληλεπιδρά με άλλες περιβαλλοντικές και κοινωνικές πτυχές ([Arsenopoulos et al., 2021](#)). Στο πλαίσιο αυτό, στην παρούσα μελέτη συμπεριλαμβάνουμε επιπλέον πληροφορίες σχετικά με την τρέχουσα κατανάλωση ενέργειας και τα χαρακτηριστικά των κτιρίων (π.χ. έτος κατασκευής, επιφάνεια θέρμανσης και αριθμός διαμερισμάτων), καθώς και τις μειώσεις CO₂ που αναμένεται να επιτύχουν οι επενδύσεις σε ΕΕ ως θεμελιώδεις παραμέτρους της διαδικασίας αξιολόγησης της ΕΕ.

Μια άλλη καινοτομία της μελέτης μας είναι η χρήση μεθόδων MM και μετα-μάθησης ([Makridakis et al., 2018](#)). Οι περισσότερες από τις προηγούμενες ερευνητικές εργασίες αξιολόγησαν τις επενδύσεις χρησιμοποιώντας πλαίσια βασισμένα στην πολυκριτήρια ανάλυση αποφάσεων ([Sarmas et al., 2020](#)) (είτε αξιοποιώντας διακριτές μεθόδους ([Mexis et al., 2021](#)), είτε συνεχείς μεθόδους βελτιστοποίησης πολλαπλών στόχων ([Abdou et al., 2021](#))), ανάλυση κόστους-οφέλους ([Morrissey et al., 2013](#)), και ανάλυση κόστους-αποτελεσματικότητας ([Tuominen et al., 2015](#); [Foda et al., 2020](#)). Ωστόσο, αυτά τα πλαίσια απαιτούν βαθιά γνώση των οικονομικών, κοινωνικών και κλιματικών παραγόντων που επηρεάζουν κάθε επένδυση. Επιπλέον, η απόδοσή τους επηρεάζεται σε μεγάλο βαθμό από τις παραδοχές που κάνουν οι αντίστοιχοι μέθοδοι. Σε αυτό το πλαίσιο, οι μέθοδοι MM θα μπορούσαν να χρησιμοποιηθούν ως εναλλακτικές, βασισμένες στα δεδομένα προσεγγίσεις στα παραδοσιακά πλαίσια αξιολόγησης της ΕΕ ([Zekić-Sušac et al., 2021](#)). Μια πρόσφατη ανασκόπηση σχετικά με τις εφαρμογές MM στον τομέα των ενεργειακών οικονομικών και χρηματοοικονομικών ([Ghoddusi et al., 2019](#)) έδειξε ότι οι μέθοδοι MM χρησιμοποιούνται κυρίως στην πρόβλεψη των τιμών του αργού πετρελαίου και της ηλεκτρικής ενέργειας. Παρά τη συνεχώς αυξανόμενη χρήση της θεωρίας MM στον τομέα της ενέργειας, η ταξινόμηση των επενδύσεων ΕΕ με βάση την αναμενόμενη χρησιμότητά τους είναι ένα έργο που θα μπορούσε να διερευνηθεί περαιτέρω.

Η παρούσα ερευνητική εργασία επιχειρεί να αναπτύξει μεθόδους MM και τεχνικές ανάλυσης δεδομένων στον τομέα των επενδύσεων ΕΕ. Στην [Doukas et al. \(2021\)](#), εφαρμόστηκαν παραδοσιακές, στατιστικές μέθοδοι ταξινόμησης, όπως η ordinal logit, η ordinal probit και οι μέθοδοι γραμμικής διακριτής ανάλυσης μαζί με έναν περιορισμένο αριθμό μεθόδων MM, όπως οι k-κοντινότεροι γείτονες και οι μηχανές διανυσμάτων υποστήριξης. Στο πλαίσιο αυτό, η παρούσα μελέτη εξετάζει επιπλέον τις μεθόδους Gaussian naive Bayes, extreme

³Η πρόβλεψη μπορεί να είναι είτε δυαδική (επένδυση έναντι μη επένδυσης) είτε πολλαπλών κατηγοριών (π.χ. το δυναμικό της επένδυσης είναι χαμηλό, μεσαίο ή υψηλό).

gradient boosted trees και random forest σε μια προσπάθεια να βελτιωθεί η ακρίβεια των προβλέψεων που γίνονται μέσω μεθόδων υψηλότερης ικανότητας μάθησης. Επιπλέον, το προτεινόμενο πλαίσιο χρησιμοποιεί έναν μετα-μαθητή με στόχο τον εντοπισμό της ακριβέστερης μεθόδου ταξινόμησης για κάθε επένδυση με βάση τα ιδιαίτερα χαρακτηριστικά της, επιτρέποντας έτσι την περαιτέρω βελτιστοποίηση και αυξάνοντας την πιθανή προστιθέμενη αξία της προτεινόμενης διαδικασίας ταξινόμησης. Η συμβολή της παρούσας μελέτης μπορεί να συνοψιστεί στη χρησιμοποίηση ενός μοντέλου μετα-μάθησης με στόχο τη μείωση του εγγενούς κινδύνου της χρήσης ενός μόνο ταξινομητή, ιδίως με μικρά ή ανισόρροπα σύνολα δεδομένων. Σε αντίθεση με προηγούμενες μελέτες, οι οποίες πρότειναν προσαρμοσμένα μοντέλα για συγκεκριμένα σύνολα δεδομένων, η παρούσα μελέτη παρέχει ένα γενικευμένο πλαίσιο που παράγει αξιόπιστες προβλέψεις όσον αφορά την ακρίβεια και την ευρωστία, ανεξάρτητα από τα επιλεγμένα χαρακτηριστικά και τον όγκο των διαθέσιμων δεδομένων.

8.3 Προτεινόμενο Μοντέλο

Η μεθοδολογία που παρουσιάζεται φιλοδοξεί να παράσχει μια σύσταση χρηματοδότησης επιχορήγησης για μελλοντικά έργα ΕΕ, αντλώντας διδάγματα από ένα σύνολο ήδη υλοποιημένων έργων με παρόμοια χαρακτηριστικά. Η βάση της προτεινόμενης προσέγγισης είναι ένα μοντέλο ταξινόμησης συνόλου στοιβάξης που βασίζεται σε πέντε βασικές μεθόδους ταξινόμησης, συγκεκριμένα *k-Nearest Neighbors*, *Gaussian Naive Bayes*, *Extreme Gradient Boosted Trees*, *Random Forest* και *Support Vector Machine*. Το σύνολο εκπαίδευσης των ταξινομητών είναι ουσιαστικά ένα σύνολο έργων που περιλαμβάνει πληροφορίες σχετικά με τις ανακαινίσεις που πραγματοποιήθηκαν σε διάφορα κτίρια στο παρελθόν. Αυτό περιλαμβάνει δεδομένα που ήταν αρχικά διαθέσιμα πριν από την υλοποίηση της ανακαινίσης (που χρησιμοποιούνται ως χαρακτηριστικά) και δεδομένα καταγραφής μετά την ολοκλήρωση της επένδυσης (που χρησιμοποιούνται για την επισήμανση). Στην πράξη, και για να καταστεί δυνατή η αυτοματοποίηση, οι πληροφορίες αυτές θα πρέπει να αποθηκεύονται στη βάση δεδομένων του πληροφοριακού συστήματος που χρησιμοποιείται από το χρηματοδοτικό ίδρυμα για την αξιολόγηση μελλοντικών επενδύσεων ΕΕ.

8.3.1 Αρχιτεκτονική Μοντέλου

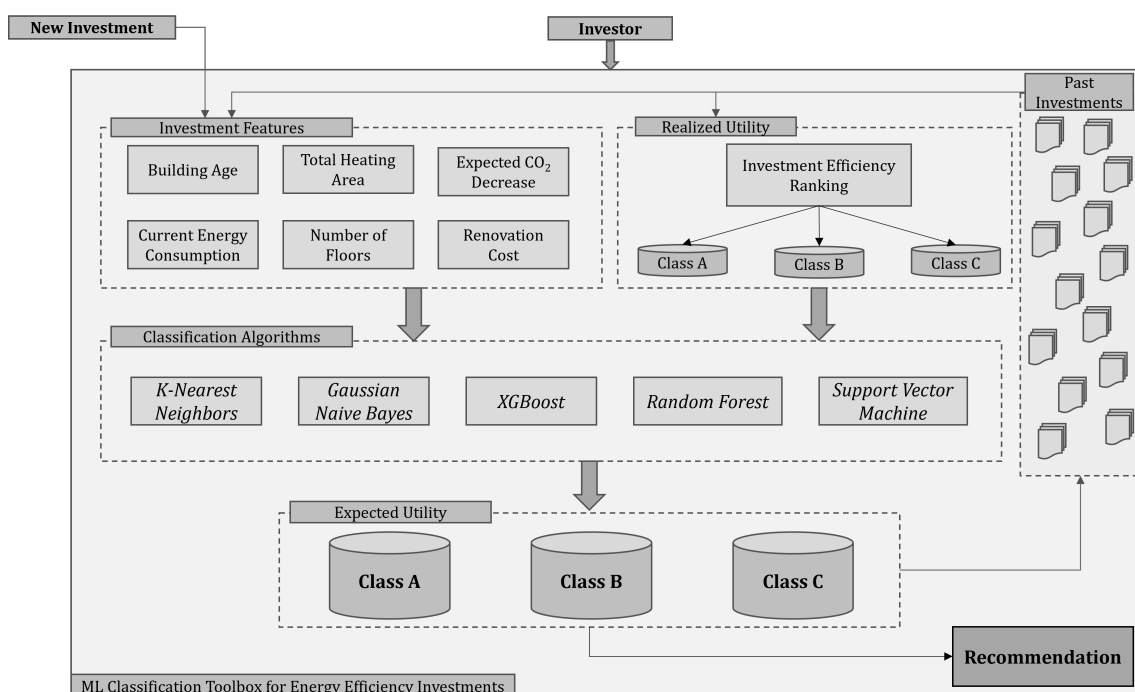
Συγκεκριμένα, τα χαρακτηριστικά της επένδυσης αφορούν συγκεκριμένα χαρακτηριστικά των έργων που, στην περίπτωση μας, είναι η ηλικία του ανακαινισμένου κτιρίου, ο αριθμός των διαμερισμάτων, η συνολική επιφάνεια θέρμανσης και η τρέχουσα κατανάλωση ενέργειας, η αναμενόμενη μείωση του CO₂ και το κόστος ανακαινίσης. Η έξοδος των βασικών ταξινομητών είναι οι πιθανότητες ότι η επένδυση ανήκει σε κάθε διακριτή κλάση από τις ακόλουθες τρεις:

- *Κλάση A*: Το έργο πρέπει να χρηματοδοτηθεί.
- *Κλάση B*: Το έργο θα πρέπει να χρηματοδοτηθεί εν μέρει.
- *Class C*: Το έργο δεν πρέπει να χρηματοδοτηθεί.

Προκειμένου να επισημανθούν οι παρελθούσες επενδύσεις, η πραγματοποιηθείσα χρησιμότητα κάθε έργου υπολογίζεται χρησιμοποιώντας ένα μέτρο επιλογής. Στην παρούσα μελέτη εξετάζουμε την κατάταξη της αποτελεσματικότητας των επενδύσεων, όπως περιγράφεται στην ενότητα 8.4.1. Κατά συνέπεια, τα έργα με την καλύτερη απόδοση χαρακτηρίζονται ως *Class A*, τα έργα με τη χειρότερη απόδοση ως *Class C*, ενώ τα υπόλοιπα ως *Class B*. Έχοντας επισημάνει τις επενδύσεις, οι βασικές μέθοδοι ταξινόμησης χρησιμοποιούνται για την ταξινόμηση παρελθόντων έργων και οι προβλέψεις τους αποθηκεύονται. Χρησιμοποιώντας αυτές τις προβλέψεις ως είσοδο μαζί με τις πραγματικές ετικέτες των επενδύσεων και τα χαρακτηριστικά που χρησιμοποιήθηκαν αρχικά από τους βασικούς ταξινομητές, εκπαιδεύεται

ένας μετα-μαθητής, δηλαδή ένας ταξινομητής λογιστικής παλινδρόμησης, με στόχο να προβλέψει ποια από τις πέντε βασικές μεθόδους είναι η καταλληλότερη για την πρόβλεψη της κλάσης κάθε έργου. Δεδομένης αυτής της γνώσης, ο “βέλτιστος” ταξινομητής χρησιμοποιείται για κάθε επένδυση για να προκύψει η πιθανότητα κάθε κλάσης. Αυτές οι πιθανότητες συνδυάζονται τελικά προκειμένου να παρασχεθεί μια σύσταση σχετικά με το ποσοστό επιχορήγησης για μια μελλοντική επένδυση, όπως περιγράφεται στην ενότητα 8.3.4. Η πλήρης διαδικασία σύστασης συνοψίζεται στο Σχήμα 8.1.

Σχήμα 8.1: Επισκόπηση της προτεινόμενης μεθοδολογίας. Η σύσταση σχετικά με το ποσοστό επιχορήγησης της χρηματοδότησης των μελλοντικών επενδύσεων βασίζεται σε μια προσέγγιση βασισμένη σε δεδομένα, η οποία αξιοποιεί χρήσιμες γνώσεις από προηγούμενα έργα, που χαρακτηρίζονται με βάση την επιτευχθείσα μείωση της κατανάλωσης ενέργειας και το κόστος της επένδυσης (πραγματοποιηθείσα χρησιμότητα). Η έξοδος των βασικών μεθόδων ταξινόμησης, καθώς και του μετα-μαθητή, παρέχει το ποσοστό της συνιστώμενης επιχορηγούμενης χρηματοδότησης.



Σημειώστε ότι το πλαίσιο της προτεινόμενης μεθοδολογίας είναι πολύ ευέλικτο όσον αφορά τα χαρακτηριστικά των επενδύσεων, τις κλάσεις, τις μεθόδους και τα μέτρα χρησιμότητας που χρησιμοποιούνται. Για παράδειγμα, οι υπεύθυνοι λήψης αποφάσεων μπορούν να προσαρμόσουν τις μεταβλητές εισόδου που χρησιμοποιούνται από τους ταξινομητές ανάλογα με τις προτιμήσεις τους ή τη διαθεσιμότητα δεδομένων. Ομοίως, μπορούν να τροποποιήσουν το σύνολο των βασικών ταξινομητών, λαμβάνοντας υπόψη διαφορετικό αριθμό και τύπους μεθόδων. Τέλος, μπορούν να καθορίσουν τον αριθμό των ετικετών που λαμβάνονται υπόψη από τις μεθόδους ταξινόμησης, καθώς και την προσέγγιση/τα μέτρα που χρησιμοποιούνται για τον προσδιορισμό τους. Ως εκ τούτου, οι επιλογές που έγιναν στη μελέτη μας για τη δημιουργία του πλαισίου της περιγραφόμενης μεθοδολογίας και την επίδειξη της χρήσης της θα πρέπει να θεωρούνται ενδεικτικές, αν και χρησιμοποιούν ένα ουσιαστικό σύνολο παραμέτρων.

Σημειώστε επίσης ότι η ευελιξία που προσφέρει το προτεινόμενο μοντέλο μπορεί σε γενικές γραμμές να αντισταθμιστεί αποτελεσματικά όσον αφορά την απόδοση ταξινόμησης μέσω του μετα-μαθητή που χρησιμοποιείται. Ανάλογα με την αλγοριθμική τους φύση, διαφορετικές μέθοδοι ταξινόμησης μπορεί να είναι πιο κατάλληλες για το χειρισμό μικρών ή ανισόρροπων συνόλων δεδομένων, καθώς και για την πραγματοποίηση ακριβών προβλέψεων όταν παρέχον-

ται ως είσοδος πολλαπλά χαρακτηριστικά, ιδίως σε περιπτώσεις όπου δεν είναι όλα τα χαρακτηριστικά κρίσιμα ή της ίδιας σημασίας. Για παράδειγμα, οι μέθοδοι που βασίζονται σε δέντρα αποφάσεων (π.χ. XGBoost και RF) μπορούν φυσικά να επιλέξουν τα πιο σημαντικά χαρακτηριστικά για την πραγματοποίηση προβλέψεων με βάση τη συμβολή κάθε χαρακτηριστικού στη συνολική μείωση του σφάλματος πρόβλεψης κατά την προσαρμογή της μεθόδου. Επιπλέον, ορισμένες μέθοδοι (π.χ. RF) είναι ιδιαίτερα αποτελεσματικές στο χειρισμό πολλαπλών χαρακτηριστικών, ενώ άλλες στην αντιμετώπιση της τυχαιότητας των δεδομένων (π.χ. RF και SVM). Αυτό έρχεται σε αντίθεση με μεθόδους όπως ο k-NN και ο Gaussian naïve Bayes που, αν και είναι πιο αποτελεσματικές με μικρά σύνολα εκπαίδευσης (λιγότερο “διψασμένοι για δεδομένα” αλγόριθμοι), δεν μπορούν να επιλέξουν αυτόματα τα πιο σχετικά χαρακτηριστικά και επομένως μπορεί να επηρεαστούν αρνητικά όταν παρέχονται πολλαπλές μεταβλητές ως είσοδος. Ο σκοπός του μετα-μαθητή είναι ακριβώς να λαμβάνει υπόψη του τέτοια ζητήματα και ιδιαιτερότητες, να μετριάξει τους υποκείμενους κινδύνους από τη χρήση ενός μόνο ταξινομητή για την αξιολόγηση μελλοντικών επενδύσεων σε ΕΕ και να παρέχει όσο το δυνατόν πιο αξιόπιστες προβλέψεις, δεδομένου του συνόλου δεδομένων που είναι διαθέσιμα για εκπαίδευση και των βασικών παραμέτρων του εξεταζόμενου προβλήματος ταξινόμησης.

8.3.2 Baseline Μοντέλα Ταξινόμησης

Η προτεινόμενη μεθοδολογία βασίζεται σε πέντε βασικές μεθόδους ταξινόμησης, οι οποίες επιλέγονται έτσι ώστε ο μετα-μαθητής να επιλέγει τον καταλληλότερο ταξινομητή από έναν πραγματικά ποικιλόμορφο⁴ σύνολο μεθόδων, καθεμία από τις οποίες κάνει διαφορετικές υποθέσεις σχετικά με το έργο πρόβλεψης. Η προσέγγιση αυτή έχει αποδειχθεί αποτελεσματική για τη βελτίωση της συνολικής ακρίβειας (Syarif et al., 2012). Οι βασικές μέθοδοι ταξινόμησης παρουσιάζονται συνοπτικά παρακάτω.

k-Nearest Neighbors

Οι k-κοντινότεροι γείτονες (k-NN) είναι μια μη παραμετρική μέθοδος ταξινόμησης (Cover and Hart, 1967). Η είσοδος της μεθόδου αποτελείται από n χαρακτηριστικά που χαρακτηρίζουν κάθε παρατήρηση (στην περίπτωση μας μια επένδυση ΕΕ), ενώ η έξοδος είναι μια ετικέτα που καθορίζει την κλάση της (στην περίπτωση μας την πραγματοποιημένη χρησιμότητα της επένδυσης). Πρακτικά, η μέθοδος ταξινομεί τις μελλοντικές μη επισημασμένες παρατηρήσεις εντοπίζοντας τις k πιο παρόμοιες επισημασμένες παρατηρήσεις (πλησιέστεροι γείτονες) με την εξεταζόμενη και λαμβάνοντας υπόψη το πλήθος των κλάσεων τους.

Συγκεκριμένα, η μέθοδος αποτελείται από δύο φάσεις: τη φάση εκπαίδευσης και τη φάση δοκιμής. Κατά τη διάρκεια της φάσης εκπαίδευσης αποθηκεύονται οι επισημειωμένες παρατηρήσεις, οι οποίες γενικά είναι διανύσματα σε έναν πολυδιάστατο χώρο, κάθε μία από τις οποίες αντιστοιχίζεται σε μια κλάση, και ορίζεται ο αριθμός των γειτόνων k . Κατά τη φάση δοκιμής τα μη επισημασμένα διανύσματα ταξινομούνται με την αντιστοίχισή τους στην κλάση που εμφανίζεται συχνότερα μεταξύ των k επισημασμένων παρατηρήσεων που βρίσκονται πλησιέστερα στο διάνυσμα δοκιμής. Ο όρος “πλησιέστερο” μπορεί να ερμηνευτεί και να υπολογιστεί χρησιμοποιώντας διάφορα μέτρα απόστασης ανάλογα με τον τύπο των χαρακτηριστικών που χρησιμοποιούνται ως είσοδος. Για συνεχείς μεταβλητές η ευκλείδεια απόσταση είναι το πιο συχνά χρησιμοποιούμενο μέτρο, ενώ για διακριτές μεταβλητές επικρατεί στη βιβλιογραφία η απόσταση Hamming (Norouzi et al., 2012). Μια άλλη στρατηγική είναι η χρήση συντελεστών συσχέτισης, όπως η συσχέτιση Pearson (Lee and Styczynski, 2018). Δεδομένου ότι η μέθοδος βασίζεται στον υπολογισμό αποστάσεων μεταξύ των χαρακτηριστικών εισόδου,

⁴Η ποικιλομορφία αναφέρεται στη διαφορετική αλγοριθμική φύση των επιλεγμένων μεθόδων MM και στα πλεονεκτήματα και τις αδυναμίες που αναμένεται να εμφανίζει εκ κατασκευής κάθε μία από αυτές τις μεθόδους όσον αφορά την ακρίβεια και την ευρωστία όταν πρόκειται για μικρά, ανισόρροπα ή θορυβώδη σύνολα δεδομένων, καθώς και για το χειρισμό πολλαπλών χαρακτηριστικών. Αυτές οι ιδιότητες συνοψίζονται στο εισαγωγικό μέρος της ενότητας 8.3 και περιγράφονται λεπτομερώς στις επόμενες υποενότητες.

συνιστάται η κανονικοποίηση των τιμών των χαρακτηριστικών για τη βελτίωση της ακρίβειας (Toussaint, 2005).

Ο ορισμός του k , ουσιαστικά της μοναδικής υπερπαραμέτρου του k -NN, είναι κρίσιμος επειδή επηρεάζει άμεσα την απόδοση της διαδικασίας επισήμανσης. Εάν το k οριστεί στη μονάδα, τότε οι μη επισημασμένες παρατηρήσεις ταξινομούνται σύμφωνα με την ετικέτα του πλησιέστερου γείτονά τους. Εάν το k οριστεί ίσο με τον αριθμό των παρατηρήσεων που περιλαμβάνονται στο σύνολο εκπαίδευσης, τότε οι μη επισημασμένες παρατηρήσεις ταξινομούνται σύμφωνα με την πιο δημοφιλή ετικέτα στο πλήρες σύνολο εκπαίδευσης. Δεδομένου ότι η "βέλτιστη" τιμή του k υπόκειται συνήθως στις ιδιαιτερότητες του συνόλου εκπαίδευσης και της εργασίας ταξινόμησης, συνήθως ορίζεται μέσω ευρετικών τεχνικών διασταυρούμενης επικύρωσης, οι οποίες χρησιμοποιούνται ευρέως στη βιβλιογραφία της MM για τη λεπτομερή ρύθμιση των υπερπαραμέτρων.

Στο πλαίσιο της παρούσας μελέτης, τα χαρακτηριστικά που εξετάζονται είναι συνεχείς μεταβλητές. Ως αποτέλεσμα, χρησιμοποιήθηκε η ευκλείδεια απόσταση για τον προσδιορισμό των πλησιέστερων γειτόνων. Δεδομένων των καρτεσιανών συντεταγμένων δύο σημείων p και q σε έναν ευκλείδειο χώρο n -διάστασης, η απόσταση υπολογίζεται ως εξής:

$$d(p, q) = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_i - q_i)^2 + \dots + (p_n - q_n)^2}. \quad (8.1)$$

Gaussian Naive Bayes

Η οικογένεια των πιθανοτικών ταξινομητών περιλαμβάνει ταξινομητές που είναι σε θέση να προβλέπουν την κατανομή πιθανότητας σε ένα διαθέσιμο σύνολο κλάσεων, αντί να προβλέπουν μια μόνο πρόβλεψη κλάσης στην οποία θα πρέπει να ανήκει η παρατήρηση (Mena et al., 2016). Οι ταξινομητές Naive Bayes είναι μια υποκατηγορία των πιθανοτικών ταξινομητών που βασίζονται στο θεώρημα του Bayes, υποθέτοντας ισχυρή ανεξαρτησία μεταξύ των χαρακτηριστικών. Ο Gaussian naive Bayes έχει χρησιμοποιηθεί σε πολλούς τομείς, συμπεριλαμβανομένων εργασιών που σχετίζονται με την αξιολόγηση της απόδοσης επενδύσεων (Chia-Cheng et al., 2019), την πρόβλεψη της παραγωγής φωτοβολταϊκών (Bayindir et al., 2017) και την ανάλυση της ενεργειακής απόδοσης των κτιρίων (Prasetyo et al., 2019).

Σύμφωνα με το Zhang (2004), δεδομένου ενός διανύσματος χαρακτηριστικών x_1 έως x_n και μιας μεταβλητής κλάσης y , η ακόλουθη σχέση δηλώνεται από το θεώρημα του Bayes. η οικογένεια των πιθανοτικών ταξινομητών περιλαμβάνει ταξινομητές που είναι σε θέση να προβλέψουν την κατανομή πιθανότητας σε ένα διαθέσιμο σύνολο κλάσεων, αντί να προβλέπουν μια μόνο πρόβλεψη κλάσης στην οποία θα πρέπει να ανήκει η παρατήρηση (Mena et al., 2016). Οι ταξινομητές Naive Bayes είναι μια υποκατηγορία των πιθανοτικών ταξινομητών που βασίζονται στο θεώρημα του Bayes, υποθέτοντας ισχυρή ανεξαρτησία μεταξύ των χαρακτηριστικών. Ο Gaussian naive Bayes έχει χρησιμοποιηθεί σε πολλούς τομείς, συμπεριλαμβανομένων εργασιών που σχετίζονται με την αξιολόγηση της απόδοσης επενδύσεων (Chia-Cheng et al., 2019), την πρόβλεψη της παραγωγής φωτοβολταϊκών (Bayindir et al., 2017) και την ανάλυση της ενεργειακής απόδοσης των κτιρίων (Prasetyo et al., 2019).

Σύμφωνα με το Zhang (2004), δεδομένου ενός διανύσματος χαρακτηριστικών x_1 έως x_n και μιας μεταβλητής κλάσης y , η ακόλουθη σχέση δηλώνεται από το θεώρημα του Bayes.

$$p(y | x_1, \dots, x_n) = \frac{p(y) p(x_1, \dots, x_n | y)}{p(x_1, \dots, x_n)}. \quad (8.2)$$

Χρησιμοποιώντας την αφελή υπόθεση εξαρτημένης ανεξαρτησίας για όλα τα i , η σχέση αυτή μπορεί να μετατραπεί στην ακόλουθη εξίσωση:

$$p(y | x_1, \dots, x_n) = \frac{p(y) \prod_{i=1}^n p(x_i | y)}{p(x_1, \dots, x_n)}. \quad (8.3)$$

Ο κανόνας ταξινόμησης που δίνεται από την ακόλουθη εξίσωση προκύπτει αφού $p(x_1, \dots, x_n)$ είναι σταθερός δεδομένης της εισόδου:

$$\hat{y} = \operatorname{argmax}_y p(y) \prod_{i=1}^n p(x_i | y). \quad (8.4)$$

Υπάρχουν διαφορετικοί ταξινομητές Naive Bayes ανάλογα με τις υποθέσεις που γίνονται σχετικά με την κατανομή της $p(x_i | y)$. Το πρόβλημα που εξετάζεται τίθεται σε συνεχή δεδομένα, επομένως μπορούμε να κάνουμε την υπόθεση ότι οι συνεχείς τιμές που σχετίζονται με κάθε κλάση ακολουθούν την κατανομή Gauss (Jahromi and Taheri, 2017). Ως εκ τούτου, αξιοποιείται η Gaussian naive Bayes, όπου η πιθανότητα των χαρακτηριστικών υποτίθεται ότι είναι Gaussian:

$$p(x_i | y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} e^{-\frac{(x_i - \mu_y)^2}{2\sigma_y^2}}. \quad (8.5)$$

Extreme Gradient Boosted Trees

Τα δέντρα ταξινόμησης είναι μια μέθοδος MM που χωρίζει αναδρομικά το χώρο των δεδομένων μέσω κανόνων για την ταξινόμηση ενός συνόλου παρατηρήσεων (Breiman, 1993). Δεδομένου ότι οι κανόνες κατάτμησης κατασκευάζονται διαδοχικά, το δέντρο ξεκινά από μια ρίζα, όπου περιλαμβάνεται το πλήρες σύνολο του εκπαιδευτικού υλικού, και χωρίζει τις διαθέσιμες παρατηρήσεις σε κλάδους, καθέννας από τους οποίους περιέχει τις παρατηρήσεις που ικανοποιούν τον πρώτο κανόνα του δέντρου. Στη συνέχεια, κάθε κλάδος μπορεί να χωριστεί περαιτέρω χρησιμοποιώντας πρόσθετους κανόνες. Οι κλάδοι που δεν χωρίζονται ονομάζονται φύλλα και περιλαμβάνουν τις τελικές προβλέψεις του δέντρου. Για να καθοριστεί ποιο φύλλο θα πρέπει να χρησιμοποιηθεί για την πρόβλεψη κάθε παρατήρησης, πρέπει να ληφθούν υπόψη οι συνδέσεις των κανόνων. Οι κανόνες που κατασκευάζονται βασίζονται στα χαρακτηριστικά που είναι διαθέσιμα για την εκπαίδευση της μεθόδου και ορίζονται αυτόματα με τη χρήση διαφόρων κριτηρίων. Επίσης, τις περισσότερες φορές, χρησιμοποιούνται πρόσθετα κριτήρια (π.χ. ρυθμός μάθησης, μέγιστος αριθμός φύλλων, μέγιστο βάθος δέντρου, ελάχιστο άθροισμα του βάρους της περίπτωσης που απαιτείται σε ένα παιδί και ελάχιστη μείωση των απωλειών που απαιτείται για να γίνει περαιτέρω διαμερισμός σε έναν κόμβο φύλλου του δέντρου) με τη μορφή υπερπαραμέτρων για να καθοριστεί τότε θα πρέπει να τερματιστεί η ανάπτυξη του δέντρου, αποφεύγοντας έτσι την υπερβολική προσαρμογή και μειώνοντας το υπολογιστικό κόστος.

Το Gradient boosting (GB) είναι μια τεχνική που μπορεί να εξοπλιστεί με οποιαδήποτε μέθοδο MM για να μειώσει την προκατάληψη και τη διακύμανση των προβλέψεων της και, ως αποτέλεσμα, να μετατρέψει τους αδύναμους εκπαιδευόμενους σε ισχυρούς. Κατά συνέπεια, η GB συνδυάζει διαδοχικά πολλαπλούς αδύναμους εκπαιδευόμενους για να δημιουργήσει έναν ενιαίο ισχυρό εκπαιδευόμενο με υψηλότερη ικανότητα μάθησης και βελτιωμένη ακρίβεια (Friedman, 2002). Ο συνδυασμός αυτός πραγματοποιείται έτσι ώστε κάθε νέος αδύναμος εκπαιδευόμενος να ΕΕιδιχεύεται στη βελτίωση των προβλέψεων των προηγούμενων, δηλαδή στην ελαχιστοποίηση των προηγούμενων σφαλμάτων πρόβλεψης. Σε αυτό το πλαίσιο, ο GB μπορεί επίσης να χρησιμοποιηθεί για την ενίσχυση της απόδοσης των δέντρων ταξινόμησης και την κατασκευή ισχυρότερων ταξινομητών.

Το Extreme gradient boosting (XGBoost) είναι ίσως η πιο δημοφιλής υλοποίηση των δέντρων με ενίσχυση βαθμίδας (Chen and Guestrin, 2016). Εκμεταλλεύεται τους πόρους μνήμης και υλικού για τις μεθόδους ενίσχυσης των δέντρων, με αποτέλεσμα την ανώτερη ταχύτητα και απόδοση (Dhaliwal et al., 2018). Επίσης, η XGBoost ενσωματώνει τρεις γνωστές τεχνικές GB, δηλαδή την gradient, την regularized και την στοχαστική ενίσχυση. Σε αυτή τη μελέτη, υλοποιήσαμε το XGBoost χρησιμοποιώντας την ενίσχυση βαθμίδας (gradient boosting).

Random Forest

Το τυχαίο δάσος (Random Forest, RF) είναι μια μέθοδος ταξινόμησης MM, η οποία βασίζεται στην ανάπτυξη πολλαπλών δέντρων ταξινόμησης και στη συνεκτίμηση του πλήθους των ψήφων τους για την τελική πρόβλεψη (Breiman, 1996). Προκειμένου τα κατασκευασμένα δέντρα να εκμεταλλευτούν τα οφέλη του συνδυασμού, μειώνοντας τόσο τη μεροληψία όσο και τη διακύμανση των προβλέψεων, κάθε δέντρο ταξινόμησης εκπαιδεύεται σε διαφορετικές παρατηρήσεις και χρησιμοποιώντας διαφορετικό αριθμό χαρακτηριστικών, που επιλέγονται τυχαία από τα αρχικά διαθέσιμα. Αυτή η τεχνική, ευρέως γνωστή ως bagging, εξασφαλίζει ότι τα δέντρα που δημιουργούνται θα είναι πραγματικά διαφορετικά, έχοντας πρόσβαση σε διαφορετικές πληροφορίες και όντας λιγότερο ευαίσθητα στις αλλαγές που γίνονται στο σύνολο εκπαίδευσης.

Στον τομέα της ενέργειας και των κτιρίων, πολλές μελέτες έχουν χρησιμοποιήσει RF για την πρόβλεψη της κατανάλωσης ενέργειας σε κτίρια (Ahmad et al., 2017), την ανάπτυξη εξατομικευμένων συστημάτων κλιματισμού σε γραφεία (Li et al., 2021) και την ανίχνευση βλαβών σε δίκτυα διανομής (Chakraborty et al., 2019), μεταξύ άλλων.

Support Vector Machines

Οι μηχανές διανυσμάτων υποστήριξης (SVMs) βασίζονται στην κατασκευή ενός υπερεπιπέδου ή ενός συνόλου υπερεπιπέδων σε έναν χώρο υψηλής ή άπειρης διάστασης, οι οποίες, μεταξύ άλλων, μπορούν να χρησιμοποιηθούν για την επίλυση εργασιών ταξινόμησης δυαδικών και πολλαπλών κλάσεων (Smola and Schölkopf, 2004). Το υπερεπίπεδο με το μεγαλύτερο λειτουργικό περιθώριο (απόσταση από τα πλησιέστερα σημεία δεδομένων του συνόλου εκπαίδευσης) επιτυγχάνει χαμηλότερα σφάλματα γενίκευσης και συνεπώς παρέχει καλύτερο διαχωρισμό των δεδομένων. Σε τέτοια περιβάλλοντα, οι SVM ονομάζονται συνήθως ταξινομητές διανυσμάτων υποστήριξης (SVC) (Mathur and Foody, 2008; Bo and Xianwu, 2006).

Δεδομένων των διανυσμάτων $x_i \in \mathbb{R}^p$, $i = 1, \dots, n$ και ενός διανύσματος $y \in \{1, -1\}$, ο SVC υπολογίζει τις τιμές $w \in \mathbb{R}^p$ και $b \in \mathbb{R}$ προκειμένου να παράγει σωστές προβλέψεις για κάθε παρατήρηση χρησιμοποιώντας την τιμή του $\text{sign}(w^T \phi(x) + b)$. Το πρωταρχικό πρόβλημα που επιλύεται με SVCs μπορεί να διατυπωθεί ως εξής:

$$\begin{aligned} \min_{w,b,z} \quad & \frac{1}{2} w^T w + C \sum_{i=1}^N z_i, \\ \text{s.t.} \quad & y_i (w^T \phi(x_i) + b) \geq 1 - z_i, \\ & z_i \geq 0. \end{aligned} \tag{8.6}$$

Αυτός ο μαθηματικός τύπος περιγράφει ότι οι SVC προσπαθούν να μεγιστοποιήσουν το περιθώριο, επιβάλλοντας παράλληλα μια ποινή C για τις παρατηρήσεις που ταξινομούνται εσφαλμένα ή εμπίπτουν στο όριο του περιθωρίου. Τέλος, ο παράγοντας απόστασης z_i για κάθε διάνυσμα X_i επιτρέπει σε μια παρατήρηση να βρισκείται σε ορισμένη απόσταση από το σωστό όριο περιθωρίου, επειδή η πλειονότητα των προβλημάτων δεν διαχωρίζεται από ένα υπερεπίπεδο.

Για την ταξινόμηση πολλαπλών κλάσεων το περιβάλλον του προβλήματος SVC διαφέρει σημαντικά από την προσέγγιση της δυαδικής ταξινόμησης (Herrero-Lopez et al., 2010; Don and Iacob, 2020). Υπάρχουν δύο προσεγγίσεις που χρησιμοποιούνται για τη γενίκευση από τη δυαδική στην ταξινόμηση πολλαπλών κλάσεων. Η άμεση μέθοδος προτείνει τη γενίκευση ενός δυαδικού ταξινομητή προκειμένου να δημιουργηθούν προβλέψεις πολλαπλών κλάσεων, ενώ η πιο συνηθισμένη προσέγγιση, η έμμεση, προτείνει το συνδυασμό N ανεξάρτητων δυαδικών ταξινομητών προκειμένου να παραχθεί ένας μοναδικός πολλαπλών κλάσεων. Στην τελευταία προσέγγιση, οι δυαδικές εργασίες μπορούν να οριστούν με τη μορφή ενός πίνακα μεγέθους $M \times N$, όπου M αντιπροσωπεύει τον αριθμό των κλάσεων και N τον αριθμό των εργασιών. Οι τιμές κάθε στοιχείου του πίνακα $R_{i,j} \in \{-1, 0, 1\}$ που παράγονται από τους δυαδικούς

ταξινομητές f χρησιμοποιούνται για την πρόβλεψη της ετικέτας της κλάσης σύμφωνα με την ακόλουθη εξίσωση:

$$\hat{y} = \arg \min_{y \in \{1, \dots, n\}} \left\{ \sum_{k=1}^N R_{yk} f^k(x) \right\}. \quad (8.7)$$

8.3.3 Μοντέλο Μετα-Μάθησης

Το stacking (ή stacked) ensemble είναι ένα σχήμα που χρησιμοποιείται για την ελαχιστοποίηση του σφάλματος γενίκευσης πολλαπλών μεθόδων πρόβλεψης που εξετάζονται σε ένα σύνολο (Wolpert, 1992). Συνήθως, τα stacking ensembles χρησιμοποιούν μετα-μαθητές οι οποίοι είναι υπεύθυνοι για το συνδυασμό των προβλέψεων από πολλαπλές βασικές μεθόδους ML με βέλτιστο τρόπο ή απλά επιλέγουν την πρόβλεψη που αναμένεται να είναι η πιο ακριβής για μια συγκεκριμένη περίπτωση. Κατά συνέπεια, αυτή η προσέγγιση μπορεί να αξιολογήσει διάφορες μεθόδους με καλές επιδόσεις που εμφανίζουν διαφορετικά χαρακτηριστικά, έχουν διαφορετικές δομές και κάνουν διαφορετικές υποθέσεις για τα δεδομένα.

Η αξιοποίηση της μοντελοποίησης στοιβαγμένων συνόλων εμπνεύστηκε λόγω της χαμηλής συσχέτισης των σφαλμάτων πρόβλεψης που συνήθως πραγματοποιούνται από διαφορετικές βασικές μεθόδους. Ως αποτέλεσμα, αυτή η τεχνική είναι κατάλληλη όταν τα σφάλματα πρόβλεψης των βασικών ταξινομητών είναι ασυσχέιστα, γεγονός που σημαίνει ότι κάθε μέθοδος καταγράφει διαφορετικά χαρακτηριστικά του προβλήματος και, ως εκ τούτου, είναι πιο επιδέξια σε διαφορετικές προοπτικές. Όταν πληρούται αυτή η υπόθεση, τα σύνολα με καρφιά παράγουν ακριβέστερες προβλέψεις από οποιαδήποτε μεμονωμένη βασική μέθοδο, μειώνοντας τις μεροληψίες των μεμονωμένων μεθόδων σε σχέση με το παρεχόμενο σύνολο εκπαίδευσης.

Το μοντέλο στοιχισμένου συνόλου που αναπτύχθηκε έχει μια απλή αρχιτεκτονική, η οποία αποτελείται από δύο επίπεδα μεθόδων ταξινόμησης. Το πρώτο επίπεδο περιλαμβάνει τους πέντε βασικούς ταξινομητές που περιγράφονται στην ενότητα 8.3.2, οι οποίοι θα ονομάζονται μέθοδοι “επιπέδου-0”. Ο επιλεγμένος μετα-μαθητής, που θα ονομάζεται μέθοδος “επιπέδου-1”, είναι μια μέθοδος λογιστικής παλινδρόμησης. Η επιλογή μας βασίστηκε στην ερμηνευσιμότητα που προσφέρει αυτή η μέθοδος, παρέχοντας μια απλή αιτιολογία για τις προβλέψεις της, δηλαδή τους παράγοντες που οδήγησαν τον μετα-μαθητή να επιλέξει έναν ταξινομητή βασικής γραμμής έναντι άλλων. Αρκετές μελέτες έχουν προτείνει την αξιοποίηση σχετικά απλών ταξινομητών ως μοντέλα επιπέδου 1 για τη βέλτιστη ενσωμάτωση των προβλέψεων των βασικών μεθόδων (Chen et al., 2020; Pavlyshenko, 2018). Η συνολική αρχιτεκτονική του στοιβαγμένου μοντέλου γενίκευσης συνοψίζεται στο Σχήμα 8.2.

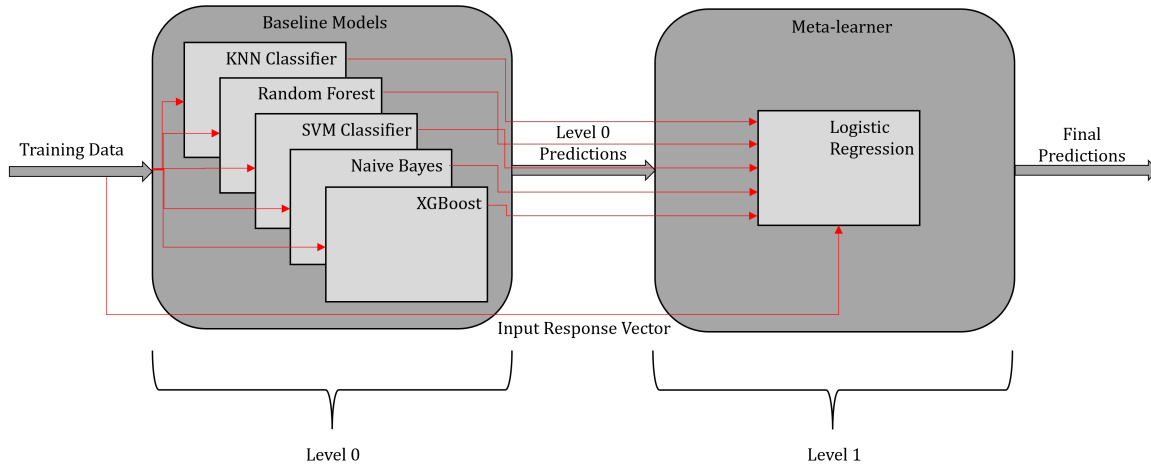
Η συνολική διαδικασία δημιουργίας του μοντέλου στοίβαξης μπορεί να χωριστεί σε τρεις φάσεις: τη δημιουργία του συνόλου, την εκπαίδευση και την πρόβλεψη σε νέα δεδομένα. Οι φάσεις αυτές περιγράφονται παρακάτω:

Phase 1 - Ensemble Set Up: Σε αυτή τη φάση, επιλέγονται οι ταξινομητές βασικής γραμμής και οι ταξινομητές μετα-μάθησης. Οι μέθοδοι βάσης θα πρέπει να ενσωματώνουν διαφορετικά χαρακτηριστικά και να προέρχονται από διαφορετική κατηγορία αλγορίθμων (π.χ. δεν θα πρέπει να περιλαμβάνουν μόνο μεθόδους που βασίζονται σε δέντρα). Ο μετα-μαθητής θα πρέπει να είναι ένας σχετικά απλός και ερμηνεύσιμος ταξινομητής.

Φάση 2 - Εκπαίδευση: Αρχικά, κάθε μία από τις βασικές μεθόδους εκπαιδεύεται χρησιμοποιώντας ένα κατάλληλο σύνολο υπερπαραμέτρων, που καθορίζονται μέσω μιας διαδικασίας διασταυρούμενης επικύρωσης (π.χ. k-fold cross-validation). Στη συνέχεια, ο μετα-μαθητής εκπαιδεύεται χρησιμοποιώντας τις προβλέψεις και τα διανύσματα εισόδου των μεθόδων επιπέδου-0 ως είσοδο και τις πραγματικές ετικέτες των παρατηρήσεων ως έξοδο.

Φάση 3 - Πρόβλεψη: Το στοιβαγμένο σύνολο χρησιμοποιείται για τη δημιουργία προβλέψεων σε δεδομένα δοκιμής. Για να γίνει αυτό, κάθε βασικός ταξινομητής χρησιμοποιείται πρώτα για να κάνει μια μεμονωμένη πρόβλεψη. Στη συνέχεια, αυτές οι προβλέψεις τροφοδοτούνται στον μετα-μαθητή για να καθορίσει, με βάση το διάνυσμα εισόδου του, ποιες προβλέψεις βασικής γραμμής θα πρέπει να χρησιμοποιηθούν.

Σχήμα 8.2: Επισκόπηση του προτεινόμενου στοιβαγμένου μοντέλου συνόλου. Οι βασικές μέθοδοι ταξινόμησης (επίπεδο-0) εκπαιδεύονται σύμφωνα με τη διαδικασία που περιγράφεται στο Σχήμα 8.1 και παρέχουν προβλέψεις για μελλοντικές επενδύσεις. Αυτές οι προβλέψεις τροφοδοτούνται στη συνέχεια στον μετα-μαθητή μαζί με τα διανύσματα εισόδου των βασικών μεθόδων. Η έξοδος του μετα-μαθητή είναι η τελική πρόβλεψη του στοιβαγμένου μοντέλου συνόλου, δηλαδή η πρόβλεψη του καταλληλότερου ταξινομητή βασικής γραμμής.



8.3.4 Σύσταση Χρηματοδότησης

Η προτεινόμενη μεθοδολογία φιλοδοξεί να παράσχει συστάσεις σχετικά με το ποσοστό της επιχορηγούμενης χρηματοδότησης που θα πρέπει να λάβουν οι μελλοντικές επενδύσεις. Εάν για τον προσδιορισμό αυτού του ποσοστού χρησιμοποιούνταν η προβλεπόμενη κλάση του μετα-μαθητή, τότε οι προτάσεις του συστήματος υποστήριξης αποφάσεων θα ήταν ουσιαστικά διακριτοί αριθμοί, που θα έπαιρναν ένα από τα τρία πιθανά ποσοστά που αντιστοιχούν σε κάθε κλάση. Για παράδειγμα, αν υποθέσουμε ότι η Κλάση *A* πρότεινε 100% χρηματοδότηση, η Κλάση *B* 50% χρηματοδότηση και η Κλάση *Γ* 0% χρηματοδότηση, τότε όλα τα έργα θα χρηματοδοτούνταν με συντελεστή $f_A = 1$, $f_B = 0.5$, ή $f_C = 0$, αντίστοιχα. Γίνεται φανερό ότι αυτή η προσέγγιση περιορίζει σημαντικά την προστιθέμενη αξία της μεθοδολογίας, αγνοώντας επίσης την αβεβαιότητα γύρω από τις προβλέψεις. Για παράδειγμα, υποθέστε ένα σενάριο όπου μια επένδυση χαρακτηρίζεται με πιθανότητα 0.55 στην Κλάση *A*, 0.35 στην Κλάση *B* και 0.10 στην Κλάση *Γ*. Χρησιμοποιώντας την προαναφερθείσα προσέγγιση, το έργο θα χρηματοδοτείτο κατά 100%, αν και υπάρχουν στοιχεία που αντιτίθενται σε αυτή την απόφαση.

Για να μετριάσουμε αυτά τα ζητήματα και να λάβουμε υπόψη την αβεβαιότητα, προτείνουμε να οικοδομήσουμε συστάσεις χρηματοδότησης με βάση την πιθανότητα κάθε κλάσης αντί της ίδιας της κυρίαρχης κλάσης, συνοψίζοντας την πιθανότητα ότι μια μελλοντική επένδυση ανήκει σε κάθε κλάση. Με δεδομένες τις μεταβλητές p_A , p_B και p_C , οι οποίες αντιπροσωπεύουν την πιθανότητα να ανήκει μια επένδυση στις κλάσεις *A*, *B* και *C*, αντίστοιχα, όπως ορίζεται από τον μετακαθαριστή, καθώς και τους συντελεστές χρηματοδότησης επιχορήγησης f_A , f_B , f_C , ο τύπος χρηματοδότησης μιας μελλοντικής επένδυσης δίνεται από την ακόλουθη εξίσωση:

$$\text{Financing Percentage} = \sum_{i \in A, B, C} f_i \times p_i. \quad (8.8)$$

Σύμφωνα με την παραπάνω εξίσωση, στο προηγούμενο παράδειγμά μας, το σύστημα υποστήριξης αποφάσεων θα συνιστούσε τη χρηματοδότηση του νέου έργου με $0,55 \times 1,00 + 0,35 \times 0,50 + 0,10 \times 0,00 = 72,5\%$, αντικατοπτρίζοντας έτσι αποτελεσματικά τις γνώσεις της προτεινόμενης μεθοδολογίας που βασίζεται στα δεδομένα.

8.4 Μελέτη Περίπτωσης

Αυτή η ενότητα παρέχει μια εκτεταμένη πειραματική εφαρμογή της προτεινόμενης μεθοδολογίας σε δεδομένα που προέρχονται από πραγματικά έργα ανακαίνισης. Περιγράφεται λεπτομερώς η διαδικασία εκπαίδευσης των πέντε βασικών μεθόδων ταξινόμησης, συμπεριλαμβανομένης της λεπτομερούς ρύθμισης των υπερπαραμέτρων τους, ακολουθούμενη από την εκπαίδευση του μοντέλου μετα-μάθησης. Τέλος, παρουσιάζονται τα αποτελέσματα της εφαρμογής.

8.4.1 Σύνολο Δεδομένων


Η πειραματική εφαρμογή της προτεινόμενης μεθοδολογίας εφαρμόστηκε σε δεδομένα που συλλέχθηκαν από το Λετονικό Περιβαλλοντικό Επενδυτικό Ταμείο (LEIF), έναν οργανισμό που ανήκει στο Υπουργείο Προστασίας του Περιβάλλοντος και Περιφερειακής Ανάπτυξης της Λετονίας και ιδρύθηκε το 1997. Ξεκινώντας από το 2009, το LEIF επέβλεψε την υλοποίηση και την παρακολούθηση μετά την υλοποίηση διαφόρων έργων που συγχρηματοδοτήθηκαν από χρηματοδοτικά μέσα για την κλιματική αλλαγή, αποτελώντας έτσι το μοναδικό ίδρυμα στη Λετονία που διαθέτει αξιόπιστα δεδομένα σχετικά με την πραγματική απόδοση διαφόρων επενδύσεων ΕΕ όσον αφορά την εξοικονόμηση ενέργειας.

Αν και η προσέγγισή μας βασίζεται στην αξιολόγηση επενδύσεων σε ένα κτίριο, πολλά από τα αρχεία που συλλέχθηκαν αφορούσαν επενδύσεις που εφαρμόστηκαν σε περισσότερα από ένα κτίρια. Ως εκ τούτου, οι εγγραφές αυτές εξαιρέθηκαν από το σύνολο των δεδομένων, συμπεριλαμβανομένου ενός τελικού δείγματος 312 έργων ΕΕ. Οι επιλεγμένες μέθοδοι MM εκπαίδευτηκαν χρησιμοποιώντας ένα τυχαία επιλεγμένο 80% του συνολικού δείγματος, δηλαδή 249 επενδύσεις, ενώ οι υπόλοιπες 63 επενδύσεις χρησιμοποιήθηκαν για τη δοκιμή της απόδοσης της μεθοδολογίας μας.

Οι προαναφερθείσες επενδύσεις ταξινομήθηκαν με τη χρήση τριών ετικετών: *Κλάση Α* που περιλαμβάνει επενδύσεις υψηλού δυναμικού, *Κλάση Β* που περιλαμβάνει επενδύσεις μεσαίου δυναμικού και *Κλάση Γ* που περιλαμβάνει επενδύσεις χαμηλού δυναμικού. Η επισήμανση των επενδύσεων βασίστηκε στην κατάταξη της αποτελεσματικότητας των επενδύσεων. Πρόκειται για μια απλή μέθοδο κατάταξης που χρησιμοποιεί δύο κριτήρια: το κόστος επένδυσης του έργου και τη μείωση της κατανάλωσης ενέργειας στο κτίριο μετά την ανακαίνιση. Τα κριτήρια αυτά συνδυάστηκαν με τα ακόλουθα βήματα: Πρώτον, οι τιμές για κάθε κριτήριο κανονικοποιήθηκαν σε μια κλίμακα (0, 1). Δεύτερον, υπολογίστηκε ο σταθμισμένος μέσος όρος των κανονικοποιημένων τιμών για όλες τις διαθέσιμες επενδύσεις. Η διαδικασία αυτή πραγματοποιήθηκε με τη χρήση ίσων βαρών για τα επιλεγμένα κριτήρια- ωστόσο, η επιλογή των συντελεστών στάθμισης μπορεί να προσαρμοστεί ανάλογα με τις προτιμήσεις του επενδυτή. Τέλος, οι τιμές κατατάχθηκαν από την καλύτερη προς τη χειρότερη. Το κορυφαίο 20% των έργων χαρακτηρίστηκε ως επένδυση Κλάσης Α, ενώ το χαμηλότερο 20% των έργων χαρακτηρίστηκε ως επένδυση Κλάσης Γ. Το υπόλοιπο 60% των επενδύσεων χαρακτηρίστηκε ως *Κλάση Β*. Η αναπαράσταση του κόστους των επενδύσεων σε σχέση με την επιτευχθείσα μείωση της κατανάλωσης ενέργειας παρουσιάζεται στο Σχήμα 8.3. Τα έργα με πράσινο χρώμα είναι επενδύσεις *Κλάση Α*, τα έργα με κίτρινο χρώμα είναι επενδύσεις *Κλάση Β*, ενώ τα έργα με κόκκινο χρώμα είναι επενδύσεις *Κλάση Γ*.

Παρατηρήστε ότι, εκ κατασκευής, το σύστημα επισήμανσης που χρησιμοποιείται οδηγεί σε ένα ανισόρροπο σύνολο εκπαίδευσης (προκατειλημμένη δειγματοληψία), με τις επενδύσεις *Κλάση Β* να έχουν μεγαλύτερη πιθανότητα να αναγνωριστούν ως η σωστή κλάση. Παρόλο που αυτό το ζήτημα μπορεί να αντιμετωπιστεί με τη χρήση τεχνικών επανδειγματοληψίας, όπως μέθοδοι που υποδειγματοληπτούν τυχαία την πλειοψηφούσα κλάση (*Class B*) ή δημιουργούν συνθετικά δεδομένα (υπερδειγματοληψία) για τις μειοψηφούσες κλάσεις (*Class A* και *Class C*; Krawczyk, 2016), ο μετα-μαθητής θα πρέπει και πάλι να είναι σε θέση να αντιμετωπίσει την ανισορροπία των κλάσεων επιλέγοντας τη βασική μέθοδο ταξινόμησης που προβλέπει καλύτερα κάθε κλάση επένδυσης. Επιπλέον, δεδομένου ότι τα ανισόρροπα σύνολα δεδομένων είναι τυπικά στην πράξη, με ορισμένες κλάσεις να παρατηρούνται φυσικά συχνότερα από άλλες,

Σχήμα 8.3: Επενδυτική σήμανση των εξεταζόμενων επενδύσεων με βάση την κατάταξη της επενδυτικής αποτελεσματικότητας.



αυτού του είδους η ανισορροπία χρησιμεύει ως ένα πρόσθετο τεστ αντοχής για την αξιολόγηση της προστιθέμενης αξίας της προτεινόμενης προσέγγισης.

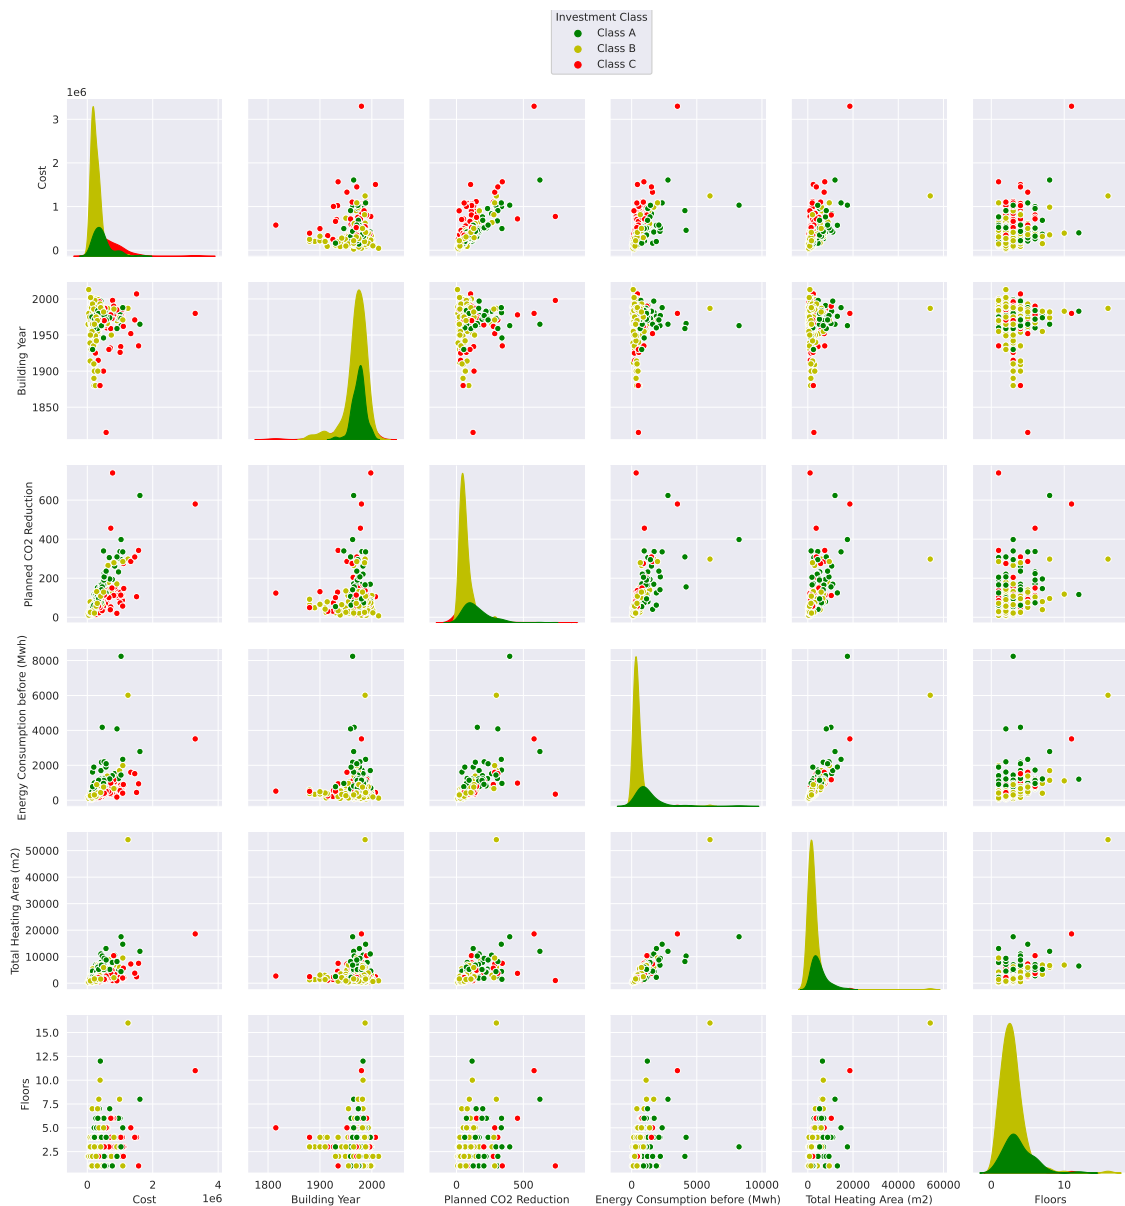
Τα επενδυτικά χαρακτηριστικά που χρησιμοποιήθηκαν στη μελέτη περιπτώσής μας εξαρτώνται εν μέρει από τη διαθεσιμότητα των δεδομένων. Στο πλαίσιο αυτό, επιλέξαμε έξι βασικά χαρακτηριστικά ως δεδομένα εισόδου στις μεθόδους ταξινόμησης, συμπεριλαμβανομένων του έτους κατασκευής του κτιρίου, της συνολικής επιφάνειας θέρμανσης (m^2), της αναμενόμενης μείωσης του CO_2 λόγω των δράσεων ανακαίνισης ($kgCO_2$), της τρέχουσας ενεργειακής κατανάλωσης του κτιρίου (MWh), του αριθμού των ορόφων του κτιρίου που θα ανακαινιστούν και του ποσού της αιτούμενης επιχορήγησης για την ανακαίνιση (€). Δεδομένου ότι όλες οι επενδύσεις πραγματοποιήθηκαν στην ίδια χώρα, δεν συμπεριλάβαμε γεωγραφικές μεταβλητές (π.χ. αναγνωριστικά της πόλης) ως πρόσθετο χαρακτηριστικό. Οι σχέσεις ανά ζεύγη μεταξύ των επιλεγμένων επενδυτικών χαρακτηριστικών παρουσιάζονται στο Σχήμα 8.4.

8.4.2 Εκπαίδευση και Ρύθμιση Υπερπαραμέτρων

Οι βέλτιστες υπερπαραμέτροι για τις πέντε βασικές μεθόδους ταξινόμησης διαμορφώθηκαν μέσω μιας διαστρωματικής διαδικασίας διασταυρούμενης επικύρωσης k-πτυχών. Ο όρος στρωματοποιημένη υποδηλώνει μια παραλλαγή της παραδοσιακής διαδικασίας διασταυρούμενης επικύρωσης k-πτυχών, όπου οι αναδιπλώσεις γίνονται διατηρώντας το ποσοστό των δειγμάτων για κάθε κλάση. Ο λόγος για τον οποίο προτιμήθηκε η στρωματοποιημένη k-fold έναντι της τυπικής αντίστοιχης διαδικασίας είναι ότι αντιμετωπίζουμε ένα έργο ταξινόμησης με ανισοβαρείς κατανομές κλάσεων, που αποτελείται από 20% Κλάση A επενδύσεις, 60% Κλάση B επενδύσεις και 20% Κλάση Γ επενδύσεις. Ο αριθμός των διαχωρισμών ορίστηκε σε 10, ενώ ο αριθμός των επαναλήψεων για τη στρωματοποιημένη k-fold ορίστηκε σε 3. Οι επιλεγμένες τιμές υπερπαραμέτρων για κάθε μέθοδο και οι συναρτήσεις που χρησιμοποιήθηκαν για την υλοποίησή τους συνοψίζονται παρακάτω.

- *k-Nearest Neighbors*: Οι πιο κρίσιμες υπερπαραμέτροι σε αυτή τη μέθοδο είναι ο αριθμός των γειτόνων που χρησιμοποιούνται για την εκτέλεση των ερωτημάτων, ο οποίος ορίζεται ίσος με 6, και η συνάρτηση βάρους που χρησιμοποιείται για την πραγματοποίηση των προβλέψεων, η οποία ορίζεται στην ομοιόμορφη. Για την υλοποίηση της μεθόδου

Σχήμα 8.4: Διάγραμμα ζεύγους των επενδυτικών μεταβλητών που εξετάζονται από τις προτεινόμενες μεθόδους ταξινόμησης στην εξεταζόμενη μελέτη περίπτωσης: Κόστος (€), Έτος κατασκευής του κτιρίου, Προγραμματισμένη μείωση CO₂ (kgCO₂), Κατανάλωση ενέργειας πριν (MWh), Συνολική επιφάνεια θέρμανσης (m²), Όροφοι



(Pedregosa et al., 2011) χρησιμοποιήθηκε η συνάρτηση *neighbors* της βιβλιοθήκης *sklearn* για την Python.

- *Gaussian Naive Bayes*: Η μέθοδος δεν απαιτεί λεπτομερή ρύθμιση των υπερ-παραμέτρων της. Για την υλοποίηση της μεθόδου χρησιμοποιήθηκε η συνάρτηση *naive_bayes* της βιβλιοθήκης *sklearn* για την Python.
- *Extreme Gradient Boosted Trees*: Η XGBoost περιλαμβάνει διάφορες υπερ-παραμέτρους οι οποίες είναι κρίσιμες για την απόδοσή της. Οι πιο σημαντικές είναι το *learning rate*, το *number of leaves* του δέντρου απόφασης, το *bagging fraction*, που επιτρέπει τη μείωση της διακύμανσης στην πρόβλεψη, και το *feature fraction*, που επιτρέπει την τυχαία επιλογή ενός υποσυνόλου χαρακτηριστικών σε κάθε επανάληψη. Έχοντας εφαρμόσει τη διαδικασία διασταυρούμενης επικύρωσης, επιλέχθηκαν οι ακόλουθες τιμές: Learning rate=0.95; maximum tree depth=10; minimum sum of

instance weight needed in a child =1; number of gradient boosted trees=1000; όλες οι άλλες υπερπαραμέτροι τέθηκαν στην προεπιλεγμένη τιμή τους. Για την υλοποίηση της μεθόδου (Chen and Guestrin, 2016) χρησιμοποιήθηκε η συνάρτηση *Classifier* της βιβλιοθήκης *XGBoost* για Python.

- *Random Forest*: Ο αριθμός των δέντρων (αριθμός εκτιμητών) στη μέθοδο RF ορίστηκε σε 500, ο παράγοντας των βαρών που σχετίζονται με τις κλάσεις ορίστηκε σε ισορροπημένο (χρησιμοποιώντας τις τιμές της μεταβλητής-στόχου για την προσαρμογή των βαρών αντιστρόφως ανάλογα με τις συχνότητες των κλάσεων στις μεταβλητές των χαρακτηριστικών) και ο μέγιστος αριθμός των χαρακτηριστικών που χρησιμοποιούνται σε κάθε επανάληψη ορίστηκε σε \log_2 . Για την υλοποίηση της μεθόδου χρησιμοποιήθηκε η συνάρτηση *ensemble* της βιβλιοθήκης *sklearn* για την Python.
- *Support Vector Machine*: Η SVM χρησιμοποίησε τον γραμμικό πυρήνα, ενώ η παράμετρος ρύθμισης *C* τέθηκε σε 1. Για την υλοποίηση της μεθόδου χρησιμοποιήθηκε η συνάρτηση *svm* της βιβλιοθήκης *sklearn* για την Python.

Μετά τη διαμόρφωση των υπερπαραμέτρων για τις βασικές μεθόδους ταξινόμησης, το τελικό βήμα της διαδικασίας εκπαίδευσης περιλαμβάνει την εκπαίδευση του μοντέλου επιπέδου 1 στο ίδιο σύνολο εκπαίδευσης. Στην παρούσα μελέτη, ο μετα-μαθητής ήταν ένας ταξινομητής λογιστικής παλινδρόμησης λόγω της απλότητας του, ο οποίος συνιστάται για τους προγνωστικούς δείκτες επιπέδου-1. Δεδομένου ότι ο επιλεγμένος μετα-μαθητής δεν έχει υπερπαραμέτρους για ρύθμιση, εκπαιδεύτηκε απευθείας στο σύνολο εκπαίδευσης επιπέδου-1, το οποίο αποτελείται από τις προβλέψεις επιπέδου-0 από τις βασικές μεθόδους και τις πραγματικές ετικέτες. Οι προβλέψεις των βασικών μεθόδων που αποτέλεσαν το σύνολο εκπαίδευσης επιπέδου-1 έγιναν μέσω μιας διαδικασίας διασταυρούμενης επικύρωσης 3 φορές στο σύνολο εκπαίδευσης.

Οι επιδόσεις των βασικών μεθόδων και του ταξινομητή στοίβαξης στη διαδικασία στρωματοποιημένης k-πτυχής επικύρωσης (10 φορές \times 3 επαναλήψεις = 30 επικυρώσεις) συνοψίζονται στον Πίνακα 8.1. Από τους βασικούς ταξινομητές, η μέθοδος SVM αναφέρει την καλύτερη απόδοση σύμφωνα με το σκορ F1, ακολουθούμενη από τις μεθόδους RF και XGBoost. Όπως αναδείχθηκε στην ενότητα 8.3, αυτό μπορεί να αποδοθεί στην ικανότητα των μεθόδων XGBoost και RF να επιλέγουν τα πιο σχετικά χαρακτηριστικά από ένα μεγάλο σύνολο επεξηγηματικών μεταβλητών, καθώς και στο γεγονός ότι οι μέθοδοι RF και SVM είναι γενικά καλύτερες στην αντιμετώπιση της τυχαιότητας των δεδομένων. Επιπλέον, διαπιστώνουμε ότι το μοντέλο στοίβαξης υπερτερεί έναντι όλων των βασικών μεθόδων σύμφωνα με τα μέτρα ακρίβειας και το σκορ F1, ενώ είναι ελαφρώς χειρότερο από το SVM όσον αφορά την ακρίβεια. Σημειώστε ότι παρόλο που οι διαφορές μεταξύ του μετα-μαθητή και του ταξινομητή SVM είναι μικρές σύμφωνα με τα μέτρα ταξινόμησης που χρησιμοποιούνται, ο πρώτος είναι πιο εύρωστος, έχοντας την τάση να ταξινομεί με μεγαλύτερη ακρίβεια τις περισσότερες επενδύσεις, αποφεύγοντας ακραία σφάλματα. Αυτό γίνεται εμφανές παρατηρώντας το Σχήμα 8.5, το οποίο παρέχει μια οπτική σύγκριση των επιδόσεων των ταξινομητών με τη μορφή box-plots. Όπως εξηγείται, η διάμεσος της βαθμολογίας F1 και των μέτρων ακρίβειας είναι υψηλότερη για τον μετα-καθαριστή σε σύγκριση με τον SVM (περισσότερες επενδύσεις ταξινομούνται σωστά), ενώ το ενδοτεταρτημοριακό εύρος της είναι σημαντικά μικρότερο (καλύτερη ευρωστία).


8.4.3 Αποτελέσματα Προβλεπτικών Μοντέλων

Μετά την εκπαίδευση του μοντέλου στοίβαξης, η απόδοση της προτεινόμενης μεθοδολογίας αξιολογείται στο σύνολο δεδομένων δοκιμής το οποίο, όπως εξηγήθηκε προηγουμένως, αποτελείται από 63 τυχαία επιλεγμένες επενδύσεις EE. Τα αποτελέσματα αυτής της εφαρμογής συνοψίζονται στον πίνακα σύγκρισης του Σχήματος 8.6, όπου παρουσιάζεται ο αριθμός των περιπτώσεων που ο μετα-μαθητής προέβλεψε κάθε κλάση σε σύγκριση με τις πραγματικές τους ετικέτες. Παρατηρούμε ότι 32 από τις 36 Κλάση B επενδύσεις (88.8%) έχουν προβλεφθεί σωστά. Για την Κλάση A, ο αντίστοιχος αριθμός είναι 10 στις 14 (71.4%),

Classifier	Accuracy	Precision	F1 Score
k-Nearest Neighbors	0.77 (0.08)	0.78 (0.10)	0.74 (0.09)
Gaussian naive Bayes	0.70 (0.10)	0.66 (0.14)	0.67 (0.12)
XGBoost	0.78 (0.10)	0.79 (0.10)	0.78 (0.10)
Random Forest	0.80 (0.09)	0.82 (0.08)	0.79 (0.09)
Support Vector Machine	0.82 (0.09)	0.85 (0.07)	0.82 (0.09)
Stacking Model	0.83 (0.09)	0.84 (0.09)	0.83 (0.09)

Πίνακας 8.1: Απόδοση ταξινόμησης (μέσος όρος και τυπική απόκλιση) των βασικών μεθόδων και του μοντέλου στοίβαξης στη διαδικασία στρωματοποιημένης 10πλής επικύρωσης. Οι καλύτερες τιμές ανά στήλη εμφανίζονται με έντονη γραφή.

Σχήμα 8.5: Σύγκριση των βασικών ταξινομητών και της στοίβαξης στη διαδικασία στρωματοποιημένης 10πλής επικύρωσης. Στο αριστερό υπο-σχήμα φαίνεται το F1 score των ταξινομητών, ενώ στο δεξί η ακρίβειά τους.




ενώ για την Κλάση Γ , 7 στις 13 (53.2%). Είναι ενδιαφέρον ότι ο ταξινομητής δεν προέβλεψε ποτέ την επένδυση Κλάση A ως Κλάση Γ ή το αντίθετο. Αυτό το εύρημα είναι ιδιαίτερα ενδιαφέρον, υποδηλώνοντας ότι ο κίνδυνος χρήσης του προτεινόμενου μετα-μαθητή για τη σύσταση χρηματοδότησης (ή μη χρηματοδότησης) μιας επένδυσης χαμηλής (ή υψηλής) δυναμικής είναι ασήμαντος.

Η απόδοση ταξινόμησης του μετα-μαθητή συνοψίζεται στον Πίνακα 8.2. Αυτός περιλαμβάνει την ακρίβεια, την ανάκληση και τη βαθμολογία F1 για κάθε κλάση, καθώς και τον μακροσκοπικό και τον σταθμισμένο μέσο όρο. Ο μακρομέσος όρος είναι ο απλός αριθμητικός μέσος όρος κάθε μέτρου σε όλες τις κλάσεις. Δεδομένου ότι αυτό το μέτρο αποδίδει ίσα βάρη σε όλες τις κλάσεις, είναι κατάλληλο για ισορροπημένες εργασίες ταξινόμησης. Αντίθετα, ο σταθμισμένος μέσος όρος ενσωματώνει την ανισορροπία των κλάσεων, υπολογίζοντας το μέσο όρο των δυαδικών μέτρων λαμβάνοντας υπόψη τον αριθμό των δειγμάτων κάθε κλάσης στο στόχο. Επομένως, ο σταθμισμένος μέσος όρος είναι καταλληλότερος για τη σύνοψη της απόδοσης του μετα-μαθητή στην παρούσα μελέτη περίπτωσης.

Είναι προφανές ότι το μοντέλο αποδίδει ελαφρώς καλύτερα με τις επενδύσεις *Class B*, δηλαδή την πιο δημοφιλή κλάση, με αποτέλεσμα 0,76 ακρίβεια και 0,82 βαθμολογία F1. Οι αντίστοιχες τιμές για την *Class A* είναι 0,83 και 0,77, ενώ για την *Class C* 0,78 και 0,64. Επομένως, διαπιστώνουμε ότι είναι εξαιρετικά απίθανο ο μετα-μαθητής να μην αναγνωρίσει σωστά τις επενδύσεις Κλάση A και Κλάση B όταν υπάρχουν, σε αντίθεση με τις επενδύσεις Κλάση Γ όπου είναι πιθανό ο μετα-μαθητής να τις κατατάξει ως Κλάση B . Ως αποτέλεσμα, μπορούμε να συμπεράνουμε ότι ο μετα-μαθητής μπορεί να χρησιμοποιηθεί αποτελεσματικά στην πράξη για τον εντοπισμό επενδύσεων υψηλού και μεσαίου δυναμικού και την υποστήριξη της χρηματοδότησης έργων ΕΕ μεγάλης κλίμακας. Αυτό επιβεβαιώνεται από τη συνολική

Σχήμα 8.6: Πίνακας σύγχυσης για το μοντέλο στοίβαξης στο σύνολο δοκιμών.



ακρίβεια του μοντέλου, η οποία είναι 0,78 σε όλες τις κλάσεις. Παρατηρήστε επίσης ότι, παρόλο που το σύνολο δεδομένων που χρησιμοποιήθηκε για την εκπαίδευση των βασικών μεθόδων ταξινόμησης ήταν ανισοβαρές, τα αποτελέσματα ανάκλησης που αναφέρονται στον Πίνακα 8.2 υποδηλώνουν ότι ο μετα-μαθητής έχει αντιμετωπίσει αποτελεσματικά αυτό το ζήτημα, παρέχοντας αμερόληπτες προβλέψεις, ειδικά όταν πρόκειται για την πρόβλεψη επενδύσεων Κλάση A και Κλάση B.

	Precision	Recall	F1 Score
<i>Class A</i>	0.83	0.71	0.77
<i>Class B</i>	0.76	0.89	0.82
<i>Class C</i>	0.78	0.54	0.64
Macro Average	0.79	0.71	0.74
Weighted Average	0.78	0.78	0.77

Πίνακας 8.2: Απόδοση ταξινόμησης του μοντέλου στοίβαξης στο σύνολο δοκιμών.

Δεδομένου ότι το μέτρο ακρίβειας δεν ενσωματώνει την ανισορροπία των κλάσεων, η οποία είναι ένας πολύ σημαντικός παράγοντας για αυτό το πρόβλημα (60% των παρατηρήσεων ανήκουν στην ίδια κλάση), αξιοποιούμε τον συντελεστή kappa του Cohen (κ). Ο συντελεστής αυτός είναι ένας στατιστικός δείκτης που χρησιμοποιείται για τη μέτρηση της αξιοπιστίας μεταξύ των κριτών για κατηγορικά δεδομένα, αποτελώντας ένα πιο αξιόπιστο μέτρο από τον απλό υπολογισμό της ποσοστιαίας συμφωνίας, λόγω της παραμέτρου κ που ενσωματώνει την πιθανότητα η συμφωνία να προκύψει τυχαία. Ο τύπος για τον συντελεστή kappa του Cohen δίνεται ως εξής:


$$\kappa = \frac{p_0 - p_e}{1 - p_e}, \tag{8.9}$$

όπου p_0 περιγράφεται ως η παρατηρούμενη αναλογική συμφωνία μεταξύ πραγματικών και προβλεπόμενων τιμών και p_e είναι η αναμενόμενη συμφωνία όταν και οι δύο σχολιαστές αναθέτουν ετικέτες τυχαία. Το σκορ kappa του Cohen για το σύνολο δοκιμών είναι 0,594, το οποίο δηλώνει σημαντική συμφωνία για τον ταξινομητή στοίβαξης.

Ωστόσο, η προτεινόμενη μεθοδολογία βασίζεται σε ταξινομητές που μπορούν να παράγουν πιθανότητες συμμετοχής σε κλάσεις. Ως εκ τούτου, οι προαναφερθείσες μετρικές αποτυγχάνουν να περιγράψουν τη συνολική εικόνα. Η ικανότητα του μοντέλου να διακρίνει μια

περίπτωση μεταξύ κάθε κλάσης μπορεί να περιγραφεί από την περιοχή κάτω από τη χαρακτηριστική καμπύλη λειτουργίας δέκτη (ROC AUC). Η ROC AUC υπολογίζεται, δημιουργώντας προβλέψεις για ένα εύρος τιμών κατωφλίου απόφασης $[0, 1]$. Για κάθε τιμή υπολογίζονται το ποσοστό αληθώς θετικών αποτελεσμάτων (TPR) -γνωστό και ως ανάκληση- και το ποσοστό ψευδώς θετικών αποτελεσμάτων (FPR). Στην περίπτωση ταξινόμησης πολλαπλών κλάσεων, το μέτρο υπολογίζεται ξεχωριστά για κάθε κλάση ακολουθώντας τη στρατηγική ταξινόμησης one-vs-rest (OVR), υποθέτοντας έναν διαφορετικό ταξινομητή ανά κλάση. Η καμπύλη ROC για κάθε κλάση παρουσιάζεται στο Σχήμα 8.7. Μια μεγάλη περιοχή στην AUC ROC σημαίνει ότι υπάρχει μεγάλη διάκριση μεταξύ των κλάσεων. Η τιμή της περιοχής κάτω από την καμπύλη ROC για τον ταξινομητή στοίβαξης συνολικά είναι 0,883, η οποία είναι μια καλή βαθμολογία, δεδομένου ότι οι τιμές AUC κυμαίνονται μεταξύ 0,5 και 1 (όπου 0,5 δηλώνει έναν κακό ταξινομητή και 1 δηλώνει έναν εξαιρετικό ταξινομητή).

Σχήμα 8.7: Καμπύλη ROC για τις τρεις κλάσεις με βάση τις παραγόμενες πιθανοτικές προβλέψεις του ταξινομητή στοίβαξης.



8.5 Συμπεράσματα

Η παρούσα μελέτη επικεντρώνεται στο πρόβλημα της αξιολόγησης του δυναμικού των μελλοντικών επενδύσεων ΕΕ όσον αφορά το κόστος ανακαίνισης και την πραγματοποιημένη εξοικονόμηση ενέργειας. Δεδομένης της έλλειψης ώριμων πληροφοριακών συστημάτων για την υποστήριξη τέτοιων εκτιμήσεων, αρκετά έργα ανακαίνισης παραπαίουν σήμερα να λάβουν οικονομική στήριξη από τα χρηματοδοτικά ιδρύματα, θέτοντας έτσι σε κίνδυνο τους παγκόσμιους περιβαλλοντικούς στόχους που έχουν τεθεί για τις επόμενες δεκαετίες. Στο πλαίσιο αυτό, προτείνεται μια μεθοδολογία βασισμένη σε δεδομένα, η οποία φιλοδοξεί να ανοίξει το δρόμο προς τον ακριβή εντοπισμό ελκυστικών έργων ΕΕ και τον προσδιορισμό των κεφαλαίων που πρέπει να επενδυθούν ανά περίπτωση. Για να γίνει αυτό, εξετάζονται κρίσιμα επενδυτικά χαρακτηριστικά έργων που έχουν ολοκληρωθεί στο παρελθόν και χρησιμοποιούνται μέθοδοι MM για να μάθουμε από τις επιτυχίες και τα λάθη τους. Η συνιστώμενη προσέγγιση αποσκοπεί στην ενίσχυση των διαδικασιών χρηματοδότησης της ΕΕ και στη διευκόλυνση των διαφόρων τύπων ενδιαφερομένων (χρηματοδότες, τραπεζίτες, επενδυτές κ.λπ.) στη σύγκριση και την επισήμανση έργων ΕΕ με τυποποιημένο και λιγότερο αβέβαιο τρόπο.

Η προτεινόμενη μεθοδολογία περιλαμβάνει ένα μοντέλο συνόλου στοίβαξης που βασίζεται σε διάφορες βασικές μεθόδους ταξινόμησης MM με στόχο την περαιτέρω βελτίωση των επιδόσεών τους. Δεδομένα που περιέχουν σημαντικά χαρακτηριστικά των επενδύσεων ΕΕ (π.χ. ηλικία κτιρίου και συνολική επιφάνεια θέρμανσης, αναμενόμενες εκπομπές CO₂ και

κόστος ανακαίνισης) συλλέγονται και χρησιμοποιούνται για την εκπαίδευση του μοντέλου ταξινόμησης. Η μεθοδολογία αξιολογείται λαμβάνοντας υπόψη μια πραγματική μελέτη περίπτωσης στη Λετονία. Τα αποτελέσματά μας δείχνουν ότι το μοντέλο συνόλου στοιβαξής υπερτερεί έναντι όλων των βασικών μεθόδων ταξινόμησης MM που εξετάστηκαν, επιτυγχάνοντας υψηλή ακρίβεια όταν χρησιμοποιείται για την αξιολόγηση μελλοντικών επενδύσεων ΕΕ. Επιπλέον, διαπιστώνουμε ότι το προτεινόμενο μοντέλο μπορεί να εντοπίσει αποτελεσματικά έργα υψηλών και μεσαίων επενδύσεων, όντας επίσης εξαιρετικό στη διάκριση των έργων χαμηλού και υψηλού δυναμικού. Το εύρημα αυτό δείχνει ότι οι ενδιαφερόμενοι μπορούν να αξιοποιήσουν την παρουσιαζόμενη μεθοδολογία για να μειώσουν τον κίνδυνο των επενδύσεών τους και να μεγιστοποιήσουν τις αποδόσεις τους.

Δεδομένων των περιορισμών της παρούσας μελέτης, οι μελλοντικές εργασίες στον τομέα της αξιολόγησης των επενδύσεων ΕΕ θα πρέπει να επικεντρωθούν στην ενσωμάτωση άλλων τύπων επενδύσεων που προέρχονται από τον τομέα της μεταποίησης, των μεταφορών και του υπαίθριου φωτισμού, διευρύνοντας έτσι τα έργα που εξετάζονται από τη μεθοδολογία και αυξάνοντας το οικονομικό και περιβαλλοντικό δυναμικό της. Το μοντέλο μετα-μάθησης που αναπτύχθηκε μπορεί να γενικευτεί για τέτοιες εφαρμογές, υπό την προϋπόθεση ότι είναι διαθέσιμα επαρκή δεδομένα για την υποστήριξη της διαδικασίας μάθησής του. Ένα άλλο σημείο ενδιαφέροντος που θα μπορούσε να διερευνηθεί περαιτέρω είναι ο τρόπος με τον οποίο η γεωγραφική τοπολογία των επενδύσεων επηρεάζει την αποτελεσματικότητά τους όσον αφορά την εξοικονόμηση ενέργειας. Εν προκειμένω, οι επενδύσεις ΕΕ που υλοποιούνται σε πολλές χώρες με διάφορα χαρακτηριστικά θα μπορούσαν να ενσωματωθούν στο μοντέλο, θέτοντας ορισμένες πρόσθετες γεωγραφικές και κλιματικές μεταβλητές για τη γενίκευση της χρήσης του και τη διεύρυνση του τύπου των ενδιαφερομένων μερών που θα ενδιαφέρονταν για τη χρήση του. Θα μπορούσαν επίσης να εξεταστούν εναλλακτικά μέτρα σε σχέση με τα εξεταζόμενα για την αξιολόγηση του δυναμικού των μελλοντικών έργων ΕΕ, ώστε οι προβλέψεις της προτεινόμενης μεθόδου να αντικατοπτρίζουν καλύτερα την πραγματική κατάσταση. Ακόμη πιο σημαντικό, και προκειμένου η προτεινόμενη προσέγγιση να γίνει πιο σχετική για εφαρμογές μεγάλης κλίμακας, θα πρέπει να προσδιοριστούν εναλλακτικοί τρόποι για την ανάκτηση των δεδομένων που σχετίζονται με την ενέργεια και τις επενδύσεις και απαιτούνται για την εκπαίδευση των ταξινομητών, συμπεριλαμβανομένων πηγών δεδομένων στις οποίες έχουν εύκολη πρόσβαση οι δημόσιες αρχές και τα χρηματοπιστωτικά ιδρύματα. Για παράδειγμα, μια εναλλακτική λύση θα ήταν η αξιοποίηση των πληροφοριών που παρέχουν τα ενεργειακά πιστοποιητικά των ανακαινισμένων κτιρίων, δηλαδή η παρακολούθηση της ΕΕ πολλών κτιρίων πριν και μετά την πραγματοποίηση συγκεκριμένων ανακαινίσεων, καθώς και του κόστους αυτών των ανακαινίσεων. Αυτού του είδους οι πληροφορίες είναι τυποποιημένες, ερμηνεύσιμες και μπορούν ευκολότερα να μοιραστούν με τα ενδιαφερόμενα μέρη, διευκολύνοντας έτσι την αξιοποίηση της προτεινόμενης μεθόδου αξιολόγησης σε ευρύτερη κλίμακα.

Βιβλιογραφία

- Abdou, N., Mghouchi, Y. E., Hamdaoui, S., Asri, N. E., and Mouqallid, M. (2021). Multi-objective optimization of passive energy efficiency measures for net-zero energy building in morocco. *Building and Environment*, 204:108141.
- Abreu, M. I., de Oliveira, R. A., and Lopes, J. (2020). Younger vs. older homeowners in building energy-related renovations: Learning from the portuguese case. *Energy Reports*, 6:159–164.
- Ahmad, M. W., Mourshed, M., and Rezgui, Y. (2017). Trees vs neurons: Comparison between random forest and ann for high-resolution prediction of building energy consumption. *Energy and Buildings*, 147:77–89.
- Arsenopoulos, A., Sarmas, E., Stavrakaki, A., Giannouli, I., and Psarras, J. (2021). A data-driven decision support tool at the service of energy suppliers and utilities for tackling energy poverty: A case study in greece. In *2021 12th International Conference on Information, Intelligence, Systems & Applications (IISA)*, pages 1–6. IEEE.
- Bayindir, R., Yesilbudak, M., Colak, M., and Genc, N. (2017). A novel application of naive bayes classifier in photovoltaic energy prediction. In *2017 16th IEEE international conference on machine learning and applications (ICMLA)*, pages 523–527. IEEE.
- Bo, G. and Xianwu, H. (2006). Svm multi-class classification. *Journal of Data Acquisition & Processing*, 21(3):334–339.
- Boon, F. P. and Dieperink, C. (2014). Local civil society based renewable energy organisations in the netherlands: Exploring the factors that stimulate their emergence and development. *Energy Policy*, 69:297–307.
- Breiman, L. (1993). *Classification and Regression Trees*. Boca Raton, FL: Chapman & Hall.
- Breiman, L. (1996). Bagging predictors. *Machine learning*, 24(2):123–140.
- Chakraborty, D., Sur, U., and Banerjee, P. K. (2019). Random forest based fault classification technique for active power system networks. In *2019 IEEE International WIE Conference on Electrical and Computer Engineering (WIECON-ECE)*, pages 1–4. IEEE.
- Chen, T. and Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pages 785–794.
- Chen, Z., Zhao, P., Li, F., Marquez-Lago, T. T., Leier, A., Revote, J., Zhu, Y., Powell, D. R., Akutsu, T., Webb, G. I., et al. (2020). ilearn: an integrated platform and meta-learner for feature engineering, machine-learning analysis and modeling of dna, rna and protein sequence data. *Briefings in bioinformatics*, 21(3):1047–1057.
- Chia-Cheng, C., Liu, Y., and Hsu, T.-H. (2019). An analysis on investment performance of machine learning: an empirical examination on taiwan stock market. *International Journal of Economics and Financial Issues*, 9(4):1.
- Cover, T. and Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1):21–27.

- de Vasconcelos, A. B., Pinheiro, M. D., Manso, A., and Cabaço, A. (2016). Epcbd cost-optimal methodology: Application to the thermal rehabilitation of the building envelope of a portuguese residential reference building. *Energy and Buildings*, 111:12–25.
- Debrah, C., Chan, A. P. C., and Darko, A. (2021). Green finance gap in green buildings: A scoping review and future research needs. *Building and Environment*, page 108443.
- Dhaliwal, S. S., Nahid, A.-A., and Abbas, R. (2018). Effective intrusion detection system using xgboost. *Information*, 9(7):149.
- Don, D. R. and Iacob, I. E. (2020). Dcsvm: fast multi-class classification using support vector machines. *International Journal of Machine Learning and Cybernetics*, 11(2):433–447.
- Doukas, H. (2018). On the appraisal of “triple-a” energy efficiency investments. *Energy Sources, Part B: Economics, Planning, and Policy*, 13(7):320–327.
- Doukas, H., Nikas, A., González-Eguino, M., Arto, I., and Anger-Kraavi, A. (2018). From integrated to integrative: Delivering on the paris agreement. *Sustainability*, 10(7):2299.
- Doukas, H., Xidonas, P., and Mastromichalakis, N. (2021). How successful are energy efficiency investments? a comparative analysis for classification & performance prediction. *Computational Economics*, pages 1–20.
- Foda, E., El-Hamalawi, A., and Le Dréau, J. (2020). Computational analysis of energy and cost efficient retrofitting measures for the french house. *Building and Environment*, 175:106792.
- Forouli, A., Gkonis, N., Nikas, A., Siskos, E., Doukas, H., and Tourkolias, C. (2019). Energy efficiency promotion in greece in light of risk: Evaluating policies as portfolio assets. *Energy*, 170:818–831.
- Friedman, J. H. (2002). Stochastic gradient boosting. *Computational statistics & data analysis*, 38(4):367–378.
- Ghoddusi, H., Creamer, G. G., and Rafizadeh, N. (2019). Machine learning in energy economics and finance: A review. *Energy Economics*, 81:709–727.
- Hayes, S., Nadel, S., Granda, C., and Hottel, K. (2011). What have we learned from energy efficiency financing programs. In *American Council for an Energy-Efficient Economy*.
- Herrero-Lopez, S., Williams, J. R., and Sanchez, A. (2010). Parallel multiclass classification using svms on gpu. In *Proceedings of the 3rd Workshop on general-purpose computation on graphics processing units*, pages 2–11.
- IEA (2009). Implementing Energy Efficiency Policies: are IEA Member Countries on Track? <https://www.oecd.org/publications/implementing-energy-efficiency-policies-are-iea-member-countries-on-track-9789264075691.htm>.
- IEA (2021). Net Zero by 2050: A Roadmap for the Global Energy Sector. <https://iea.blob.core.windows.net/assets/4719e321-6d3d-41a2-bd6b-461ad2f850a8/NetZeroBy2050-ARoadmapfortheGlobalEnergySector.pdf>.
- Intrachooto, S. and Horayangkura, V. (2007). Energy efficient innovation: Overcoming financial barriers. *Building and Environment*, 42(2):599–604.

- IRENA (2015). Renewable Energy Statistics. <https://www.irena.org/publications/2015/Jun/Renewable-Energy-Target-Setting>.
- Jahromi, A. H. and Taheri, M. (2017). A non-parametric mixture of gaussian naive bayes classifiers based on local independent features. In *2017 Artificial Intelligence and Signal Processing Conference (AISP)*, pages 209–212. IEEE.
- Jensen, P. A. and Maslesa, E. (2015). Value based building renovation—a tool for decision-making and evaluation. *Building and Environment*, 92:1–9.
- Jensen, P. A., Maslesa, E., Berg, J. B., and Thuesen, C. (2018). 10 questions concerning sustainable building renovation. *Building and Environment*, 143:130–137.
- Kalkbrenner, B. J. and Roosen, J. (2016). Citizens’ willingness to participate in local renewable energy projects: The role of community and trust in germany. *Energy Research & Social Science*, 13:60–70.
- Krawczyk, B. (2016). Learning from imbalanced data: open challenges and future directions. *Progress in Artificial Intelligence*, 5(4):221–232.
- Lee, J. Y. and Styczynski, M. P. (2018). Ns-knn: a modified k-nearest neighbors approach for imputing metabolomics data. *Metabolomics*, 14(12):1–12.
- Li, Q. Y., Han, J., and Lu, L. (2021). A random forest classification algorithm based personal thermal sensation model for personalized conditioning system in office buildings. *The Computer Journal*, 64(3):500–508.
- Loureiro, T., Gil, M., Desmaris, R., Andaloro, A., Karakosta, C., and Plesser, S. (2020). De-risking energy efficiency investments through innovation. In *Multidisciplinary Digital Publishing Institute Proceedings*, volume 65, page 3.
- Makridakis, S., Spiliotis, E., and Assimakopoulos, V. (2018). Statistical and machine learning forecasting methods: Concerns and ways forward. *PLOS ONE*, 13(3):1–26.
- Marinakis, V. (2020). Big data for energy management and energy-efficient buildings. *Energies*, 13(7):1555.
- Mathur, A. and Foody, G. M. (2008). Multiclass and binary svm classification: Implications for training and classification users. *IEEE Geoscience and remote sensing letters*, 5(2):241–245.
- Mena, D., Montañés, E., Quevedo, J. R., and del Coz, J. J. (2016). An overview of inference methods in probabilistic classifier chains for multilabel classification. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 6(6):215–230.
- Mexis, F. D., Papapostolou, A., Karakosta, C., Sarmas, E., Koutsandreas, D., and Doukas, H. (2021). Leveraging energy efficiency investments: An innovative web-based benchmarking tool. *Advances in Science, Technology and Engineering Systems Journal*, 6:237–248.
- Morrissey, J., Meyrick, B., Sivaraman, D., Horne, R., and Berry, M. (2013). Cost-benefit assessment of energy efficiency investments: Accounting for future resources, savings and risks in the australian residential sector. *Energy Policy*, 54:148–159.
- Norouzi, M., Fleet, D. J., and Salakhutdinov, R. R. (2012). Hamming distance metric learning. In *Advances in neural information processing systems*, pages 1061–1069.

- Ortiz, J., i Casas, A. F., Salom, J., Soriano, N. G., and i Casas, P. F. (2016). Cost-effective analysis for selecting energy efficiency measures for refurbishment of residential buildings in catalonia. *Energy and Buildings*, 128:442–457.
- Painuly, J. P. (2001). Barriers to renewable energy penetration; a framework for analysis. *Renewable energy*, 24(1):73–89.
- Painuly, J. P., Park, H., Lee, M.-K., and Noh, J. (2003). Promoting energy efficiency financing and escos in developing countries: mechanisms and barriers. *Journal of Cleaner Production*, 11(6):659–665.
- Papapostolou, A., Mexis, F. D., Sarmas, E., Karakosta, C., and Psarras, J. (2020). Web-based application for screening energy efficiency investments: A mcda approach. In *2020 11th International Conference on Information, Intelligence, Systems and Applications (IISA)*, pages 1–7. IEEE.
- Pavlyshenko, B. (2018). Using stacking approaches for machine learning models. In *2018 IEEE Second International Conference on Data Stream Mining & Processing (DSMP)*, pages 255–258. IEEE.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.
- Prasetyo, B., Muslim, M., et al. (2019). Analysis of building energy efficiency dataset using naive bayes classification classifier. In *Journal of Physics: Conference Series*, volume 1321, page 032016. IOP Publishing.
- Sarkar, A. and Singh, J. (2010). Financing energy efficiency in developing countries—lessons learned and remaining challenges. *Energy Policy*, 38(10):5560–5571.
- Sarmas, E., Xidonas, P., and Doukas, H. (2020). *Multicriteria Portfolio Construction with Python*. Springer.
- Sarrica, M., Brondi, S., Cottone, P., and Mazzara, B. M. (2016). One, no one, one hundred thousand energy transitions in europe: The quest for a cultural approach. *Energy Research & Social Science*, 13:1–14.
- Smola, A. J. and Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14(3):199–222.
- Stocker, E., Tschurtschenthaler, M., and Schrott, L. (2015). Cost-optimal renovation and energy performance: Evidence from existing school buildings in the alps. *Energy and Buildings*, 100:20–26.
- Syarif, I., Zaluska, E., Prugel-Bennett, A., and Wills, G. (2012). Application of bagging, boosting and stacking to intrusion detection. In *International Workshop on Machine Learning and Data Mining in Pattern Recognition*, pages 593–602. Springer.
- Taylor, P. G., d’Ortigue, O. L., Francoeur, M., and Trudeau, N. (2010). Final energy use in iea countries: The role of energy efficiency. *Energy Policy*, 38(11):6463–6474.
- Taylor, R. P., Govindarajalu, C., Levin, J., Meyer, A. S., and Ward, W. A. (2008). *Financing energy efficiency: lessons from Brazil, China, India, and beyond*. World Bank Publications.

- Thøgersen, J. and Grønhøj, A. (2010). Electricity saving in households—a social cognitive approach. *Energy policy*, 38(12):7732–7743.
- Toussaint, G. (2005). Geometric proximity graphs for improving nearest neighbor methods in instance-based learning and data mining. *International Journal of Computational Geometry & Applications*, 15(02):101–150.
- Tuominen, P., Reda, F., Dawoud, W., Elboshy, B., Elshafei, G., and Negm, A. (2015). Economic appraisal of energy efficiency in buildings using cost-effectiveness assessment. *Procedia Economics and Finance*, 21:422–430.
- Wolpert, D. H. (1992). Stacked generalization. *Neural networks*, 5(2):241–259.
- Zekić-Sušac, M., Mitrović, S., and Has, A. (2021). Machine learning based system for managing energy efficiency of public sector as an approach towards smart cities. *International journal of information management*, 58:102074.
- Zhang, D., Zhang, Z., and Managi, S. (2019). A bibliometric analysis on green finance: Current status, development, and future directions. *Finance Research Letters*, 29:425–430.
- Zhang, H. (2004). The optimality of naive bayes. *AA*, 1(2):3.

Κεφάλαιο 9

Μοντέλο Βελτιστοποίησης Προγραμματισμού Αντλιών Ύδρευσης για την Εξομάλυνση Αιχμών Φορτίου

9.1 Εισαγωγή

Στο κεφάλαιο αυτό παρουσιάζεται μια ολοκληρωμένη μέθοδος για την έξυπνη διαχείριση της ενέργειας με στόχο την εξομάλυνση της κατανάλωσης ηλεκτρικής ενέργειας σε απομακρυσμένα νησιωτικά συστήματα. Η καινοτόμος μέθοδος βασίζεται σε δύο πυλώνες: την ανάπτυξη ενός συνόλου μοντέλων MM, που χρησιμοποιούνται για την ακριβή πρόβλεψη της παραγωγής ΑΠΕ και της κατανάλωσης ηλεκτρικής ενέργειας, και τον σχεδιασμό ενός αλγορίθμου χρονοπρογραμματισμού που μετατοπίζει με βέλτιστο τρόπο τις ώρες λειτουργίας των αντλιοστασίων ύδρευσης προς διαστήματα χαμηλού αναμενόμενου φορτίου.

Η ορθή λειτουργία των συστημάτων ύδρευσης συνδέεται άμεσα με τη διασφάλιση της προσβασιμότητας του πληθυσμού στο νερό. Το νερό και η ενέργεια αποτελούν δύο από τους πιο ζωτικούς πόρους και η ολοκληρωμένη διαχείρισή τους μπορεί να προσφέρει σημαντικά πολυποίικα οικονομικά και περιβαλλοντικά οφέλη και στους δύο τομείς. Στο πλαίσιο αυτό, οι Στόχοι Βιώσιμης Ανάπτυξης των Ηνωμένων Εθνών, και ιδίως οι Στόχοι 6 και 11, έχουν εντοπίσει το πρόβλημα της διασφάλισης της διαθεσιμότητας και της βιώσιμης διαχείρισης του νερού για όλους, αντιμετωπίζοντας συγκεκριμένες δράσεις για την εξασφάλιση της πρόσβασης σε ασφαλές νερό και εστιάζοντας στη βελτίωση της αποδοτικότητας των πόρων (UN, 2015). Στόχος είναι η εφαρμογή ενός ολοκληρωμένου συστήματος διαχείρισης των υδάτινων πόρων για την υποστήριξη και την ενίσχυση της συμμετοχής των τοπικών κοινοτήτων στη βελτίωση της διαχείρισης των υδάτων έως το 2030. Από το 2014, η ετήσια κατανάλωση ενέργειας στον τομέα των υδάτων αντιστοιχούσε σε περίπου 120 Mtoe, παγκοσμίως. Το μεγαλύτερο μέρος της κατανάλωσης ενέργειας απορροφάται με τη μορφή ηλεκτρικής ενέργειας, η οποία αντιστοιχεί σε περίπου 4% της συνολικής παγκόσμιας κατανάλωσης ηλεκτρικής ενέργειας (Luna et al., 2019). Σύμφωνα με την Carns (2005), η κατανάλωση ενέργειας με τη μορφή ηλεκτρισμού απαιτείται για διάφορες διεργασίες στα συστήματα ύδρευσης, καθώς είναι απαραίτητη κυρίως για την άντληση, τη διήθηση του νερού, την κροκίδωση και την τροφοδοσία του πηκτικού και του χλωρίου. Η ζήτηση νερού αναμένεται να αυξηθεί κατά 44% έως το 2050 λόγω της ανάπτυξης των τομέων της μεταποίησης, της παραγωγής θερμικής ενέργειας, της γεωργίας και των κατοικιών. Σύμφωνα με την έκθεση Water-Energy Nexus του Διεθνούς Οργανισμού Ενέργειας, η διαθεσιμότητα του νερού καθίσταται επίσης ζήτημα μεγάλης σημασίας λόγω της οικονομικής και πληθυσμιακής ανάπτυξης, καθώς και της κλιματικής αλλαγής, ιδίως για τις αναδυόμενες οικονομίες, εντείνοντας την αλληλεξάρτηση του νερού και της ενέργειας τις επόμενες δεκαετίες (IEA, 2016).

Οι εταιρείες ύδρευσης και οι δήμοι γενικότερα στοχεύουν να εγγυηθούν την ασφάλεια της υδροδότησης, μειώνοντας παράλληλα την κατανάλωση ενέργειας και το λειτουργικό κόστος, καθώς και τις περιβαλλοντικές επιπτώσεις που συνδέονται με την όλη διαδικασία (Papapostolou et al., 2018). Έχουν ήδη υλοποιηθεί διάφορες δράσεις για τη βελτίωση της βιωσιμότητας του τομέα του νερού (Papapostolou et al., 2020), συμπεριλαμβανομένων των ΑΠΕ, μεταξύ άλλων, με στόχο να συμβάλουν στην αποκέντρωση και τη διαφοροποίηση της παραγωγής ηλεκτρικής ενέργειας (Ruangpattana et al., 2011). Εκτός αυτού, εξετάζονται και άλλες δράσεις, όπως η εκ των υστέρων αναβάθμιση του εξοπλισμού των συστημάτων ύδρευσης. Ωστόσο, οι δράσεις αυτές τείνουν να περιλαμβάνουν εκτεταμένο οικονομικό κόστος και να απαιτούν σημαντικές επενδύσεις, θέτοντας ανυπέρβλητους περιορισμούς στην υλοποίησή τους (Mankad and Tapsuwan, 2011). Μια άλλη προσέγγιση είναι η εστίαση στη βελτίωση της λειτουργίας της άντλησης με την ενίσχυση του ελέγχου της άντλησης μέσω τεχνικών βελτιστοποίησης. Πιο συγκεκριμένα, έχουν εμφανιστεί ψηφιακές τεχνικές και τεχνικές ελέγχου, όπως συστήματα παρακολούθησης και προηγμένη μοντελοποίηση βελτιστοποίησης, οι οποίες έχουν το πλεονέκτημα ότι δεν απαιτούν μεγάλες επενδύσεις, όπως ανακαινίσεις του συστήματος, γεγονός που τις καθιστά πιο ελκυστικές (Wanjiru et al., 2016; Kernan et al., 2017; Lange et al., 2020).

Το πρόβλημα της διαχείρισης των υδάτινων πόρων είναι ακόμη πιο κρίσιμο σε μικρές, απομακρυσμένες περιοχές όπως τα νησιά, λόγω των ανεπαρκών υδάτινων πόρων και της υψηλής ζήτησης, κυρίως κατά τη θερινή περίοδο λόγω των αυξημένων τουριστικών αφίξεων. Ορισμένα χρόνια προβλήματα που δεν έχουν επιλυθεί ακόμη είναι ο καθυστερημένος σχεδιασμός σε περιφερειακό και εθνικό επίπεδο και η ανεπαρκής στρατηγική όσον αφορά τη χρήση του νερού για γεωργικές εφαρμογές (Gikas and Angelakis, 2009). Στο πλαίσιο αυτό, έχουν αναπτυχθεί διάφοροι αλγόριθμοι έξυπνης διαχείρισης ενέργειας για την εξομάλυνση φορτίου και την εξοικονόμηση αιχμής, οι οποίοι βασίζονται σε δυναμική μοντελοποίηση σε εξειδικευμένα συστήματα λογισμικού που υλοποιούν τις προτεινόμενες λύσεις, όπως το λογισμικό APROS (Chapaloglou et al., 2019) και το εργαλείο προσομοίωσης TRNSYS 17 (Chua et al., 2014). Επιπλέον, αρκετές μελέτες έχουν επικεντρωθεί στην άμεση σύζευξη φωτοβολταϊκών (Φ/Β) συστημάτων με συστήματα άντλησης νερού (Padmavathi and Daniel, 2011), με στόχο είτε την επίτευξη της πιο αξιόπιστης και οικονομικής λειτουργίας των τελευταίων (Ghoneim, 2006; Campana et al., 2015), είτε τη βέλτιστη διαστασιολόγηση αυτόνομων Φ/Β συστημάτων άντλησης νερού (Olcan, 2015; Yahyaoui et al., 2017).

Η παρούσα εργασία επικεντρώνεται στην έξυπνη ενεργειακή διαχείριση απομακρυσμένων νησιωτικών ενεργειακών συστημάτων, δίνοντας ιδιαίτερη έμφαση στις αιχμές φορτίου που μπορούν να εξοικονομηθούν με τον βέλτιστο προγραμματισμό των ωρών λειτουργίας των εγκατεστημένων αντλιοστασίων νερού. Σε αυτό το πλαίσιο, η προβληματική ρύθμιση της παρούσας μελέτης μπορεί να διατυπωθεί ως εξής: Δεδομένων ιστορικών δεδομένων σχετικά με τη συνολική ηλεκτρική ενέργεια που καταναλώνεται στο νησί και την αντίστοιχη παραγωγή με βάση τις ΑΠΕ, ο στόχος είναι ο βέλτιστος προγραμματισμός της λειτουργίας των αντλιοστασίων νερού του νησιού. Συγκεκριμένα, στόχος είναι να προταθεί σε ημερήσια βάση ένα ωριαίο πρόγραμμα λειτουργίας των αντλιοστασίων νερού, έτσι ώστε οι αιχμές του καθαρού φορτίου (δηλαδή η συνολική κατανάλωση ηλεκτρικής ενέργειας μείον την παραγωγή με βάση τις ΑΠΕ) να ελαχιστοποιούνται κάτω από ένα σύνολο περιορισμών που σχετίζονται με τις ελάχιστες ώρες λειτουργίας των αντλιοστασίων νερού που εξασφαλίζουν τη διαθεσιμότητα του νερού. Ο στόχος αυτός μπορεί να ποσοτικοποιηθεί μέσω συγκεκριμένων δεικτών απόδοσης (Key Performance Indicators - KPIs), οι οποίοι αξιολογούν την ημερήσια και εβδομαδιαία απόκλιση της καθαρής κατανάλωσης ηλεκτρικής ενέργειας σε επίπεδο νησιού. Στην παρούσα μελέτη, η προτεινόμενη μέθοδος εφαρμόζεται στην περίπτωση χρήσης της Τήλου, ενός μικρού ελληνικού νησιού και δήμου που βρίσκεται στο Αιγαίο Πέλαγος και περιλαμβάνει, μεταξύ άλλων, κατανομημένη παραγωγή ηλεκτρικής ενέργειας από Φ/Β και έναν αριθμό δημοτικών αντλιοστασίων νερού.

Η προτεινόμενη μέθοδος εξοικονόμησης αιχμής παρέχει μια λύση με βάση τα δεδομένα στο πρόβλημα προγραμματισμού του συστήματος ύδρευσης, η οποία είναι ευέλικτη όσον αφορά

τις ώρες λειτουργίας και τον αριθμό των περιορισμών μετατοπίσιμων φορτίων και βασίζεται στα ακόλουθα βασικά στοιχεία:

- Ένα σύνολο τριών μοντέλων MM που προβλέπει την κατανάλωση ηλεκτρικής ενέργειας λαμβάνοντας υπόψη τα ημερήσια και μηνιαία εποχικά πρότυπα φορτίου, καθώς και τις τάσεις.
- Ένα σύνολο τριών μοντέλων MM που προβλέπει την παραγωγή ηλεκτρικής ενέργειας με βάση Φ/B λαμβάνοντας υπόψη τις προβλέψεις του καιρού, μεταξύ άλλων επεξηγηματικών μεταβλητών.
- Ένα σύνολο περιορισμών που σχετίζονται με τις ώρες λειτουργίας που απαιτούνται από τα αντλιοστάσια σε καθημερινό επίπεδο για τη διασφάλιση της διαθεσιμότητας νερού, καθώς και την ευελιξία της λειτουργίας τους.
- Ένας ευρετικός αλγόριθμος βελτιστοποίησης που ξυρίζει τις αιχμές με δυναμικό τρόπο, ώστε (i) το ενεργειακό σύστημα του νησιού να επωφελείται από την ηλεκτρική ενέργεια που παράγεται από ΑΠΕ και (ii) οι ώρες λειτουργίας των αντλιοστασίων να μη συμπίπτουν με τις αιχμές κατανάλωσης ηλεκτρικής ενέργειας του νησιού.

Η καινοτομία της προτεινόμενης μεθόδου έγκειται στην αυτόνομη αρχιτεκτονική της που δεν απαιτεί υποστήριξη από επαγγελματικά εργαλεία προσομοίωσης λογισμικού. Η μέθοδος αποτελείται από δύο σύνολα τριών βασικών μοντέλων πρόβλεψης που είναι ακριβή, εύκολα στην εφαρμογή, απαιτούν περιορισμένο όγκο δεδομένων για να εκπαιδευτούν αποτελεσματικά και είναι ανθεκτικά στην υπερπροσαρμογή και την αβεβαιότητα, καθώς και από έναν ευρετικό αλγόριθμο βελτιστοποίησης που είναι ευέλικτος όσον αφορά τις εισροές και τους κανόνες μετατόπισης φορτίου που λαμβάνονται υπόψη. Επιπλέον, σε αντίθεση με τις υπάρχουσες λύσεις εξοικονόμησης αιχμής που εξαρτώνται σε μεγάλο βαθμό από συστήματα αποθήκευσης ενέργειας μπαταριών (Uddin et al., 2020), η προτεινόμενη μέθοδος δεν απαιτεί αποθήκευση ενέργειας για την εξοικονόμηση αιχμής, με αποτέλεσμα να είναι εφαρμόσιμη σε πολλά απομονωμένα μικροδίκτυα. Τέλος, η προτεινόμενη μέθοδος αντιμετωπίζει το πρόβλημα της εξοικονόμησης αιχμών από μια καινοτόμο οπτική γωνία που συνδέει άμεσα τη διαθεσιμότητα νερού με την εξοικονόμηση ενέργειας, παρέχοντας επίσης εμπειρικά στοιχεία για το πώς τα κέρδη από την εξοικονόμηση αιχμών σχετίζονται με (i) την ποσότητα φορτίου που μπορεί να μετατοπιστεί σε ημερήσια βάση, (ii) την ακρίβεια των προβλέψεων που χρησιμοποιούνται στο πλαίσιο της διαδικασίας βελτιστοποίησης και (iii) την ποσότητα ηλεκτρικής ενέργειας που παράγεται από ΑΠΕ. Οι πτυχές αυτές πιστεύεται ότι αποκτούν μεγαλύτερη σημασία σε νησιωτικά περιβάλλοντα μικρής κλίμακας, όπου, αφενός, οι ανάγκες σε ηλεκτρική ενέργεια του τοπικού συστήματος ύδρευσης αντιπροσωπεύουν σημαντικό μερίδιο της συνολικής κατανάλωσης ηλεκτρικής ενέργειας του νησιού και, αφετέρου, η διακύμανση του φορτίου μεταξύ περιόδων εκτός αιχμής και αιχμής, καθώς και μεταξύ διαφορετικών εποχών, είναι συνήθως υψηλή.

Η υπόλοιπη εργασία οργανώνεται ως εξής. Στην ενότητα 9.2 γίνεται ανασκόπηση των σχετικών εργασιών στον τομέα και προσδιορίζονται τα κενά. Στην ενότητα 9.3 παρουσιάζεται η προτεινόμενη μέθοδος εξοικονόμησης αιχμής, συμπεριλαμβανομένων των τριών βασικών μοντέλων πρόβλεψης και του αλγορίθμου βελτιστοποίησης. Μια πραγματική μελέτη περίπτωσης της προτεινόμενης μεθόδου στο ελληνικό νησί της Τήλου παρουσιάζεται στην ενότητα 9.4. Τέλος, η ενότητα 9.5 ολοκληρώνει την εργασία και συνοψίζει ορισμένα βασικά σημεία για μελλοντική έρευνα.

9.2 Αναλυτική Διατύπωση Προβλήματος

9.2.1 Διατύπωση Προβλήματος

Σήμερα, ο όγκος των παραγόμενων δεδομένων αυξάνεται συνεχώς. Τα δεδομένα πραγματικού χρόνου στον τομέα της ενέργειας δημιουργούνται από τις τεχνολογίες του Διαδικτύου

των Πραγμάτων, συμπεριλαμβανομένων των έξυπνων μετρητών για την κατανάλωση ενέργειας και την παραγωγή ΑΠΕ (Saadi et al., 2020), των δεδομένων που βασίζονται σε αισθητήρες (Liu et al., 2020), των δεδομένων επενδύσεων ενεργειακής απόδοσης (Sarmas et al., 2022) και των περιουσιακών στοιχείων που βασίζονται στο δίκτυο, όπως οι τροφοδότες μετασχηματιστών (Kong et al., 2020). Επίσης, η πρόσβαση σε ανοικτά δεδομένα, όπως ιστορικά δεδομένα για τον καιρό ή την ενέργεια, έχει απλοποιηθεί, ανοίγοντας νέες ευκαιρίες για την ανάπτυξη μοντέλων και προσεγγίσεις αναγνώρισης προτύπων. Άλλα δεδομένα, τα οποία δεν σχετίζονται άμεσα με τον ενεργειακό τομέα, όπως δεδομένα για αντλίες νερού, είναι επίσης διαθέσιμα και μπορούν να ενσωματωθούν στους αλγορίθμους που αναπτύσσονται. Όλες αυτές οι πηγές δεδομένων προσφέρουν αναμφίβολα ευκαιρίες για την ανάπτυξη μιας προσέγγισης πολλαπλής κλίμακας και πολλαπλών ενδιαφερομένων μερών, με τη μορφή νέων αναλυτικών μεθόδων που αποσκοπούν στο να παρέχουν στους ενδιαφερόμενους φορείς στον τομέα της ενέργειας πιο αξιόπιστες και αξιοποιήσιμες πληροφορίες, ενισχύοντας τη λήψη αποφάσεων βάσει δεδομένων (Marinakis, 2020; Marinakis et al., 2020). Ως εκ τούτου, σκοπός της παρούσας μελέτης είναι η αξιοποίηση μοντέλων MM και τεχνικών βελτιστοποίησης προκειμένου να προστεθεί αξία στα διαθέσιμα δεδομένα που σχετίζονται με την κατανάλωση ηλεκτρικής ενέργειας, τη Φ/Β παραγωγή, τις καιρικές συνθήκες και τα μεταβλητά φορτία (αντλίες νερού), προτείνοντας ένα ολοκληρωμένο σχέδιο προγραμματισμού προς μια αυτοματοποιημένη προσέγγιση για τη διαχείριση συστημάτων ύδρευσης στα δύσκολα περιβάλλοντα των νησιών μικρής κλίμακας.

9.2.2 Τεχνικές Βελτιστοποίησης Συστημάτων Ύδρευσης

Η βελτίωση των συστημάτων ύδρευσης υποστηρίζεται κυρίως από ψηφιακές τεχνικές και λογισμικό. Ο σκοπός αυτών των εργαλείων που βασίζονται σε λογισμικό στον προγραμματισμό και τη λειτουργία των συστημάτων ύδρευσης είναι η ελαχιστοποίηση της χρήσης των πόρων, ο περιορισμός των απωλειών νερού και η αύξηση της εξοικονόμησης ενέργειας κατά τη διαδικασία διανομής του νερού. Σημαντική εξοικονόμηση ενέργειας μπορεί επίσης να προέλθει από τις διαδικασίες επεξεργασίας νερού, αλλά η παρούσα ενότητα επικεντρώνεται σε λύσεις βελτιστοποίησης της διανομής νερού. Παραδοσιακά εργαλεία υδραυλικής μοντελοποίησης, όπως το EPANET (Farina et al., 2014), έχουν χρησιμοποιηθεί σε μεγάλο βαθμό για την ανάλυση της συμπεριφοράς των δικτύων διανομής, κατανέμοντας τις απαιτήσεις νερού των χρηστών σε κόμβους υπολογισμού. Το EPANET είναι ένα πακέτο λογισμικού μοντελοποίησης για συστήματα διανομής νερού, το οποίο αναπτύχθηκε αρχικά από την Υπηρεσία Προστασίας Περιβάλλοντος των ΗΠΑ (Rossman, 1999). Παρέχει λειτουργίες υδραυλικής προσομοίωσης και προσομοίωσης της διανομής νερού εντός δικτύων νερού με σωλήνες υπό πίεση, βελτιώνοντας τη διαίσθηση της κίνησης του νερού εντός των συστημάτων διανομής. Με τη βοήθεια τέτοιων προγραμμάτων λογισμικού έχουν υλοποιηθεί αρκετές εργασίες που επικεντρώνονται στο σχεδιασμό συστημάτων ύδρευσης για την κάλυψη των καθημερινών αναγκών σε νερό σε πολλές περιοχές (Kumar et al., 2015; Adeniran and Oyelowo, 2013; Ramana and Chekka, 2018).

Εκτός από τα εμπορικά πακέτα λογισμικού, η ανάγκη βελτίωσης της αποδοτικότητας της λειτουργίας του συστήματος ύδρευσης έχει οδηγήσει σε διάφορες προσεγγίσεις βελτιστοποίησης με στόχο την ενίσχυση του προγραμματισμού των αντλιών κατά τη διάρκεια της ημέρας, προτείνοντας ρητά τις συγκεκριμένες ώρες κατά τη διάρκεια της ημέρας που πρέπει να ενεργοποιούνται οι αντλίες. Οι προσπάθειες προς αυτή την κατεύθυνση ξεκίνησαν με τη χρήση γενετικών αλγορίθμων με στόχο την ελαχιστοποίηση του κόστους λειτουργίας των αντλιών, αξιοποιώντας τα τιμολόγια ηλεκτρικής ενέργειας εκτός αιχμής και την αποθηκευτική ικανότητα του συστήματος διανομής νερού (Mackle et al., 1995). Τέτοιες ευρετικές και μεταερευτικές μεθοδολογίες έχουν επίσης συνδυαστεί με διαθέσιμο λογισμικό, όπως το EPANET, και έχουν εφαρμοστεί σε πραγματικά δίκτυα διανομής νερού, προκειμένου να παρέχουν επιχειρησιακές στρατηγικές παροχής νερού προς την κατεύθυνση της μείωσης

του κόστους και της καταναλισκόμενης ενέργειας (Costa et al., 2010). Οι προαναφερθείσες μελέτες κατάφεραν να επιτύχουν σημαντική εξοικονόμηση ενέργειας που φτάνει έως και το 10% όσον αφορά την κατανάλωση ενέργειας σε σύγκριση με την ενέργεια που καταναλωνόταν πριν από την εφαρμογή των προτεινόμενων σχεδίων, ανοίγοντας έτσι το δρόμο προς λύσεις προσανατολισμένες στα δεδομένα.

Άλλες μελέτες έχουν επικεντρωθεί στο συνδυασμό του προβλήματος βελτιστοποίησης του προγραμματισμού της λειτουργίας της άντλησης με τη στάθμη του νερού στις δεξαμενές αποθήκευσης. Η βασική ιδέα είναι η διαχείριση τόσο του χρονοδιαγράμματος άντλησης όσο και των επιπέδων ενεργοποίησης για τον έλεγχο του συστήματος ύδρευσης, χρησιμοποιώντας διαφορετικά επίπεδα ενεργοποίησης κατά τη διάρκεια διαφορετικών περιόδων της ημέρας, με στόχο την ελαχιστοποίηση της αιχμής άντλησης και του ύψους άντλησης. Η εφαρμογή ενός τέτοιου γενετικού αλγορίθμου που ενσωματώνει ιστορικές τιμές και αθέρατες μεταβλητές απόφασης πέτυχε εξοικονόμηση 20% στο ενεργειακό κόστος (Kazantzis et al., 2002). Επίσης, εξετάστηκε η ύπαρξη ειδικών κανόνων που αφορούν τη διαχείριση του συστήματος ύδρευσης, συμπεριλαμβανομένων των περιπτώσεων όπου τα αντλιοστάσια ελέγχονται σύμφωνα με τις στάθμες νερού πολλαπλών δεξαμενών, ή ακόμη και όταν πρέπει να λαμβάνονται υπόψη τόσο οι στάθμες των δεξαμενών όσο και η ώρα της ημέρας, προκειμένου να μειωθεί η άντληση κατά την περίοδο αιχμής του τιμολογίου (Marchi et al., 2017).

Οι ευρετικές μέθοδοι που αναλύονται στην παρούσα ενότητα προσφέρουν ευοίωνα αποτελέσματα όσον αφορά την εξοικονόμηση λειτουργικού κόστους και τη μείωση των εκπομπών CO₂, συνδυάζοντας οικονομικά και περιβαλλοντικά οφέλη. Ωστόσο, ο συνδυασμός του προβλήματος της στάθμης του αποθηκευμένου νερού με τη βελτιστοποίηση του προγραμματισμού των αντλιών προκάλεσε αυξημένη πολυπλοκότητα στους γενετικούς αλγορίθμους που αναπτύχθηκαν και κατά συνέπεια οδήγησε σε υψηλό υπολογιστικό φόρτο (Van Zyl et al., 2004). Επιπλέον, η ύπαρξη πολλών μεταβλητών απόφασης επιβάλλει κάποια πρόσθετα όρια στη σύγκλιση των χρησιμοποιούμενων ευρετικών μεθόδων. Στο πλαίσιο αυτό, διάφορες υβριδικές μέθοδοι, όπως τροποποιημένοι μηχανισμοί μετάλλαξης, έχουν επιχειρήσει να αντιμετωπίσουν το πρόβλημα.

9.2.3 Πρόβλεψη Παραγωγής

Ένας σημαντικός αριθμός μεθόδων πρόβλεψης έχει αναπτυχθεί με την πάροδο των ετών για την πρόβλεψη της παραγωγής ΑΠΕ και την υποστήριξη αποφάσεων που σχετίζονται με τη διαχείριση της ενέργειας, την τιμολόγηση και τη βελτιστοποίηση, ιδίως για την αιολική και την ηλιακή ενέργεια που αποτελούν τους πιο κοινούς και οικονομικά αποδοτικούς τύπους ΑΠΕ (Petropoulos et al., 2021). Στον τομέα της πρόβλεψης της ηλιακής ενέργειας, οι μέθοδοι παλινδρόμησης, όπως τα νευρωνικά δίκτυα (NNs; Korkmaz, 2021; Ghadami et al., 2021), τα μοντέλα που βασίζονται σε δέντρα αποφάσεων (Hassan et al., 2017) και οι μηχανές διανυσμάτων υποστήριξης (Eseye et al., 2018) έχουν αναγνωριστεί ως οι πλέον κατάλληλες λόγω της ικανότητάς τους να λαμβάνουν αποτελεσματικά υπόψη πολλαπλούς παράγοντες που επηρεάζουν την παραγωγή Φ/Β και να λαμβάνουν υπόψη μη γραμμικές σχέσεις. Αυτοί οι παράγοντες περιλαμβάνουν ιστορικά δεδομένα παραγωγής και καιρικών συνθηκών, μετεωρολογικές προβλέψεις και συνθήκες εγκατάστασης, μεταξύ άλλων. Παρ' όλα αυτά, η ποσοτική σύγκριση μεταξύ των διαφόρων μεθόδων πρόβλεψης αποτελεί πρόκληση στην πράξη, καθώς η ακρίβειά τους μπορεί να εξαρτάται σε μεγάλο βαθμό από την ποιότητα και την ανάλυση των διαθέσιμων ιστορικών δεδομένων, τον εξεταζόμενο ορίζοντα πρόβλεψης και την ακρίβεια των παρεχόμενων μετεωρολογικών προβλέψεων (Sobri et al., 2018).

Nespoli et al. (2019) συνέκρινε δύο από τις πιο διαδεδομένες μεθόδους MM που χρησιμοποιούνται για την πρόβλεψη της ηλιακής ενέργειας, η πρώτη αξιοποιώντας μόνο ιστορικά δεδομένα και η δεύτερη λαμβάνοντας υπόψη, εκτός από τις ιστορικές παρατηρήσεις, και τις μετεωρολογικές προβλέψεις. Σύμφωνα με τα αποτελέσματα, το πρώτο μοντέλο ανέφερε πιο σταθερή απόδοση, αλλά ήταν συχνά λιγότερο ακριβές από το δεύτερο σε ηλιόλουστες ημέρες. Επιπλέον, η ακρίβεια και των δύο μοντέλων επιδεινώθηκε τις συννεφιασμένες ημέρες, πι-

θανώς λόγω των ανακριβών μετεωρολογικών προβλέψεων που δόθηκαν στα μοντέλα ως είσοδος για τις ημέρες αυτές. Τα αποτελέσματα αυτά αναδεικνύουν τη σημασία της συνοδείας των μοντέλων πρόβλεψης ηλιακής ενέργειας με ακριβείς καιρικές προβλέψεις, όπως η θερμοκρασία περιβάλλοντος, η ηλιακή ακτινοβολία και η νεφοκάλυψη, και καταδεικνύουν γιατί οι υβριδικές μέθοδοι και τα σύνολα (Kourentzes et al., 2014) χρησιμοποιούνται ευρέως για την αντιμετώπιση της αβεβαιότητας των μοντέλων, των δεδομένων και των παραμέτρων (Petropoulos et al., 2018).

9.2.4 Πρόβλεψη Φορτίου

Η πρόβλεψη φορτίου είναι κρίσιμη για την αποτελεσματική λειτουργία και τον προγραμματισμό του συστήματος ηλεκτρικής ενέργειας. Ανάλογα με τον εξεταζόμενο ορίζοντα πρόβλεψης, ο οποίος μπορεί να εκτείνεται από λεπτά έως έτη, μπορεί να απαιτούνται διαφορετικοί τύποι δεδομένων και μοντέλων για τον σχεδιασμό ακριβών λύσεων πρόβλεψης (Petropoulos et al., 2021). Σε περιβάλλοντα διαχείρισης λειτουργιών, οι βραχυπρόθεσμες προβλέψεις, που εκτείνονται από 1 ώρα έως 168 ώρες (μία εβδομάδα) μπροστά, είναι οι πιο χρήσιμες, καθώς υποστηρίζουν αποφάσεις που σχετίζονται με την υποβολή προσφορών, τη βελτιστοποίηση χαρτοφυλακίου και το σχεδιασμό τιμολογίων, καθώς και τεχνικές εξοικονόμησης ενέργειας, όπως η μετατόπιση φορτίου, η εξοικονόμηση αιχμής, η αποθήκευση ενέργειας και η εξισορρόπηση φορτίου (Spiliotis et al., 2020).

Πολλές μέθοδοι πρόβλεψης έχουν προταθεί κατά τη διάρκεια των ετών για τη βραχυπρόθεση πρόβλεψη φορτίου (Suganthi and Samuel, 2012; Kuster et al., 2017). Μια εξειδικευμένη ανασκόπηση της κατάστασης για την πρόβλεψη ενέργειας σε κτίρια έχει πραγματοποιηθεί από το Sun et al. (2020). Σε γενικές γραμμές, οι μέθοδοι πρόβλεψης μπορούν να κατηγοριοποιηθούν σε μεθόδους χρονοσειρών, MM και υβριδικές μεθόδους. Οι μέθοδοι πρόβλεψης χρονοσειρών περιλαμβάνουν οικογένειες στατιστικών μοντέλων όπως το ARIMA και η εκθετική εξομάλυνση που εντοπίζουν πρότυπα στα ιστορικά δεδομένα φορτίου και τα προεκτείνουν στο χρόνο (Ferbar Tratar and Strmčnik, 2016). Οι μέθοδοι χρονοσειρών είναι διαισθητικές και γρήγορες στον υπολογισμό, αλλά περιορισμένης προσαρμοστικότητας και ικανότητας μοντελοποίησης μη γραμμικών σχέσεων. Οι μέθοδοι πρόβλεψης που βασίζονται στη MM μπορούν να αντιμετωπίσουν αποτελεσματικά αυτούς τους περιορισμούς, όντας επίσης σε θέση να ενσωματώσουν αποτελεσματικά πληροφορίες που σχετίζονται με τις καιρικές συνθήκες, τις ημερολογιακές επιδράσεις, τις ειδικές ημέρες και εκδηλώσεις και άλλους παράγοντες που μπορεί να επηρεάσουν τη ζήτηση. Τα πιο δημοφιλή μοντέλα MM που χρησιμοποιούνται στον τομέα είναι τα NN (Li, 2020) και, πιο πρόσφατα, η βαθιά μάθηση (Oreshkin et al., 2021). Παρόλα αυτά, τα μοντέλα MM που βασίζονται σε δέντρα παλινδρόμησης, όπως το XGBoost, έχουν επίσης γίνει δημοφιλή, παρουσιάζοντας πολλά υποσχόμενα αποτελέσματα σε διάφορες εφαρμογές πρόβλεψης φορτίου (Wang et al., 2021; Aguilar Madrid and Antonio, 2021; Abbasi et al., 2019; Liu et al., 2018), ενώ είναι σχετικά ταχύτερα στον υπολογισμό και ευκολότερα στην παραμετροποίηση από τα NNs. Τέλος, οι υβριδικές μέθοδοι πρόβλεψης περιλαμβάνουν την ενσωμάτωση μοντέλων χρονοσειρών ή MM με στόχο τον μετριασμό της αβεβαιότητας του μοντέλου (Bozkurt et al., 2017).

9.3 Προτεινόμενο Μοντέλο

Η προτεινόμενη μέθοδος διαχείρισης ενέργειας βασίζεται σε δύο πυλώνες. Ο πρώτος πυλώνας περιλαμβάνει δύο σύνολα τριών βασικών μοντέλων πρόβλεψης, υπεύθυνα για την πρόβλεψη της ηλεκτρικής ενέργειας που παράγεται από ΑΠΕ και της συνολικής ηλεκτρικής ενέργειας που καταναλώνεται από το σύστημα. Ο δεύτερος πυλώνας περιλαμβάνει έναν ευρετικό αλγόριθμο βελτιστοποίησης που κατανέμει βέλτιστα τις ώρες λειτουργίας των αντλιών κάθε ημέρα με στόχο την ελαχιστοποίηση των προβλεπόμενων αιχμών. Οι προαναφερθέντες πυλώνες συνδυάζονται δυναμικά προκειμένου να δημιουργηθεί ένα ολοκληρωμένο σχέδιο χρονοπρογραμματισμού για το σύστημα ύδρευσης, το οποίο τόσο εξοικονόμησε τις αιχμές

όσο και εξασφάλισε τη διαθεσιμότητα του νερού.

9.3.1 Μοντέλα Πρόβλεψης

Στην ενότητα αυτή παρουσιάζονται τα τρία βασικά μοντέλα MM που χρησιμοποιήθηκαν στην παρούσα μελέτη για την πρόβλεψη της παραγωγής ηλεκτρικής ενέργειας από Φ/Β και της κατανάλωσης, συμπεριλαμβανομένων λεπτομερειών σχετικά με τη διαδικασία εκπαίδευσης και βελτιστοποίησης. Σημειώστε ότι, όπως θα εξηγηθεί στη συνέχεια αυτής της ενότητας, οι τελικές προβλέψεις είναι ουσιαστικά ένα σύνολο των προβλέψεων που παράγονται από τα βασικά μοντέλα. Επίσης, να αναφερθεί ότι παρόλο που κάθε μεταβλητή πρόβλεψης προβλέπεται ανεξάρτητα, και στις δύο περιπτώσεις τα βασικά μοντέλα που χρησιμοποιούνται μοιράζονται τις ίδιες αρχές και τον ίδιο σχεδιασμό. Ακολουθώντας τα πρόσφατα ευρήματα της βιβλιογραφίας, επιλέχθηκαν τόσο τα μοντέλα που βασίζονται σε δέντρα αποφάσεων όσο και τα NN για την παραγωγή ενεργειακών προβλέψεων, καθώς θεωρούνται ως οι πιο δημοφιλείς και ακριβείς τύποι μεθόδων MM στον τομέα (Petropoulos et al., 2021).

Τα μοντέλα δέντρων απόφασης χωρίζουν αναδρομικά το χώρο δεδομένων σύμφωνα με ορισμένα χαρακτηριστικά (ανεξάρτητες ή επεξηγηματικές μεταβλητές) και προσαρμόζουν ένα απλό μοντέλο πρόβλεψης σε κάθε τμήμα (Loh, 2011). Κάθε φύλλο του δέντρου αντιστοιχίζεται σε μια συγκεκριμένη κλάση που αντιπροσωπεύει την καταλληλότερη τιμή-στόχο. Η πρόβλεψη για νέες περιπτώσεις επιτυγχάνεται με μια πλοήγηση που ξεκινά από τη ρίζα του δέντρου και καταλήγει σε ένα φύλλο, με βάση το αποτέλεσμα των διενεργούμενων συγκρίσεων κατά μήκος κάθε κόμβου του δέντρου (Rokach and Maimon, 2005). Αν και τα δέντρα αποφάσεων αναπτύχθηκαν αρχικά για την επίλυση εργασιών ταξινόμησης, ταιριάζουν επίσης καλά σε εργασίες παλινδρόμησης όπου η εξαρτημένη μεταβλητή λαμβάνει συνεχείς τιμές (Makridakis et al., 2018). Σε αυτή την περίπτωση, η συνάρτηση απώλειας (σφάλμα πρόβλεψης) που χρησιμοποιείται για την εκπαίδευση του μοντέλου είναι συνήθως η μέση τετραγωνική διαφορά μεταξύ των πραγματοποιημένων τιμών και των προβλεπόμενων (Loh, 2014). Εξετάστηκαν δύο διαφορετικές υλοποιήσεις δέντρων παλινδρόμησης: το σύστημα ενίσχυσης δέντρων *XGBoost* και ο αλγόριθμος δέντρων παλινδρόμησης *LightGBM* gradient boosting. Και οι δύο υλοποιήσεις είναι πολύ δημοφιλείς, με τον *LightGBM* να θεωρείται ως η τυπική μέθοδος επιλογής στους περισσότερους πρόσφατους διαγωνισμούς πρόβλεψης του Kaggle (Bojer and Meldgaard, 2021).

Τα NN βασίζονται σε ένα σύνολο πολλαπλών συνδεδεμένων κόμβων, συνήθως συγκεντρωμένων σε επίπεδα, που μεταδίδουν πληροφορίες μεταξύ τους. Κάθε νευρώνας λαμβάνει αριθμητικές τιμές ως είσοδο και τις συνδυάζει χρησιμοποιώντας συγκεκριμένα βάρη και (μη γραμμικές) συναρτήσεις ενεργοποίησης. Τα βάρη, τα οποία αποτελούν ουσιαστικά τις εκπαιδευσιμες παραμέτρους του μοντέλου, προσαρμόζονται καθώς πραγματοποιείται η μάθηση, έτσι ώστε το σφάλμα πρόβλεψης του μοντέλου να μειώνεται σταδιακά. Αν και στη βιβλιογραφία έχουν προταθεί διάφοροι τύποι NN, όπως τα αναδρομικά NN (Hewamalage et al., 2021), για την πρόβλεψη χρονοσειρών, τα πολυεπίπεδα perceptrons (MLP) εξακολουθούν να θεωρούνται ως μία από τις πιο αποτελεσματικές υλοποιήσεις των NN, βρίσκοντας εξαιρετικές εφαρμογές βαθιάς μάθησης στην πρόβλεψη φορτίου (Oreshkin et al., 2021), μεταξύ άλλων. Ως αποτέλεσμα, στην παρούσα μελέτη εστιάζουμε σε πολυεπίπεδα NNs τροφοδότησης προς τα εμπρός, προσεκτικά ρυθμισμένα για τις ιδιαιτερότητες του εξεταζόμενου συνόλου δεδομένων.

XGBoost (Chen and Guestrin, 2016) είναι μια μέθοδος συνόλου βασισμένη σε δέντρα αποφάσεων που χρησιμοποιεί μια προσέγγιση gradient boosting για τη δημιουργία αξιόπιστων προβλέψεων, υποστηρίζοντας διάφορες αντικειμενικές λειτουργίες, συμπεριλαμβανομένης της παλινδρόμησης, της ταξινόμησης και της κατάταξης. *XGBoost* έχει χρησιμοποιηθεί προκειμένου να επιλύσει διάφορα προβλήματα πραγματικής κλίμακας, ελαχιστοποιώντας την απαραίτητη ποσότητα πόρων (Ma and Yan, 2019). Παρόμοια με το *DecisionTreeRegressor*, το *XGBoost* περιλαμβάνει αρκετές υπερ-παραμέτρους που επηρεάζουν την ακρίβεια των προβλέψεων. Οι πιο επιδραστικές είναι το *learning rate*, που αναφέρεται επίσης ως *eta*, το οποίο είναι ο βαθμός συρρίκνωσης για τα βάρη των χαρακτηριστικών, καθιστώντας τη διαδικασία boosting περι-

σότερο ή λιγότερο συντηρητική, το *minimum split loss*, που αναφέρεται επίσης ως *gamma*, το οποίο αντιπροσωπεύει την ελάχιστη απώλεια που απαιτείται για να γίνει μια κατάτμηση σε έναν κόμβο φύλλου του δέντρου, και το *maximum depth* του δέντρου, το οποίο επηρεάζει την πολυπλοκότητα του μοντέλου, με κίνδυνο υπερπροσαρμογής. Παρόμοια με το *Decision-TreeRegressor*, χρησιμοποιήθηκε μια αναζήτηση πλέγματος για τη λεπτομερή ρύθμιση των τιμών των υπερπαραμέτρων. Πιο συγκεκριμένα, το *learning rate* ορίζεται μεταξύ (0,1, 0,6) με βήμα 0,1, το *minimum split loss* μεταξύ (2,20) με βήμα 2 και το *maximum depth* μεταξύ (1,25) με βήμα 5.

LightGBM (Ke et al., 2017) είναι ένας νέος αλγόριθμος MM δέντρων απόφασης με ενίσχυση κλίσης, ο οποίος ενισχύει τις κορυφαίες επιδόσεις σε πολλές εργασίες MM όσον αφορά την αποτελεσματικότητα και την ακρίβεια. Ο αλγόριθμος έχει εφαρμοστεί σε διάφορες εφαρμογές στον τομέα της ενέργειας, όπως η πρόβλεψη αιολικής ενέργειας (Ju et al., 2019) και η πρόβλεψη ηλεκτρικού φορτίου (Park et al., 2021), μεταξύ άλλων. Ο *LightGBM*, όπως και οι προαναφερθέντες αλγόριθμοι, περιλαμβάνει διάφορες παραμέτρους που είναι καθοριστικές για τη συμπεριφορά του. Οι πιο σημαντικές είναι ο ρυθμός μάθησης, ο αριθμός φύλλων, ο κλάσμα σακούλας, που επιτρέπει τη μείωση της διακύμανσης στην πρόβλεψη, και ο κλάσμα χαρακτηριστικών, που επιτρέπει την τυχαία επιλογή ενός υποσυνόλου χαρακτηριστικών σε κάθε επανάληψη. Για άλλη μια φορά, πραγματοποιήθηκε αναζήτηση πλέγματος για τον εντοπισμό των καταλληλότερων υπερ-παραμέτρων, λαμβάνοντας υπόψη τιμές μεταξύ (10, 50) με βήμα 5 για τον αριθμό των φύλλων και (0,1, 0,9) με βήμα 0,1 για όλες τις άλλες υπερ-παραμέτρους.

Ο *MLP* είναι ένας αλγόριθμος μάθησης με επίβλεψη στην κατηγορία των NN με τροφοδότηση προς τα εμπρός (Haykin, 1994), ο οποίος ενσωματώνει την ικανότητα μάθησης μη γραμμικών σχέσεων δεδομένων. Στην παρούσα μελέτη εξετάζουμε την υλοποίηση του *MLP Regressor* στο *sklearn* (Pedregosa et al., 2011) χρησιμοποιώντας τον βελτιστοποιητή στοχαστικής κλίσης *adam* που βασίζεται στη βελτιστοποίηση. Η αρχιτεκτονική του *MLP* περιλαμβάνει 2 κρυφά στρώματα με 64 κόμβους το καθένα. Έχουν διερευνηθεί διάφορες αρχιτεκτονικές, συμπεριλαμβανομένων των βαθιών αρχιτεκτονικών, αλλά η αύξηση του αριθμού των στρωμάτων δεν βελτίωσε την ακρίβεια πρόβλεψης, πιθανότατα λόγω του σχετικά χαμηλού αριθμού των διαθέσιμων χαρακτηριστικών και του σχετικά μικρού μεγέθους του συνόλου δεδομένων. Οι υπερ-παραμέτροι των μοντέλων έχουν ρυθμιστεί λεπτομερώς με τη χρήση αναζήτησης πλέγματος, λαμβάνοντας υπόψη το ρυθμό μάθησης και το μέγεθος της δέσμης, όπως παρουσιάζονται στον Πίνακα 9.1.

Σε όλες τις περιπτώσεις, οι βέλτιστες τιμές των υπερ-παραμέτρων προσδιορίστηκαν χρησιμοποιώντας μέρος (20%) των δεδομένων που ήταν διαθέσιμα για εκπαίδευση ως σύνολο επικύρωσης. Για να διασφαλιστεί ότι τα αποτελέσματα θα είναι αξιόπιστα για διάφορες χρονικές περιόδους, προσομοιώνοντας την πραγματική απόδοση πρόβλεψης των βασικών μοντέλων μετά τη δειγματοληψία και αποφεύγοντας πιθανά ζητήματα που σχετίζονται με την υπερπροσαρμογή, το σύνολο επικύρωσης αποτελούνταν από παρατηρήσεις που αντιπροσώπευαν διαφορετικούς μήνες, ημέρες και ώρες του συνόλου δεδομένων. Τα μέσα απόλυτα και τετραγωνικά σφάλματα χρησιμοποιήθηκαν για τον προσδιορισμό των “βέλτιστων” συνδυασμών των τιμών των υπερ-παραμέτρων για κάθε μοντέλο. Οι υπερ-παραμέτροι που βελτιστοποιήθηκαν για κάθε μοντέλο συνοψίζονται στον Πίνακα 9.1 μαζί με τον αντίστοιχο χώρο αναζήτησης και τις επιλεγμένες τιμές.

Οι τελικές προβλέψεις προκύπτουν από το συνδυασμό των προβλέψεων που παράγονται από καθένα από τα τρία βασικά μοντέλα. Τα βάρη για τον συνδυασμό των βασικών προβλέψεων καθορίζονται για κάθε σειρά ξεχωριστά κατά τη φάση της επικύρωσης (βελτιστοποίηση υπερπαραμέτρων). Η στρατηγική αυτή ακολουθήθηκε επειδή η ομαδοποίηση θεωρείται εδώ και καιρό μια αποτελεσματική τεχνική για τη βελτίωση της ακρίβειας των προβλέψεων, τον μετριασμό της αβεβαιότητας των μοντέλων και των παραμέτρων και την αποφυγή της υπερπροσαρμογής μέσω της διαφοροποίησης (Spiliotis et al., 2020; Petropoulos et al., 2018). Τα ευρήματα πρόσφατων, σημαντικών διαγωνισμών πρόβλεψης υπογραμμίζουν την αξία του συνδυασμού (Makridakis et al., 2020) και υποστηρίζουν τη σύνθεση συνόλων μοντέλων που

Πίνακας 9.1: Ο χώρος αναζήτησης και οι επιλεγμένες τιμές των υπερ-παραμέτρων για τα τρία μοντέλα πρόβλεψης που χρησιμοποιήθηκαν στην παρούσα μελέτη. Οι τιμές αναφέρονται χωριστά για τις σειρές παραγωγής Φ/B και κατανάλωσης ηλεκτρικής ενέργειας.

Model	Hyper-parameter	Min Value	Max Value	Step	Selected	
					PV Production	Consumption
XGBoost	learning rate	0.1	0.6	0.1	0.5	0.3
	minimum split loss	2	20	2	2	4
	maximum tree depth	1	25	5	5	5
LightGBM	learning rate	0.1	0.9	0.1	30	30
	number of leaves	10	50	10	0.1	0.3
	bagging fraction	0.1	0.9	0.1	0.7	0.7
	feature fraction	0.1	0.9	0.1	0.9	0.7
MLP	learning rate	0.001	0.01	0.002	0.001	0.001
	batch size	Values Tested: 32, 64, 28			32	64

βασίζονται σε δέντρα παλινδρόμησης και NN, όπως αυτά που εξετάζονται στην παρούσα μελέτη (Nasios and Vogklis, 2022; In and Jung, 2021). Εναλλακτικά, θα μπορούσε να εφαρμοστεί μια μέθοδος επιλογής του καλύτερου μοντέλου ανά ωριαίο διάστημα, αλλά το ensembling έχει αποδειχθεί πιο ακριβές και αξιόπιστο για τους σκοπούς της παρούσας μελέτης.

9.3.2 Μοντέλα Βελτιστοποίησης

Σκοπός του αλγορίθμου είναι η βέλτιστη μετατόπιση των ωρών λειτουργίας των αντλιοστασίων νερού σε ωριαία διαστήματα με χαμηλή αναμενόμενη κατανάλωση ηλεκτρικής ενέργειας στο νησί, ώστε να αποφεύγονται οι αιχμές. Για την ανάπτυξη του αλγορίθμου βελτιστοποίησης εξετάζονται δύο τρόποι λειτουργίας, προσπαθώντας να προσομοιωθεί τόσο η χειροκίνητη όσο και η αυτόματη λειτουργία. Στον πρώτο τρόπο λειτουργίας, που θα ονομαστεί “ευέλικτος”, το πρόγραμμα λειτουργίας των αντλιοστασίων είναι απεριόριστο, το οποίο μπορεί να ερμηνευτεί ως ευελιξία για την έναρξη και τη διακοπή λειτουργίας των αντλιοστασίων σε οποιαδήποτε ώρα της ημέρας. Η δεύτερη λειτουργία προσομοιώνει ένα “constrained” σχέδιο λειτουργίας των αντλιοστασίων, το οποίο σημαίνει ότι η λειτουργία ενός σταθμού πρέπει να είναι συνεχής και μπορεί να σταματήσει μόνο όταν συμπληρωθούν οι ημερήσιες απαιτούμενες ώρες. Και στους δύο τρόπους λειτουργίας ο αλγόριθμος βελτιστοποίησης απαιτεί την ακόλουθη είσοδο:

- Ο αριθμός των διαθέσιμων αντλιοστασίων (N).
- Ο αριθμός των απαιτούμενων ωρών λειτουργίας για κάθε αντλιοστάσιο κατά τη διάρκεια μιας ημέρας ($PHours$).
- Η ωριαία κατανάλωση ηλεκτρικής ενέργειας (εγκατεστημένη ισχύς) κάθε αντλιοστασίου ($PCons$).
- Το προβλεπόμενο καθαρό ηλεκτρικό φορτίο του νησιού (εξαιρουμένης της κατανάλωσης των αντλιοστασίων) για κάθε ωριαίο διάστημα κατά τη διάρκεια μιας ημέρας ($TCons$).

Ο ψευδοκώδικας του αλγορίθμου βελτιστοποίησης που αναπτύχθηκε για τον ευέλικτο τρόπο λειτουργίας παρουσιάζεται στον Αλγόριθμο 1. Ο προγραμματισμός λειτουργίας των αντλιών σχεδιάζεται στοχευμένα για την απομάκρυνση των αιχμών του καθαρού φορτίου (δηλαδή του συνολικού φορτίου μείον την παραγωγή ηλεκτρικής ενέργειας με βάση τα Φ/B) στο επίπεδο του νησιωτικού δικτύου. Στο πλαίσιο αυτό, ο αλγόριθμος επιλέγει το αντλιοστάσιο που λειτουργεί στο σημείο μέγιστου καθαρού φορτίου ηλεκτρικής ενέργειας και αναθέτει την αντίστοιχη αντλία στο διάστημα με το ελάχιστο ωριαίο φορτίο σύμφωνα με τις προβλέψεις κατανάλωσης ενέργειας του νησιού, καθώς και τις προβλέψεις παραγωγής Φ/B . Αφού ολοκληρωθεί η αντιστοίχιση του επιλεγμένου αντλιοστασίου στο επιλεγμένο διάστημα, ο αλγόριθμος προχωρά στις απαραίτητες ενημερώσεις των μεταβλητών $TCons$, η οποία περιγράφει

τη συνολική κατανάλωση του νησιού, και *PHours*, η οποία περιλαμβάνει τις υπόλοιπες ώρες που πρέπει να λειτουργήσει κάθε αντλιοστάσιο. Η όλη διαδικασία επαναλαμβάνεται έως ότου όλες οι ώρες λειτουργίας κάθε αντλιοστασίου αντιστοιχιστούν στο βέλτιστο διάστημα, όπως φαίνεται στο διάγραμμα ροής του αλγορίθμου βελτιστοποίησης, το οποίο είναι διαθέσιμο στο παράρτημα. Σημειώστε ότι, σε αυτόν τον τρόπο λειτουργίας, ο αλγόριθμος παρέχει ένα συνολικό ελάχιστο όσον αφορά την επιτυγχανόμενη εξοικονόμηση αιχμής.

Algorithm 1: Pump scheduling algorithm (flexible mode of operation)

Inputs : N : number of pumps

$PCons$: $\{x_1, x_2, \dots, x_N\}$, consumption per pump

$PHours$: $\{y_1, y_2, \dots, y_N\}$, operating hours per pump

$TCons$: $\{z_1, z_2, \dots, z_{24}\}$, consumption per hour interval

Output: $OperPlan[i, j]$: the operating plan; 1 if pump i is mapped to interval j ; 0 otherwise

```

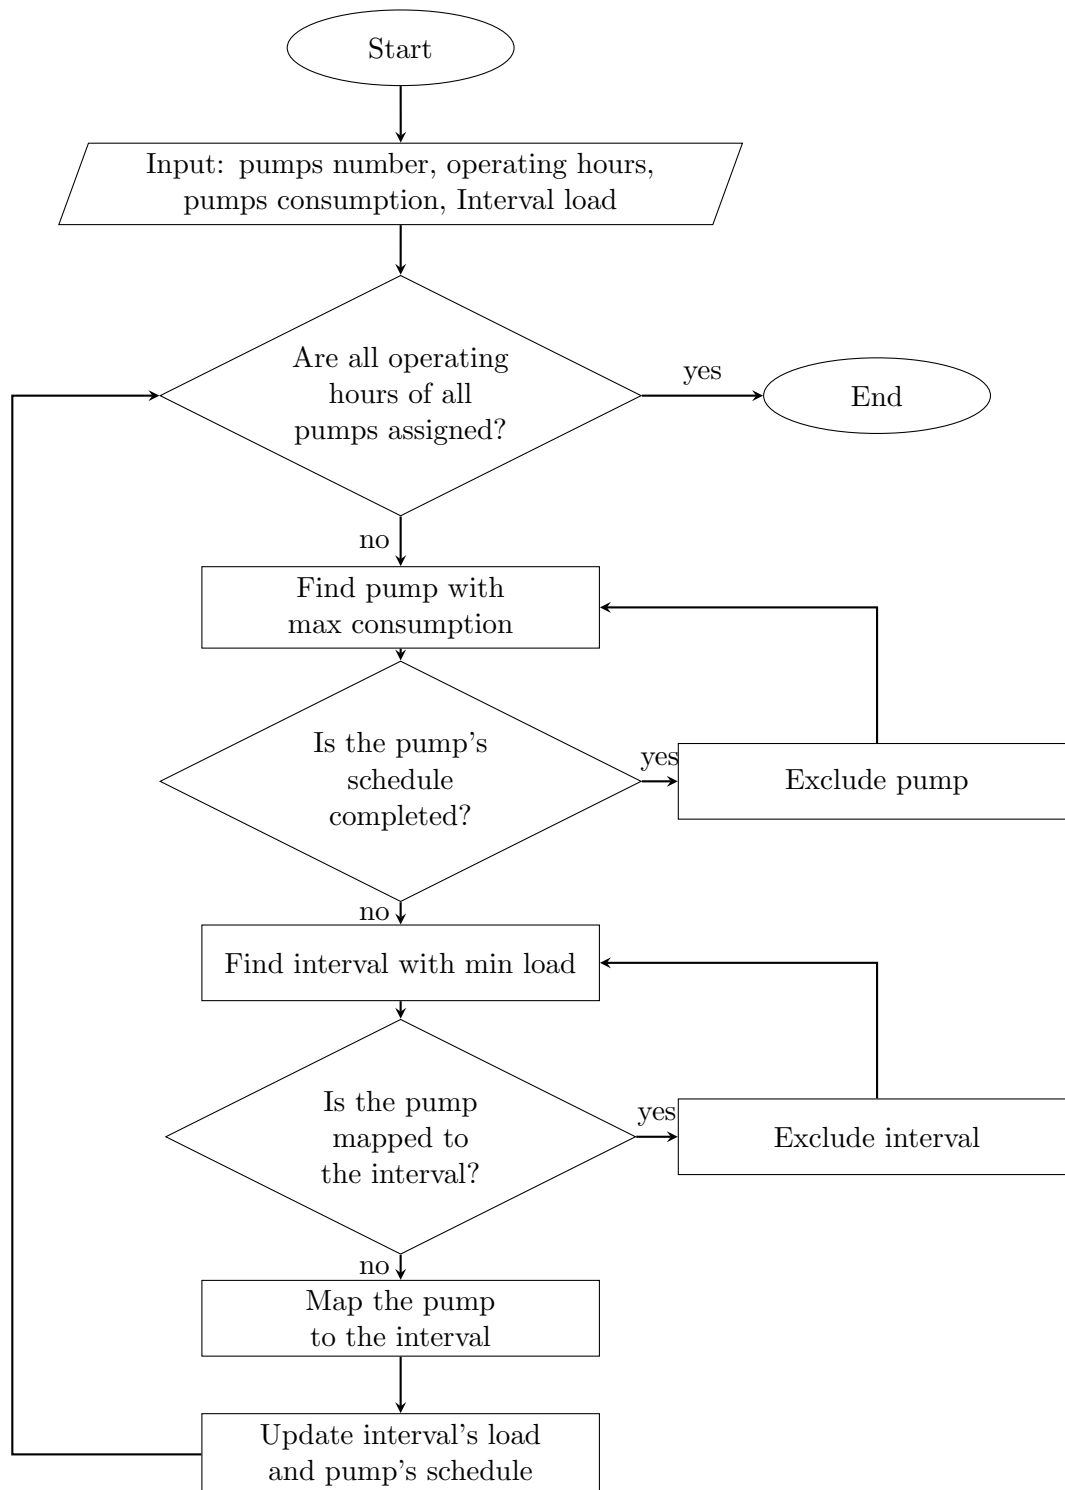
1 while  $PHours \neq 0$  do
2   for  $PHours[i] > 0$  do
3     | utilized pump  $\leftarrow \max(PCons)$ ;
4   end
5   max consumption  $\leftarrow PCons[\text{utilized pump}]$ ;
6   for  $OperPlan[\text{utilized pump}, j] == 0$  do
7     | utilized interval  $\leftarrow \min(TCons)$ ;
8   end
9    $OperPlan[\text{utilized pump}, \text{utilized interval}] \leftarrow 1$ ;
10   $TCons[\text{utilized interval}] \leftarrow TCons[\text{utilized interval}] + \text{max consumption}$ ;
11   $PHours[\text{utilized pump}] \leftarrow PHours[\text{utilized pump}] - 1$ ;
12 end

```

Στο δεύτερο τρόπο λειτουργίας, όπου η λειτουργία των αντλιών είναι περιορισμένη, ο αλγόριθμος βελτιστοποίησης τροποποιείται εν μέρει παρέχοντας μια λύση που μπορεί να μην είναι η βέλτιστη σε ορισμένες περιπτώσεις, αλλά προσεγγίζει τη βέλτιστη λύση του προβλήματος όσον αφορά την εξοικονόμηση αιχμής. Πρώτον, ο αλγόριθμος επιλέγει το αντλιοστάσιο με τη μέγιστη ωριαία κατανάλωση, όπως κάνει και ο αλγόριθμος του πρώτου τρόπου λειτουργίας. Η διαφορά αυτής της προσέγγισης είναι ότι ο αλγόριθμος επιλέγει ένα πολύωρο διάστημα, ίσο με τις ημερήσιες ώρες λειτουργίας του αντλιοστασίου, λόγω του περιορισμού της συνεχούς λειτουργίας. Πιο συγκεκριμένα, ο αλγόριθμος διερευνά όλα τα πιθανά πολύωρα διαστήματα με στόχο την εύρεση του ωριαίου διαστήματος με τη μέγιστη κατανάλωση ενέργειας σε κάθε ένα από αυτά. Τέλος, αντιστοιχίζει το αντλιοστάσιο στο πολύωρο διάστημα που περιλαμβάνει την ελάχιστη από αυτές τις τιμές, προσπαθώντας να αποτρέψει την εμφάνιση αιχμών. Η διαδικασία αυτή επαναλαμβάνεται έως ότου αντιστοιχιστούν όλα τα αντλιοστάσια σε ένα πολύωρο διάστημα. Η δυναμική αντιστοίχιση των αντλιοστασίων σε ωριαία διαστήματα εξασφαλίζει ότι δεν θα δημιουργηθούν νέες αιχμές καθ' όλη τη διάρκεια της διαδικασίας, λόγω της ιδιότητας του αλγορίθμου να ενημερώνει το καθαρό φορτίο του επιλεγμένου ωριαίου διαστήματος μετά την αντιστοίχιση μιας νέας αντλίας σε αυτό. Ο προτεινόμενος αλγόριθμος βελτιστοποίησης έχει υλοποιηθεί στη γλώσσα προγραμματισμού Python 3.0 και έχει αξιολογηθεί εκτενώς σε μια μελέτη περίπτωσης που περιγράφεται στην ενότητα 9.4. Ο αλγόριθμος παρουσιάζεται αναλυτικά στο παρακάτω διάγραμμα.

Θα πρέπει να σημειώσουμε ότι, προκειμένου οι αιχμές να εντοπιστούν με μεγαλύτερη ακρίβεια και να εξομαλυνθούν ανάλογα, το καθαρό ηλεκτρικό φορτίο θα πρέπει ιδανικά να υπολογίζεται λαμβάνοντας επίσης υπόψη τόσο τη διαμόρφωση του ηλεκτρικού δικτύου όσο και τις αντίστοιχες απώλειες. Αν και η πληροφορία αυτή δεν ήταν διαθέσιμη για την περίπτωση που εξετάστηκε στην παρούσα μελέτη, θα πρέπει να αξιοποιείται σε παρόμοιες εφαρμογές

Σχήμα 9.1: Διάγραμμα ροής του αλγορίθμου βελτιστοποίησης που χρησιμοποιείται για τον προγραμματισμό των ωρών λειτουργίας των αντλιών (ευέλικτος τρόπος λειτουργίας).



όταν είναι προσβάσιμη. Ωστόσο, δεδομένου ότι η προτεινόμενη μέθοδος βελτιστοποίησης επικεντρώνεται σε σχετικά μικρά, απομακρυσμένα νησιά, η επίδραση των απωλειών αναμένεται να είναι δευτερεύουσας σημασίας λόγω του μικρού μήκους που έχει το δίκτυο διανομής σε τέτοιες περιπτώσεις.

9.4 Μελέτη Περίπτωσης

9.4.1 Συνολο Δεδομένων

Προκειμένου να εκτιμηθούν οι δυνατότητες της προτεινόμενης μεθόδου βελτιστοποίησης όσον αφορά την εξοικονόμηση αιχμής, εξετάζεται η περίπτωση της Τήλου. Η Τήλος είναι ένα τυπικό μικρό ελληνικό νησί και δήμος που βρίσκεται στο Αιγαίο Πέλαγος και ανήκει στη νησιωτική αλυσίδα των Δωδεκανήσων. Αποτελεί ένα απομακρυσμένο νησί που έχει προχωρήσει σημαντικά προς την πράσινη ενεργειακή μετάβαση τα τελευταία χρόνια, υποστηριζόμενη και από την υλοποίηση του έργου TILOS Horizon 2020 (TILOS, 2015). Στο πλαίσιο του έργου αναπτύχθηκε ο πρώτος πλήρως αδειοδοτημένος υβριδικός σταθμός παραγωγής ηλεκτρικής ενέργειας από ΑΠΕ και μπαταρίες στην Ελλάδα, ικανός να καλύψει μεγάλο μέρος της τοπικής κατανάλωσης ηλεκτρικής ενέργειας. Ταυτόχρονα, προωθήθηκαν επίσης οι πτυχές της έξυπνης μέτρησης και της διαχείρισης της ζήτησης, με τα τοπικά αντλιοστάσια νερού να αποτελούν μια δεξαμενή αυξημένης ευελιξίας και επαρκούς αντίκτυπου απόκρισης για το σκοπό αυτό.

Εκτός από τον κεντρικό υβριδικό σταθμό παραγωγής ηλεκτρικής ενέργειας, οι κατανεμημένες ΑΠΕ εμφανίστηκαν επίσης κατά την πρόσφατη περίοδο στο νησί. Έτσι, στην παρούσα μελέτη χρησιμοποιήθηκαν ιστορικά δεδομένα λειτουργίας από κατανεμημένα Φ/Β συστήματα ως δεδομένα εισόδου για την προτεινόμενη μέθοδο βελτιστοποίησης και τα μοντέλα πρόβλεψης. Διερευνάται επίσης η εμπειρική αξιολόγηση παρόμοιων συστημάτων, τα οποία ενσωματώνουν τοπική Φ/Β ισχύ σε διαφορετικές κλίμακες με περιουσιακά στοιχεία άντλησης νερού σταθερών χαρακτηριστικών. Τα περιουσιακά στοιχεία άντλησης νερού της μελέτης περιλαμβάνουν έναν στόλο πέντε αντλιών νερού στο νησί της Τήλου, που παρακολουθούνται και ελέγχονται μέσω μιας κεντρικής πλατφόρμας διαχείρισης.


Τα δεδομένα που χρησιμοποιούνται είναι ωριαία και έχουν διάρκεια περίπου 2 ετών και τριών μηνών (19008 ώρες), που κυμαίνονται από την 1η Μαρτίου 2019 έως τις 30 Απριλίου 2021. Το σύνολο δεδομένων περιλαμβάνει τη συνολική ηλεκτρική ενέργεια που καταναλώνεται στο νησί της Τήλου, την ηλεκτρική ενέργεια που παράγεται ¹ από τα Φ/Β (εγκατεστημένη ισχύς 4,8 kW) και την ηλεκτρική ενέργεια που καταναλώνεται από τα πέντε αντλιοστάσια νερού. Αυτές οι χρονοσειρές, που παρουσιάζονται στο Σχήμα 9.2, θα αποτελέσουν τις βασικές μεταβλητές εισόδου της προτεινόμενης μεθόδου βελτιστοποίησης.

Αξίζει να αναφερθεί ότι η κατανάλωση ηλεκτρικής ενέργειας των αντλιοστασίων νερού υπολογίζεται μέσω του προγράμματος λειτουργίας τους. Συγκεκριμένα, κάθε αντλιοστάσιο λειτουργεί σε διαφορετικές ώρες κατά τη διάρκεια της ημέρας, όπως φαίνεται στο Σχήμα 9.3. Οι ώρες αυτές είναι προκαθορισμένες και σταθερές μέσα σε κάθε ημέρα του ίδιου μήνα, αλλά διαφέρουν μεταξύ των μηνών, ώστε να λαμβάνονται αποτελεσματικά υπόψη οι ανάγκες του νησιού όσον αφορά την ύδρευση των κατοίκων και την άρδευση. Επιπλέον, η εγκατεστημένη ισχύς των αντλιοστασίων διαφέρει (6, 10, 16, 2 και 11 kW για τους σταθμούς 1, 2, 3, 4 και 5, αντίστοιχα), ανάλογα και με άλλες παραμέτρους (π.χ. στάθμη νερού γεώτρησης, διαθέσιμο ύψος κ.λπ.) που μαζί καθορίζουν τον όγκο του νερού που μεταφέρεται στις τοπικές δεξαμενές νερού πριν από τη διανομή και την τελική του χρήση. Επομένως, προκειμένου η προτεινόμενη βελτιστοποίηση να έχει νόημα και να διασφαλίζει επαρκή παροχή νερού, τόσο σε ημερήσια όσο και σε μηνιαία βάση, πρέπει να διασφαλίζει ότι οι συνολικές ημερήσιες και μηνιαίες ώρες λειτουργίας κάθε αντλίας παραμένουν ίσες με αυτές που καθορίζονται σήμερα από τους χειριστές των σταθμών.

Όπως φαίνεται στο Σχήμα 9.2, όλες οι σειρές χαρακτηρίζονται από ισχυρά ετήσια εποχικά μοτίβα. Η συνολική κατανάλωση ηλεκτρικής ενέργειας είναι υψηλότερη το καλοκαίρι και ιδιαίτερα τον Ιούλιο και τον Αύγουστο, πιθανώς λόγω της αυξημένης τουριστικής δραστηριότητας και της χρήσης κλιματιστικών, ενώ είναι σημαντικά χαμηλότερη τον υπόλοιπο χρόνο.

¹Για να διευκολυνθούν οι συγκρίσεις στα πειράματα και να παρουσιαστούν καλύτερα τα ευρήματα, αναφέρεται ο συντελεστής ισχύος των Φ/Β (η ηλιακή ισχύς διαιρούμενη με την εγκατεστημένη ισχύ, εκφρασμένη ως ποσοστό) αντί της ηλιακής ισχύος καθαυτής (που μετράται σε kW).

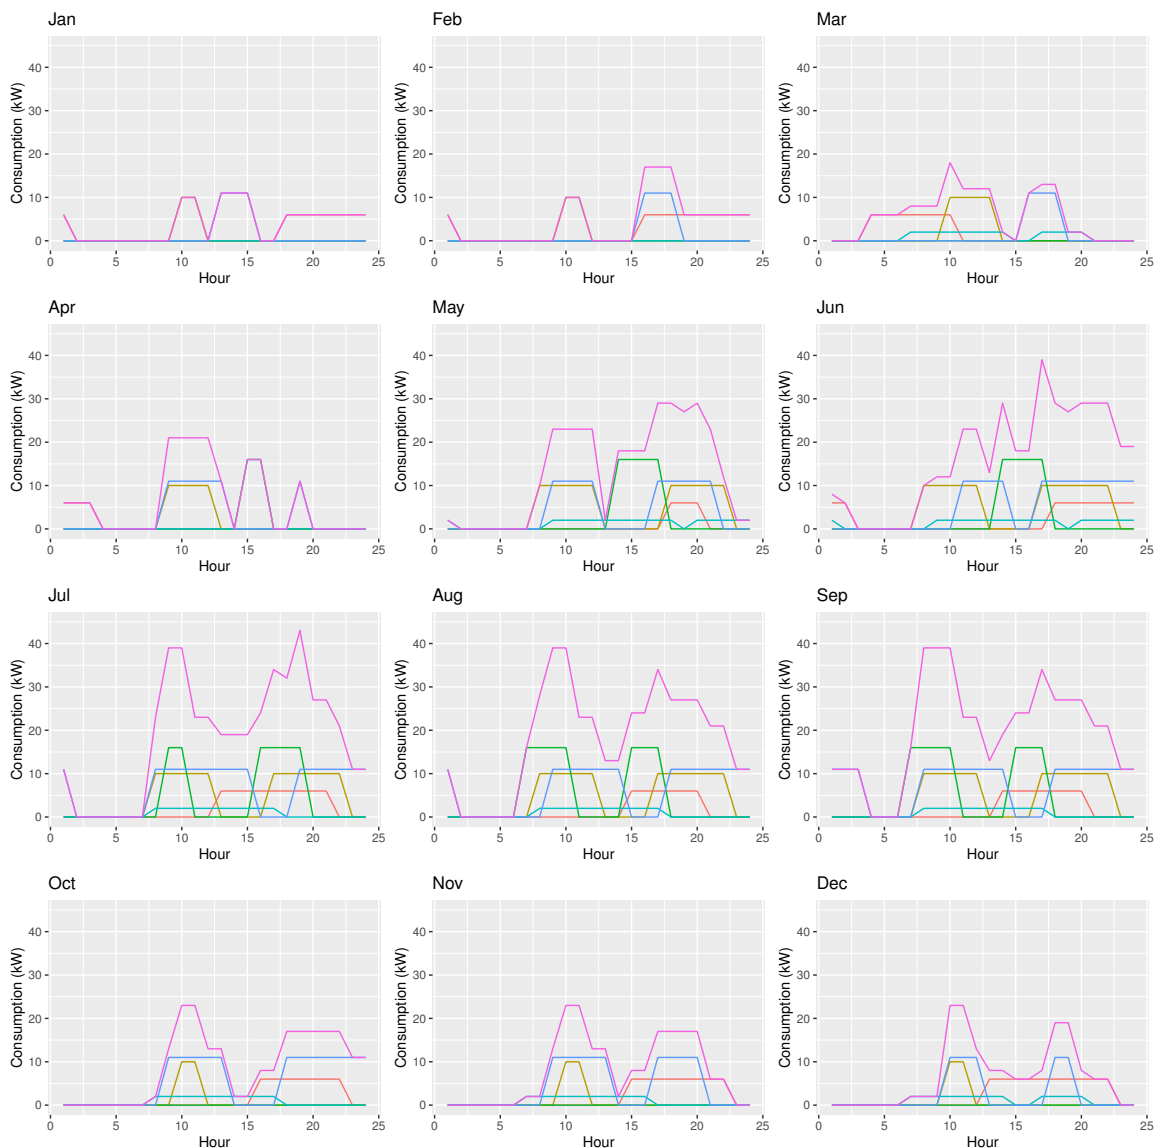
Σχήμα 9.2: Ωριαίες χρονοσειρές που αντιπροσωπεύουν τη συνολική ηλεκτρική ενέργεια που καταναλώνεται (kW) στο νησί της Τήλου, τον συντελεστή ισχύος των Φ/Β (%) και την ηλεκτρική ενέργεια που καταναλώνεται (kW) από τα πέντε αντλιοστάσια νερού (σύνολο των πέντε σταθμών).



Ωστόσο, ο Δεκέμβριος και ο Ιανουάριος εμφανίζουν ορισμένες αξιοσημείωτες κορυφές. Ομοίως, η παραγωγή ηλεκτρικής ενέργειας από Φ/Β είναι μεγαλύτερη το καλοκαίρι, καθώς και τον Απρίλιο, τον Μάιο και τον Σεπτέμβριο, ενώ είναι σημαντικά χαμηλότερη τον χειμώνα. Επιπλέον, όπως φαίνεται στο Σχήμα 9.4, οι σειρές εμφανίζουν έντονη ημερήσια εποχικότητα, η οποία οφείλεται στην ανθρώπινη συμπεριφορά και στις καιρικές συνθήκες. Για παράδειγμα, λόγω της ημερήσιας εποχικότητας της ηλιακής ακτινοβολίας, η παραγωγή ηλεκτρικής ενέργειας από Φ/Β κορυφώνεται το μεσημέρι και μειώνεται τις πρώτες πρωινές και νυχτερινές ώρες. Από την άλλη πλευρά, η κατανάλωση ενέργειας αυξάνεται μετά τις 09:00, αναφέροντας μια κορύφωση γύρω στις 20:00. Είναι ενδιαφέρον ότι τα ημερήσια πρότυπα της παραγωγής ηλεκτρικής ενέργειας από Φ/Β και της κατανάλωσης στο νησί διαφέρουν, υποδεικνύοντας ότι ακόμη και τα μεγάλα μερίδια παροχής ενέργειας από Φ/Β δεν επαρκούν για την αποτελεσματική απομάκρυνση των αιχμών κατανάλωσης με φυσικό τρόπο (αυτοκατανάλωση σε πραγματικό χρόνο), εκτός εάν εκτελούνται κατάλληλες ενέργειες μετατόπισης φορτίου. Ωστόσο, τα αντλιοστάσια νερού λειτουργούν κυρίως τις μεσημεριανές και απογευματινές ώρες, πράγμα που σημαίνει ότι οι διαχειριστές ενέργειας θα μπορούσαν να μειώσουν τις αιχμές με κατάλληλη προσαρμογή των τρεχουσών ωρών λειτουργίας των αντλιοστασίων. Η αναντιστοιχία μεταξύ της συνολικής κατανάλωσης ηλεκτρικής ενέργειας και της Φ/Β παραγωγής (συντελεστής συσχέτισης Pearson 0,1), καθώς και η αντιστοιχία μεταξύ της ηλεκτρικής ενέργειας που καταναλώνεται σε επίπεδο νησιού και αντλιοστασίου νερού (συντελεστής συσχέτισης Pearson 0,5) αποτελούν περαιτέρω κίνητρο για την παρούσα μελέτη και καταδεικνύουν τη δυνητική αξία της προτεινόμενης προσέγγισης βελτιστοποίησης, ιδίως σε περιβάλλοντα μικρής κλίμακας όπου η ευαισθησία αυτών των αναντιστοιχιών είναι σχετικά ισχυρή.

Εκτός από τις τρεις σειρές που παρουσιάζονται στο Σχήμα 9.4, το σύνολο δεδομένων περιλαμβάνει ωριαίες μετεωρολογικές προβλέψεις που θα αξιοποιηθούν για την ακριβή πρόβλεψη της ηλιακής ισχύος. Συγκεκριμένα, οι μετεωρολογικές προβλέψεις αφορούν την ηλιακή ακτι-

Σχήμα 9.3: Ημερήσια κατανάλωση ηλεκτρικής ενέργειας των πέντε αντλιοστασίων που εξετάστηκαν στην παρούσα μελέτη. Το ημερήσιο πρόγραμμα λειτουργίας αλλάζει σε διάφορους μήνες αλλά παραμένει το ίδιο εντός κάθε μήνα. Η συνολική ηλεκτρική ενέργεια που καταναλώνεται από τους σταθμούς εμφανίζεται με μωβ χρώμα.




νοβολία (μετρούμενη σε W/m^2), τη θερμοκρασία (μετρούμενη σε $^{\circ}C$), τη νεφοκάλυψη (που κυμαίνεται από 0 έως 8, με την πρώτη τιμή να υποδηλώνει μηδενική κάλυψη και τη δεύτερη τιμή πλήρη κάλυψη) και την ταχύτητα του ανέμου (μετρούμενη σε m/s) προβλέψεις που γίνονται σε εβδομαδιαία βάση. Οι κατανομές αυτών των μεταβλητών απεικονίζονται στα ιστογράμματα του Σχήματος 9.5.

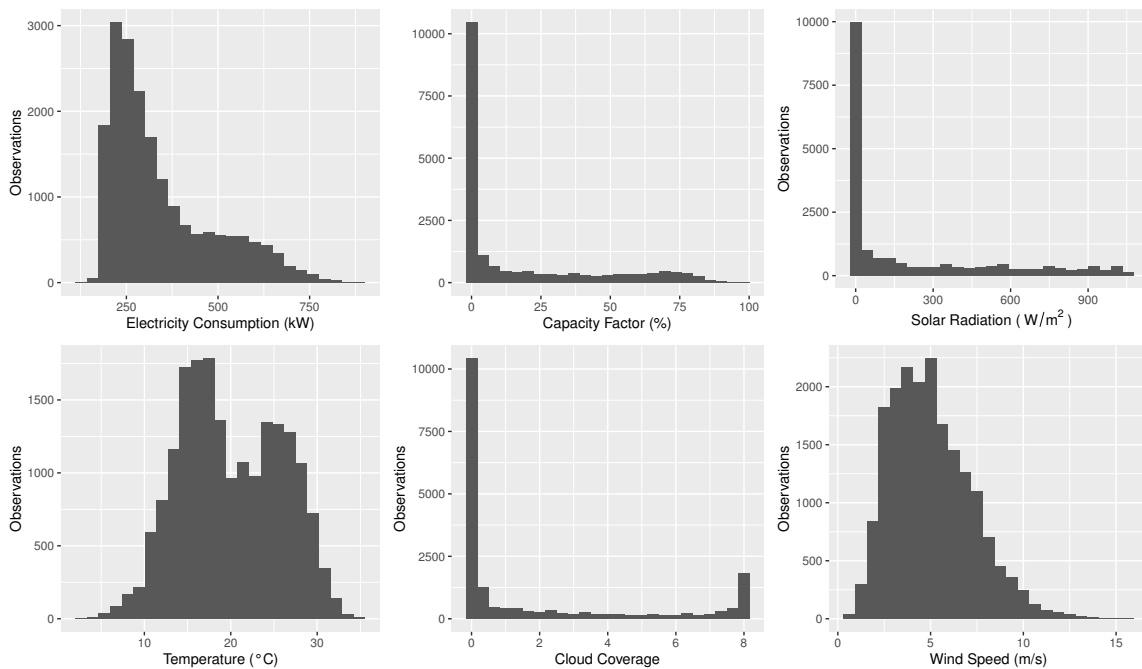
9.4.2 Πειραματικός Σχεδιασμός

Προκειμένου να προσομοιωθεί η απόδοση της προτεινόμενης μεθόδου όσο το δυνατόν πιο ρεαλιστικά, χρησιμοποιείται μια προσέγγιση με βάση τη μόδα κυλιόμενης προέλευσης, λαμβάνοντας υπόψη μια συνολική περίοδο αξιολόγησης 8760 ωρών (1 έτος). Αυτό μας επιτρέπει να αξιολογήσουμε τα οφέλη της μακροπρόθεσμα, λαμβάνοντας παράλληλα υπόψη ημερολογιακούς και καιρικούς παράγοντες που ενδέχεται να επηρεάσουν την απόδοσή της κατά τη διάρκεια του έτους. Σύμφωνα με αυτή τη ρύθμιση, οι πρώτες 10248 διαθέσιμες παρατηρή-

Σχήμα 9.4: Κατανομή των εποχιακών δεικτών (υπολογίζεται με χρήση προσθετικής αποσύνθεσης με κινητούς μέσους όρους; [Spiliotis et al., 2020](#)) για τη συνολική κατανάλωση ηλεκτρικής ενέργειας (αριστερά), τον συντελεστή ισχύος των Φ/Β (μέση) και την κατανάλωση των αντλιοστασίων νερού (δεξιά). Η χαμηλή διακύμανση των δεικτών γύρω από το εποχικό προφίλ (μπλε γραμμή) υποδηλώνει χρονοσειρές με έντονη ημερήσια εποχικότητα (οι παρατηρήσεις επικαλύπτονται κάθε 24 ώρες).



Σχήμα 9.5: Κατανομές (ιστογράμματα) των μεταβλητών που εξετάζονται από την προτεινόμενη μέθοδο βελτιστοποίησης στην εξεταζόμενη μελέτη περίπτωσης (κατανάλωση ηλεκτρικής ενέργειας, συντελεστής ισχύος Φ/Β και προβλέψεις καιρού)



σεις χρησιμοποιούνται για την εκπαίδευση των προτεινόμενων μοντέλων πρόβλεψης, όπως περιγράφεται στην υποενότητα [9.3.1](#). Στη συνέχεια, προβλέπεται η συνολική κατανάλωση ηλεκτρικής ενέργειας του νησιού και η ηλιακή ισχύς για τις επόμενες 168 ώρες (1 εβδομάδα). Χρησιμοποιώντας αυτές τις προβλέψεις ως είσοδο, εφαρμόζεται ο αλγόριθμος που περιγράφεται στην υποενότητα [9.3.2](#) προκειμένου να καθοριστεί ένα “βέλτιστο” πρόγραμμα λειτουργίας για τα αντλιοστάσια άντλησης νερού του νησιού. Στη συνέχεια, με βάση την πραγματοποιηθείσα κατανάλωση ηλεκτρικής ενέργειας και τη Φ/Β παραγωγή που αναφέρθηκε για την εβδομάδα που είχε προβλεφθεί προηγουμένως, μετράται ο αντίκτυπος των προτεινόμενων σχεδίων χρησιμοποιώντας τους ακόλουθους βασικούς δείκτες απόδοσης (KPIs):

1. SD_{day} : Μέση τυπική απόκλιση της κατανάλωσης ηλεκτρικής ενέργειας, μετρούμενη σε ημερήσια βάση.
2. SD_{week} : Μέση τυπική απόκλιση της κατανάλωσης ηλεκτρικής ενέργειας, μετρούμενη σε εβδομαδιαία βάση.
3. $Max - Min_{day}$: Μέση διαφορά μεταξύ μέγιστης και ελάχιστης κατανάλωσης ηλεκτρικής ενέργειας, μετρούμενη σε ημερήσια βάση.
4. $Max - Min_{week}$: Μέση διαφορά μεταξύ μέγιστης και ελάχιστης κατανάλωσης ηλεκτρικής ενέργειας, μετρούμενη σε εβδομαδιαία βάση.
5. $Max - Mean_{day}$: Μέση διαφορά μεταξύ μέγιστης και μέσης κατανάλωσης ηλεκτρικής ενέργειας, μετρούμενη σε ημερήσια βάση.
6. $Max - Mean_{week}$: Μέση διαφορά μεταξύ μέγιστης και μέσης κατανάλωσης ηλεκτρικής ενέργειας, μετρούμενη σε εβδομαδιαία βάση.

Οι προαναφερθέντες KPIs είναι εμπνευσμένοι από τη μελέτη του [Feng et al. \(2019\)](#), ο οποίος πρότεινε την τυπική απόκλιση και τη διαφορά μεταξύ μέγιστης και ελάχιστης τιμής (peak-valley difference) για την αξιολόγηση ενός μοντέλου μεικτού αχέραιου γραμμικού προγραμματισμού για ένα πρόβλημα εξοικονόμησης αιχμής που αφορά θερμοηλεκτρικούς σταθμούς. Επιπλέον, αυτές οι μετρικές έχουν αξιοποιηθεί είτε ως KPIs είτε ως αντικειμενική συνάρτηση σε μια ποικιλία παρόμοιων προβλημάτων εξοικονόμησης αιχμής, όπως η λειτουργία εξοικονόμησης αιχμής των υδροηλεκτρικών σταθμών καταιονισμού ([Liao et al., 2021](#)) και των υδροθερμικών-πυρηνικών σταθμών σε περιβάλλον πολλαπλών δικτύων ηλεκτρικής ενέργειας ([Feng et al., 2017](#)), αναδεικνύοντας τους καταλληλότερους δείκτες για την αξιολόγηση της απόδοσης εξοικονόμησης αιχμής του προτεινόμενου αλγορίθμου βελτιστοποίησης. Για να είναι δυνατές οι άμεσες συγκρίσεις, οι δείκτες KPI υπολογίζονται επίσης για την πραγματοποιηθείσα κατανάλωση ενέργειας, δηλαδή για τον τρόπο λειτουργίας “business as usual” (BaU), όπου δεν πραγματοποιείται καμία βελτιστοποίηση και οι αντλίες νερού λειτουργούν σύμφωνα με το συνηθισμένο πρόγραμμα.

Μετά την ολοκλήρωση του πρώτου γύρου αξιολόγησης, η προέλευση της πρόβλεψης μεταφέρεται προς τα εμπρός κατά 168 ώρες, χρησιμοποιώντας τις πρώτες 10416 διαθέσιμες παρατηρήσεις για την επανεκπαίδευση των προτεινόμενων μοντέλων πρόβλεψης και εφαρμόζοντας εκ νέου τον αλγόριθμο βελτιστοποίησης για τη μέτρηση της απόδοσής του για τη δεύτερη εβδομάδα του συνόλου δοκιμών. Η διαδικασία αυτή επαναλαμβάνεται έως ότου δεν απομείνουν παρατηρήσεις. Ως αποτέλεσμα, είναι διαθέσιμες συνολικά 52 περίοδοι αξιολόγησης, οι οποίες αντιπροσωπεύουν επαρκώς τις επιδόσεις της μεθόδου βελτιστοποίησης.

Σημειώνεται ότι η συχνότητα ενημέρωσης του προτεινόμενου προγράμματος λειτουργίας επιλέχθηκε προσεκτικά αφού λήφθηκαν υπόψη ορισμένοι πρακτικοί περιορισμοί. Για παράδειγμα, οι προγνώσεις καιρού παρέχονται επί του παρόντος στο σύστημα διαχείρισης ενέργειας μέσω μιας διαδικτυακής υπηρεσίας σε εβδομαδιαία βάση. Έτσι, ο επανυπολογισμός των προβλέψεων ηλιακής ισχύος σε καθημερινή βάση καθίσταται αδύνατος. Επιπλέον, παρόλο που τα περισσότερα συστήματα διαχείρισης ενέργειας μπορούν να προσαρμόσουν αυτόματα τις ώρες λειτουργίας των αντλιοστασίων, οι διαχειριστές ενέργειας ενδέχεται να πρέπει να εγκρίνουν τις όποιες αλλαγές γίνονται, ενέργεια που δεν είναι πάντα εφικτό να εκτελείται σε τακτική βάση. Παρ’ όλα αυτά, η προτεινόμενη μέθοδος μπορεί εύκολα να προσαρμοστεί ώστε να επιτρέπει συχνότερες ενημερώσεις σε σύγκριση με αυτές που εξετάστηκαν στην παρούσα μελέτη, μια πρακτική που θα μπορούσε να επιτρέψει ακριβέστερες ενεργειακές προβλέψεις και, ως εκ τούτου, καλύτερη βελτιστοποίηση.

Στα πειράματα που διεξήχθησαν εξετάζονται δύο τρόποι εφαρμογής της προτεινόμενης μεθόδου βελτιστοποίησης. Στον πρώτο τρόπο λειτουργίας, ο οποίος θα ονομαστεί “ελεύθελος”, η λειτουργία των αντλιών είναι απολύτως ευέλικτη και τα αντλιοστάσια μπορούν να εκκινήσουν και να σταματήσουν οποιαδήποτε ώρα της ημέρας. Στο δεύτερο τρόπο λειτουργίας, που θα ονομαστεί “constrained”, η λειτουργία των αντλιών είναι περιορισμένη και,


μετά την έναρξη λειτουργίας ενός σταθμού, δεν μπορεί να σταματήσει μέχρι να παρέλθουν οι απαιτούμενες ώρες λειτουργίας του. Εν προκειμένω, η πρώτη λειτουργία προσομοιώνει πλήρως αυτοματοποιημένα συστήματα που ελέγχουν τις αντλίες νερού από απόσταση, ενώ η δεύτερη λειτουργία προσομοιώνει συστήματα όπου οι αντλίες νερού ελέγχονται χειροκίνητα από τους διαχειριστές ενέργειας. Ως αποτέλεσμα, οι διαφορές που αναφέρθηκαν μεταξύ αυτών των δύο τρόπων λειτουργίας μπορούν να καταδείξουν αποτελεσματικά τα δυνητικά οφέλη των αυτοματοποιημένων συστημάτων έναντι των μη αυτοματοποιημένων.

9.4.3 Ακρίβεια Μοντέλων Πρόβλεψης

Όπως εξηγείται στην ενότητα 9.3, ο αλγόριθμος βελτιστοποίησης βασίζεται σε προβλέψεις που αντιπροσωπεύουν τη μελλοντική κατανάλωση ηλεκτρικής ενέργειας και τη Φ/Β παραγωγή. Σε γενικές γραμμές, η μεγαλύτερη ακρίβεια πρόβλεψης αναμένεται να οδηγήσει σε αποτελεσματικότερη διαχείριση της ενέργειας. Στην προκειμένη περίπτωση, οι προβλέψεις που απαιτούνται από τον αλγόριθμο αφορούν τη συνολική κατανάλωση ηλεκτρικής ενέργειας του νησιού και την ηλιακή ενέργεια. Και στις δύο περιπτώσεις, οι προβλέψεις παράγονται χρησιμοποιώντας ένα σύνολο μοντέλων MM, όπως περιγράφεται στην υποενότητα 9.3.1. Παρόλα αυτά, δεδομένων των ιδιοτήτων και της φύσης κάθε σειράς, χρησιμοποιούνται διαφορετικά χαρακτηριστικά ως είσοδος ανά περίπτωση για τη διευκόλυνση της εκπαίδευσης και την ενίσχυση της ακρίβειας πρόβλεψης.

Η κατανάλωση ηλεκτρικής ενέργειας χαρακτηρίζεται από έντονα εποχικά πρότυπα, τα οποία παρατηρούνται τόσο σε ημερήσιο όσο και σε ετήσιο επίπεδο. Αυτό γίνεται εμφανές παρατηρώντας τα Σχήματα 9.2 και 9.4, καθώς και το Σχήμα 9.6 που παρουσιάζει τη συνάρτηση αυτοσυσχέτισης των αντίστοιχων σειρών κατά τη διάρκεια της εβδομάδας (168 ώρες) και του έτους (8760 ώρες). Η αυτοπαλινδρόμηση, δηλαδή η χρήση παρελθουσών παρατηρήσεων κατανάλωσης ηλεκτρικής ενέργειας ως χαρακτηριστικών για την πρόβλεψη μελλοντικών, είναι μια πολλά υποσχόμενη προσέγγιση πρόβλεψης, ιδίως εάν μεταξύ των χαρακτηριστικών περιλαμβάνονται κατηγορικές μεταβλητές όπως ο μήνας, η εβδομάδα, η καθημερινή ημέρα και η ώρα της ημέρας για να διευκολυνθεί η αναγνώριση προτύπων. Ως εκ τούτου, τα προαναφερθέντα χαρακτηριστικά (υστέρηση 168 και ημερολογιακές μεταβλητές) είναι οι μόνοι παλινδρομείς που λαμβάνονται υπόψη από τα βασικά μοντέλα MM για την πρόβλεψη της κατανάλωσης ηλεκτρικής ενέργειας.


Σχήμα 9.6: Συνάρτηση αυτοσυσχέτισης της συνολικής κατανάλωσης ηλεκτρικής ενέργειας που υπολογίζεται κατά τη διάρκεια της εβδομάδας (168 ώρες) και του έτους (8760 ώρες)



Η ηλιακή ενέργεια είναι από τη φύση της στοχαστική και εξαρτάται κυρίως από τις καιρικές συνθήκες. Ως εκ τούτου, σε αντίθεση με τα προηγούμενα μοντέλα, οι παρατηρήσεις του παρελθόντος δεν λαμβάνονται υπόψη ως χαρακτηριστικά και οι προβλέψεις βασίζονται στις

μετεωρολογικές προβλέψεις που είναι διαθέσιμες στο EMS. Το Σχήμα 9.7 παρέχει συγκρίσεις μεταξύ της ηλιακής ισχύος και των μετεωρολογικών προβλέψεων που χρησιμοποιούνται για την πρόβλεψή της. Όπως αναμενόταν, η ηλιακή ακτινοβολία σχετίζεται στενά με τη Φ/B παραγωγή, αποτελώντας κρίσιμο παράγοντα πρόβλεψης. Η θερμοκρασία και η ταχύτητα του ανέμου σχετίζονται επίσης θετικά με την ηλιακή ισχύ, αλλά σε πολύ ασθενέστερο βαθμό. Τέλος, αν και η υψηλότερη νεφοκάλυψη οδηγεί συνήθως σε μικρότερη παραγωγή ενέργειας, η επεξηγηματική της δύναμη είναι περιορισμένη, πιθανώς λόγω της αβεβαιότητας που ενέχουν οι προβλέψεις της συγκεκριμένης μεταβλητής. Παρ' όλα αυτά, προκειμένου να βοηθήσουμε τα βασικά μοντέλα πρόβλεψης να συλλάβουν τις ημερολογιακές επιδράσεις και την ημερήσια εποχικότητα, συμπεριλαμβάνουμε τον μήνα, την εβδομάδα και την ώρα της ημέρας (κατηγορικές μεταβλητές) μεταξύ των χαρακτηριστικών τους.

Σχήμα 9.7: Συντελεστής ισχύος Φ/B (%) σε σύγκριση με την ηλιακή ακτινοβολία (W/m^2), τη θερμοκρασία ($^{\circ}C$), τη νεφοκάλυψη και την ταχύτητα του ανέμου (m/s). Οι συντελεστές συσχέτισης Pearson είναι 0,82, 0,30, -0,11 και 0,22 αντίστοιχα.



Η ακρίβεια των προτεινόμενων συνόλων αξιολογείται με τον υπολογισμό της ρίζας του μέσου τετραγωνικού σφάλματος (RMSE) και του μέσου απόλυτου σφάλματος (MAE) των αντίστοιχων προβλέψεων κατά την εξεταζόμενη περίοδο αξιολόγησης, καθώς και του συντελεστή συσχέτισης Pearson μεταξύ των προβλέψεων και των πραγματοποιημένων τιμών, ως εξής:

$$RMSE = \sqrt{\frac{1}{8760} \sum_{t=1}^{8760} (y_t - f_t)^2},$$

$$MAE = \frac{1}{8760} \sum_{t=1}^{8760} |y_t - f_t|,$$

$$r_{y,f} = \frac{\sum_{t=1}^{8760} (y_t - \bar{y})(f_t - \bar{f})}{\sqrt{\sum_{t=1}^{8760} (y_t - \bar{y})^2} \sqrt{\sum_{t=1}^{8760} (f_t - \bar{f})^2}},$$

όπου y_t είναι η πραγματική μελλοντική τιμή της εξεταζόμενης χρονοσειράς την ώρα t της περιόδου αξιολόγησης, f_t η πρόβλεψη του μοντέλου που χρησιμοποιήθηκε για την παραγωγή των προβλέψεων, ενώ \bar{y} και \bar{f} ο μέσος όρος των πραγματικών και των προβλεπόμενων τιμών, αντίστοιχα. Η επιλογή των επιλεγμένων μέτρων απόδοσης μπορεί να αιτιολογηθεί ως εξής: Τα τετραγωνικά σφάλματα, όπως και το RMSE, βελτιστοποιούνται για τη μέση τιμή (Kolassa, 2016), αξιολογώντας τα μοντέλα πρόβλεψης με βάση το πόσο επιδέξια είναι στην εκτίμηση της μέσης παραγόμενης/καταναλισκόμενης ηλεκτρικής ενέργειας, ενώ παράλληλα τιμωρούνται και τα πιο μεγάλα σφάλματα που συνήθως εμφανίζονται κατά τις ώρες αιχμής. Από την άλλη πλευρά, τα απόλυτα σφάλματα, όπως το MAE, βελτιστοποιούνται για τη διάμεσο (Schwertman et al., 1990), παρέχοντας στοιχεία για το πόσο ακριβή είναι τα μοντέλα που αναπτύχθηκαν στην πρόβλεψη των τιμών παραγωγής/κατανάλωσης ηλεκτρικής ενέργειας που εμφανίζονται πιο συχνά, ενώ παράλληλα είναι πιο ανθεκτικά σε εξαιρετικά μεγάλα σφάλματα και εστιάζουν σε ώρες μη αιχμής. Τέλος, ο συντελεστής συσχέτισης υποδεικνύει κατά πόσον οι προβλέψεις συσχετίζονται επαρκώς γραμμικά με τις πραγματικές μελλοντικές τιμές ή όχι, δηλαδή κατά πόσον τα μοντέλα που αναπτύχθηκαν είναι ικανά να προβλέψουν τη διακύμανση της σειράς-στόχου. Αν και κανένα μέτρο ακρίβειας δεν είναι τέλειο, έχοντας πλεονεκτήματα και μειονεκτήματα (Koutsandreas et al., 2021), πιστεύουμε ότι αυτό το σύνολο μέτρων μπορεί να συνοψίσει αποτελεσματικά τη συνολική απόδοση των προτεινόμενων μοντέλων στις πιο κρίσιμες διαστάσεις του εξεταζόμενου έργου πρόβλεψης.

Τα αποτελέσματα συνοψίζονται στον Πίνακα 9.2. Όπως φαίνεται, και τα δύο σύνολα είναι επαρκώς ακριβή δεδομένου του ορίζοντα πρόβλεψης μιας εβδομάδας, αποτυπώνοντας τα ημερήσια πρότυπα των βασικών μεταβλητών που εξετάζει η προτεινόμενη μέθοδος βελτιστοποίησης. Επιπλέον, όπως φαίνεται στο Σχήμα 9.8, τα σύνολα καταφέρνουν να συλλάβουν αποτελεσματικά την εποχικότητα, τις τάσεις και τις μεταβολές που σχετίζονται με τις καιρικές συνθήκες των υπό πρόβλεψη σειρών, τόσο σε θερινές όσο και σε χειμερινές περιόδους.

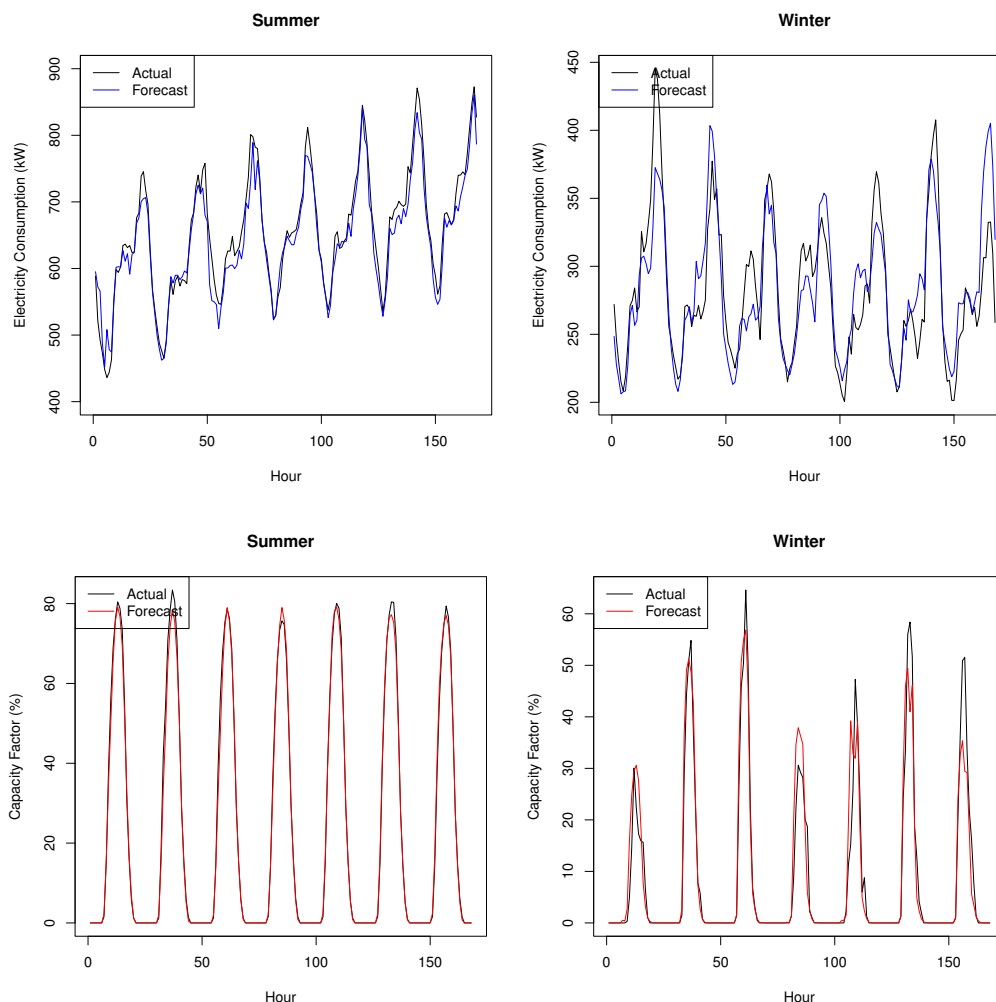
Πίνακας 9.2: Απόδοση πρόβλεψης (ακρίβεια) του συνόλου των μοντέλων MM που χρησιμοποιήθηκαν στη μελέτη περίπτωσης.

Μέτρηση	κατανάλωση ηλεκτρικής ενέργειας	ηλιακή ενέργεια
<i>RMSE</i>	32.58	0.34
<i>MAE</i>	22.54	0.14
<i>r_{y,f}</i>	0.97	0.96

9.4.4 Αποτελέσματα Βελτιστοποίησης

Έχοντας λάβει τις προβλέψεις για κάθε εβδομάδα που λαμβάνει χώρα η προσομοίωση, εφαρμόζεται ο προτεινόμενος αλγόριθμος βελτιστοποίησης για την κατάλληλη προσαρμογή


Σχήμα 9.8: Παραδείγματα που απεικονίζουν τις επιδόσεις των μοντέλων πρόβλεψης της κατανάλωσης ηλεκτρικής ενέργειας (επάνω) και της ηλιακής ενέργειας (κάτω). Τα παραδείγματα αναφέρονται σε δύο τυχαία επιλεγμένες καλοκαιρινές (2020-07-31 έως 2020-08-06) και χειμερινές (2020-12-04 έως 2020-12-10) εβδομάδες της περιόδου αξιολόγησης.



του προγράμματος λειτουργίας των αντλιών και την εξοικονόμηση αιχμών. Στο Σχήμα 9.9 παρατίθενται δύο ενδεικτικά παραδείγματα της διαδικασίας βελτιστοποίησης, παρουσιάζοντας την κατανάλωση ηλεκτρικής ενέργειας σε μια θερινή και μια χειμερινή εβδομάδα της προσομοίωσης υπό τον τρόπο λειτουργίας BaU, καθώς και τον ευέλικτο και τον περιορισμένο τρόπο λειτουργίας. Παρατηρούμε ότι και οι δύο τρόποι βελτιστοποίησης οδηγούν σε παρόμοια κέρδη όσον αφορά τη διακύμανση, εξοικονομώντας αποτελεσματικά τις αιχμές και αυξάνοντας την κατανάλωση σε ώρες χαμηλότερης έντασης. Επιπλέον, όπως αναμενόταν, ο αντίκτυπος της εξοικονόμησης αιχμών είναι πιο εμφανής τη θερινή εβδομάδα, καθώς τόσο η παραγωγή ηλεκτρικής ενέργειας με βάση τα Φ/Β όσο και η ποσότητα του φορτίου που μπορεί να μετατοπιστεί είναι μεγαλύτερες σε σύγκριση με τη χειμερινή εβδομάδα.

Οι ημερήσιες αλλαγές που εφαρμόζονται στις αρχικές ώρες λειτουργίας των αντλιών συνοψίζονται στο Σχήμα 9.10 για κάθε τρόπο λειτουργίας βελτιστοποίησης ξεχωριστά. Όπως φαίνεται, και στις δύο περιπτώσεις ο αλγόριθμος προτείνει τη διακοπή της λειτουργίας των αντλιών από τις 08:00 έως τις 14:00 και από τις 18:00 έως τις 23:00. Αυτό οφείλεται στο γεγονός ότι σε αυτά τα χρονικά διαστήματα η αναμενόμενη κατανάλωση είναι σημαντική, ενώ ταυτόχρονα η ηλεκτρική ενέργεια που παράγεται από τα Φ/Β πλαίσια δεν επαρκεί για να καλύψει επαρκώς τη ζήτηση. Κατά συνέπεια, ο αλγόριθμος προτείνει τη λειτουργία των

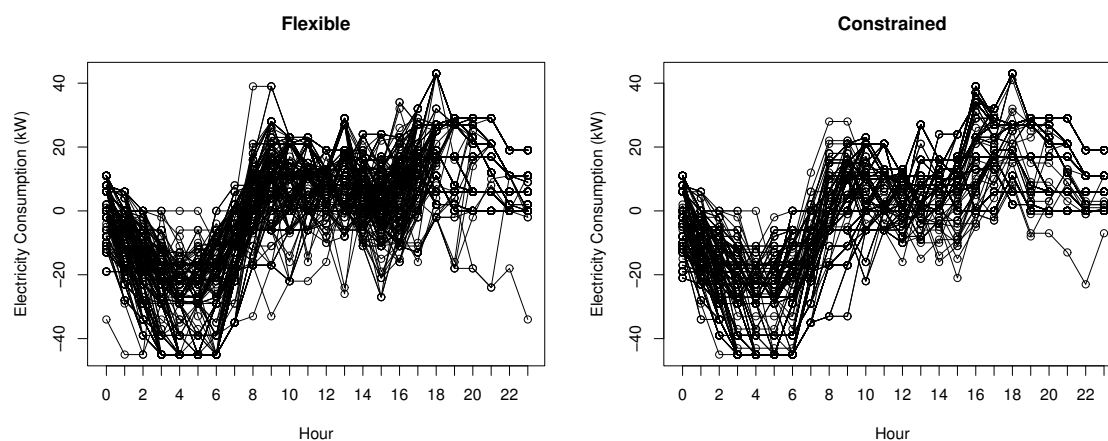
Σχήμα 9.9: Παραδείγματα που απεικονίζουν τον τρόπο με τον οποίο προσαρμόζεται η συνολική κατανάλωση ηλεκτρικής ενέργειας του νησιού όταν λαμβάνονται υπόψη οι ευέλικτοι και οι περιορισμένοι τρόποι βελτιστοποίησης λειτουργίας για την εξοικονόμηση αιχμών. Τα παραδείγματα αναφέρονται σε δύο τυχαία επιλεγμένες καλοκαιρινές (2020-07-31 έως 2020-08-06) και χειμερινές (2020-12-04 έως 2020-12-10) εβδομάδες της περιόδου αξιολόγησης. Παρουσιάζεται επίσης η ηλιακή ενέργεια για να διευκολυνθούν οι συγκρίσεις.



αντλιών είτε τις πρώτες πρωινές ώρες (01:00 έως 07:00), όπου η κατανάλωση ηλεκτρικής ενέργειας είναι στο ελάχιστο επίπεδο, είτε το απόγευμα (15:00 έως 17:00), όπου η ηλιακή ενέργεια είναι ακόμη αξιοσημείωτη.

Η απόδοση της προτεινόμενης μεθόδου βελτιστοποίησης σε όλη την περίοδο προσομοίωσης συνοψίζεται στον Πίνακα 9.3 όπου για την αξιολόγησή της χρησιμοποιούνται οι KPIs που παρουσιάστηκαν στην υποενότητα 9.4.2. Παρατηρούμε ότι, στο πλαίσιο του ευέλικτου τρόπου λειτουργίας, η ημερήσια και εβδομαδιαία απόκλιση της κατανάλωσης μειώνεται κατά περίπου 20% και 17%, αντίστοιχα. Τα αποτελέσματα είναι ελαφρώς χειρότερα υπό τον περιορισμένο τρόπο λειτουργίας, μειούμενα σε περίπου 19% και 16%, αντίστοιχα. Ομοίως, λόγω των ενεργειών μετατόπισης φορτίου, η μέση διαφορά μεταξύ της μέγιστης και της ελάχιστης κατανάλωσης ηλεκτρικής ενέργειας που αναφέρεται για την ευέλικτη λειτουργία σε ημερήσια και εβδομαδιαία βάση μειώνεται κατά περισσότερο από 17% και 12%, αντίστοιχα. Δεδομένου ότι η εγκατεστημένη ισχύς των αντλιοστασίων νερού (45 kW) αντιπροσωπεύει μόλις το 13% και το 5% της μέσης και μέγιστης κατανάλωσης ηλεκτρικής ενέργειας που αναφέρθηκε για την περίοδο προσομοίωσης, συμπεραίνουμε ότι η προτεινόμενη μέθοδος παρουσιάζει

Σχήμα 9.10: Μετατόπιση φορτίου που πραγματοποιείται στο πλαίσιο του ευέλικτου και του περιορισμένου τρόπου βελτιστοποίησης λειτουργίας. Κάθε γραμμή αντιπροσωπεύει τις ημερήσιες διαφορές που αναφέρθηκαν μεταξύ της λειτουργίας BaU και των βελτιστοποιημένων λειτουργιών (ευέλικτη ή περιορισμένη). Οι θετικές τιμές υποδεικνύουν ώρες κατά τις οποίες ο αλγόριθμος πρότεινε τη λειτουργία των αντλιοστασίων νερού, ενώ οι αρνητικές τιμές υποδεικνύουν ώρες κατά τις οποίες ο αλγόριθμος πρότεινε τη λειτουργία των αντλιοστασίων νερού.



πολλές δυνατότητες και ότι η αξιοποίησή της μπορεί να οδηγήσει σε σημαντικές βελτιώσεις όσον αφορά τη σταθερότητα, ιδίως όταν τα φορτία των ενεργοβόρων συστημάτων μπορούν να μετατοπιστούν ευέλικτα.

Πίνακας 9.3: Απόδοση της προτεινόμενης μεθόδου όσον αφορά την εξοικονόμηση αιχμής. Χρησιμοποιούνται διάφοροι δείκτες KPI για την αξιολόγηση της ημερήσιας και εβδομαδιαίας απόκλισης της κατανάλωσης ηλεκτρικής ενέργειας της Τήλου όταν δεν μετατοπίζονται φορτία (BaU), επιτρέπεται η ευέλικτη μετατόπιση φορτίου και πραγματοποιείται περιορισμένη μετατόπιση φορτίου. Παρέχονται επίσης οι ποσοστιαίες βελτιώσεις των δύο τρόπων βελτιστοποίησης της μετατόπισης φορτίου σε σχέση με τον τρόπο λειτουργίας BaU.

KPI	BaU	Flexible		Constrained	
		Absolute Values	Percentage Improvements (%)	Absolute Values	Percentage Improvements (%)
SD_{day}	51.58	41.23	20.07	41.81	18.94
SD_{week}	54.93	45.73	16.75	46.19	15.91
$Max - Min_{day}$	175.01	143.79	17.84	147.74	15.58
$Max - Min_{week}$	242.12	212.90	12.07	216.66	10.52
$Max - Mean_{day}$	98.99	87.23	11.88	87.27	11.84
$Max - Mean_{week}$	142.02	130.40	8.18	130.01	8.46

Δεδομένου ότι η προτεινόμενη μέθοδος εξοικονόμησης αιχμής επηρεάζεται εν μέρει από την ποσότητα της ηλεκτρικής ενέργειας που παράγεται από τις ΑΠΕ, η οποία στην προκειμένη περίπτωση είναι σχετικά μικρή σε σύγκριση με την ηλεκτρική ενέργεια που καταναλώνεται, τόσο από το πλήρες σύστημα όσο και από τα αντλιοστάσια νερού, επεκτείνουμε την ανάλυση με τεχνητή κλιμάκωση της εγκατεστημένης ισχύος του υφιστάμενου Φ/Β συστήματος κατά έναν παράγοντα² των 10 και 40. Μετά την κλιμάκωση των ιστορικών δεδομένων παραγωγής

²Ο παράγοντας 10 επιλέχθηκε έτσι ώστε η παραγόμενη ηλεκτρική ενέργεια να έχει την ίδια κλίμακα

Φ/Β, επαναλαμβάνουμε το πλήρες πείραμα και υπολογίζουμε εκ νέου τους δείκτες KPI που παρουσιάστηκαν παραπάνω για να εκτιμήσουμε την επίδραση της ποσότητας της παραγόμενης ηλεκτρικής ενέργειας στην πραγματοποιημένη μέγιστη ροπή. Τα αποτελέσματα παρουσιάζονται στον Πίνακα 9.4.

Πίνακας 9.4: Απόδοση της προτεινόμενης μεθόδου όσον αφορά την εξοικονόμηση αιχμής (SD_{day}) όταν η παραγωγή ηλεκτρικής ενέργειας από Φ/Β αυξάνεται κατά 10 και 40 φορές. Για τη διευκόλυνση των συγκρίσεων, οι βελτιώσεις των δύο τρόπων λειτουργίας μετατόπισης φορτίου σε σχέση με τον τρόπο λειτουργίας BaU παρέχονται ως ποσοστά.


KPI	Flexible Ποσοστιαίες βελτιώσεις (%)	Constrained
Αρχική κλίμακα	20.07	18.94
Αναβάθμιση κλίμακας ($\times 10$)	16.68	15.87
Κλιμάκωση ($\times 40$)	11.96	11.34

Μπορεί να φανεί ότι η προτεινόμενη μέθοδος έχει πάντα θετική επίδραση στην ημερήσια απόκλιση της κατανάλωσης ηλεκτρικής ενέργειας, με τις βελτιώσεις να κυμαίνονται από περίπου 12% (συντελεστής κλιμάκωσης 40) έως 20% (συντελεστής κλιμάκωσης 1, δηλαδή αρχική κλίμακα). Επιπλέον, όπως αναμενόταν, ο περιορισμένος τρόπος λειτουργίας είναι ελαφρώς λιγότερο αποτελεσματικός σε σύγκριση με τον ευέλικτο, με αποτέλεσμα περίπου 1-2% λιγότερη βελτίωση. Είναι ενδιαφέρον ότι, όταν λαμβάνει χώρα κλιμάκωση, οι βελτιώσεις μειώνονται με έναν αποσβεσμένο, μη γραμμικό τρόπο. Αυτό οφείλεται στο γεγονός ότι, όπως παρουσιάστηκε νωρίτερα σε αυτή την ενότητα και φαίνεται στο Σχήμα 9.9, υπάρχει μια αξιοσημείωτη αναντιστοιχία μεταξύ των ωρών αιχμής της κατανάλωσης και της παραγωγής Φ/Β. Ως αποτέλεσμα, όταν αυξάνεται η Φ/Β παραγωγή, η κατανάλωση μειώνεται κυρίως σε ώρες όπου η ζήτηση είναι ήδη σχετικά χαμηλή και οι οποίες θα ήταν επιλέξιμες για μετατόπιση φορτίου. Επομένως, είναι προφανές ότι η ποσότητα της παραγόμενης ηλεκτρικής ενέργειας και η κατανομή της κατά τη διάρκεια της ημέρας επηρεάζει σε κάποιο βαθμό την απόδοση της προτεινόμενης μεθόδου και ότι η μεγαλύτερη παραγωγή ΑΠΕ δεν εγγυάται απαραίτητα καλύτερη απόδοση όσον αφορά την εξοικονόμηση αιχμής. Η επίδραση αυτή απεικονίζεται καλύτερα στο Σχήμα 9.11 όπου η εγκατεστημένη ισχύς του υφιστάμενου Φ/Β συστήματος κλιμακώνεται τεχνητά κατά ένα συντελεστή από 1 έως 40 με βήμα 5 και αναφέρονται οι διαφορές που υπολογίζονται σε όρους SD_{day} μεταξύ του BAU και του ευέλικτου τρόπου λειτουργίας, τόσο σε απόλυτες τιμές όσο και ως ποσοστά. Όπως φαίνεται, παρόλο που η προτεινόμενη μέθοδος βελτιώνει τον επιλεγμένο δείκτη KPI κατά περισσότερο από 8 kWh (ελαφρώς μεγαλύτερη από τη μέση ετήσια κατανάλωση των αντλιών νερού), οι ποσοστιαίες βελτιώσεις συρρικνώνονται καθώς αυξάνεται η εγκατεστημένη ισχύς. Επιπλέον, αφού ο συντελεστής κλιμάκωσης φτάσει σε μια τιμή 20 (περίπου 25% της μέσης ετήσιας κατανάλωσης), οι απόλυτες βελτιώσεις σταθεροποιούνται γύρω στο 13%. Με βάση τα παραπάνω, απομακρυσμένα νησιά όπως η Τήλος θα πρέπει να καθορίσουν προσεκτικά την κλίμακα της παραγωγής τους από ΑΠΕ με βάση το προφίλ της ενεργειακής ζήτησης και το ποσό του φορτίου που μπορεί να μετατοπιστεί. Παρόλο που ο καθορισμός της αύξησης των ΑΠΕ που θα ήταν κερδοφόρα σε τέτοιες συνθήκες είναι ένα δύσκολο έργο, καθώς υπόκειται στην αναμενόμενη απόδοση της επένδυσης μεταξύ άλλων παραγόντων, για την περίπτωση της Τήλου διαπιστώνουμε ότι ο βέλτιστος συντελεστής κλιμάκωσης των Φ/Β λόγω της εξοικονόμησης αιχμής συνδέεται με τη μέση ετήσια κατανάλωση των αντλιών νερού και ότι η υπάρχουσα εγκατεστημένη ισχύς είναι επαρκής για τη βέλτιστη κατανομή του φορτίου των αντλιών νερού.

Για να αξιολογηθεί ρητά η επίδραση της ακρίβειας των προβλέψεων στην απόδοση της προτεινόμενης μεθόδου βελτιστοποίησης, διερευνάται η σχέση μεταξύ των ημερήσιων κερδών

με το φορτίο που μετατοπίζεται. Ο συντελεστής 40 παρέχει ένα σενάριο όπου η παραγόμενη ηλεκτρική ενέργεια είναι μεγαλύτερη από το φορτίο που μετατοπίζεται.

Σχήμα 9.11: Απόδοση της προτεινόμενης μεθόδου (ευέλικτος τρόπος λειτουργίας) όσον αφορά την εξοικονόμηση αιχμής (SD_{day}) όταν η παραγωγή ηλεκτρικής ενέργειας από Φ/Β αυξάνεται κατά έναν παράγοντα από 1 έως 40. Οι βελτιώσεις σε σχέση με τη λειτουργία BaU παρέχονται τόσο σε απόλυτες τιμές όσο και σε ποσοστά.



της προτεινόμενης προσέγγισης όσον αφορά τη σταθερότητα της κατανάλωσης ηλεκτρικής ενέργειας ($SDgains_{day}$) και των αντίστοιχων ημερήσιων MAE που αναφέρονται για τις παραγόμενες προβλέψεις κατανάλωσης ηλεκτρικής ενέργειας (e_c) και παραγωγής Φ/Β (e_p). Επιπλέον, δεδομένου ότι η ποσότητα των μετατοπίσιμων φορτίων (SL) αναμένεται να επηρεάσει αυτά τα κέρδη, το αιτιώδες μοντέλο διαρθρώνεται ως εξής:

$$SD\hat{gains}_{day,i} = a_0 + a_1 \times e_{c,i} + a_2 \times e_{p,i} + a_3 \times SL_i,$$

όπου $SD\hat{gains}_{day,i}$ είναι τα αναμενόμενα κέρδη σε όρους σταθερότητας την ημέρα i και $a_0 \dots a_3$ οι συντελεστές του εκτιμώμενου μοντέλου γραμμικής παλινδρόμησης. Οι τιμές αυτών των συντελεστών και η σημαντικότητά τους συνοψίζονται στον Πίνακα 9.5 για την περίπτωση του ευέλικτου τρόπου λειτουργίας, λαμβάνοντας επίσης υπόψη έναν συντελεστή κλιμάκωσης 1 (αρχικά δεδομένα), 10 και 40 για την παραγόμενη ηλεκτρική ενέργεια, ομοίως με την ανάλυση που διεξήχθη προηγουμένως. Όπως φαίνεται, με εξαίρεση την περίπτωση όπου δεν πραγματοποιείται κλιμάκωση, όλες οι επεξηγηματικές μεταβλητές που χρησιμοποιήθηκαν είναι στατιστικά σημαντικές για την εκτίμηση των κερδών σταθερότητας. Επιπλέον, τα αποτελέσματα της προσομοίωσης δείχνουν ότι υψηλότερα κέρδη είναι δυνατά όταν μπορούν να μετατοπιστούν μεγαλύτερες ποσότητες φορτίων και να πραγματοποιηθούν χαμηλότερα σφάλματα πρόβλεψης. Είναι ενδιαφέρον ότι, όταν η Φ/Β παραγωγή είναι σημαντική, η παραγωγή ακριβών προβλέψεων για την ηλιακή ενέργεια είναι πιο σημαντική για τη μεγιστοποίηση των κερδών από την ακριβή πρόβλεψη της κατανάλωσης, αποτέλεσμα που μπορεί να αποδοθεί στον σημαντικό ρόλο που διαδραματίζουν οι προβλέψεις για την παραγωγή ηλεκτρικής ενέργειας από Φ/Β στη διαδικασία βελτιστοποίησης.

9.5 Συμπεράσματα

Στην παρούσα μελέτη, παρουσιάστηκε μια ολοκληρωμένη μέθοδος για την έξυπνη διαχείριση της ενέργειας με στόχο την εξομάλυνση της κατανάλωσης ηλεκτρικής ενέργειας σε απομακρυσμένα νησιωτικά συστήματα ηλεκτρικής ενέργειας. Η καινοτόμος μέθοδος βασίστηκε σε δύο πυλώνες: την ανάπτυξη ενός συνόλου μοντέλων MM, που χρησιμοποιούνται για την ακριβή πρόβλεψη της παραγωγής ΑΠΕ και της κατανάλωσης ηλεκτρικής ενέργειας, και τον

Πίνακας 9.5: Συνοπτική παρουσίαση του μοντέλου αιτιώδους γραμμικής παλινδρόμησης που χρησιμοποιήθηκε για τη συσχέτιση των κερδών που επιτυγχάνονται από την προτεινόμενη μέθοδο όσον αφορά τη σταθερότητα της κατανάλωσης ηλεκτρικής ενέργειας ($KPI\ SD_{day}$) με το σφάλμα πρόβλεψης της κατανάλωσης ηλεκτρικής ενέργειας (e_c), το σφάλμα πρόβλεψης της παραγωγής ηλεκτρικής ενέργειας από Φ/B (e_p) και το ποσό του φορτίου που μπορεί να μετατοπιστεί (SL). Οι συντελεστές με σημαντικότητα μεγαλύτερη από 95% σημειώνονται με (*).

Coefficient	Value	Standard Error	t value	Significance
Scale up ($\times 1$) - Original data				
<i>Intercept</i>	3.071	0.581	5.285	*
e_p	-2.41	1.842	-1.310	
e_c	-0.073	0.012	-5.862	*
<i>SL</i>	0.036	0.001	25.532	*
Scale up ($\times 10$)				
<i>Intercept</i>	2.054	0.612	3.356	*
e_p	-0.345	0.194	-1.779	*
e_c	-0.055	0.013	-4.164	*
<i>SL</i>	0.033	0.001	22.200	*
Scale up ($\times 40$)				
<i>Intercept</i>	3.756	0.445	8.438	*
e_p	-0.231	0.035	-6.536	*
e_c	-0.045	0.010	-4.651	*
<i>SL</i>	0.027	0.001	25.270	*

σχεδιασμό ενός αλγορίθμου χρονοπρογραμματισμού που μετατοπίζει με βέλτιστο τρόπο τις ώρες λειτουργίας των αντλιοστασίων νερού προς διαστήματα χαμηλού αναμενόμενου φορτίου. Τα αποτελέσματά μας υποδεικνύουν ότι είναι δυνατή η σημαντική μείωση των αιχμών, ενώ παράλληλα διασφαλίζεται η διαθεσιμότητα του νερού και η εκπλήρωση των περιορισμών που σχετίζονται με τη λειτουργία του συστήματος ύδρευσης.

Τα μοντέλα πρόβλεψης που αναπτύχθηκαν ήταν γρήγορα στον υπολογισμό, εύκολα στην εφαρμογή και αξιοποιούσαν μικρό αριθμό μεταβλητών εισόδου, συμπεριλαμβανομένων ορισμένων χαρακτηριστικών αυτόματης παλινδρόμησης για την πρόβλεψη φορτίου και προβλέψεων καιρού για την πρόβλεψη παραγωγής ΑΠΕ. Τα μοντέλα κατάφεραν να αποτυπώσουν αποτελεσματικά τα ημερήσια και μηνιαία πρότυπα των μεταβλητών πρόβλεψης και παρείχαν ικανοποιητικά αποτελέσματα από άποψη ακρίβειας. Ο προτεινόμενος αλγόριθμος βελτιστοποίησης εφαρμόστηκε στη συνέχεια για τον κατάλληλο προγραμματισμό του προγράμματος λειτουργίας των αντλιοστασίων, χρησιμοποιώντας ως δεδομένα εισόδου τις προβλέψεις που παρήγαγαν τα μοντέλα για κάθε εβδομάδα, καθώς και τα προφίλ λειτουργίας των αντλιοστασίων. Ο αλγόριθμος σχεδιάστηκε για να υποστηρίζει τόσο ευέλικτους όσο και περιορισμένους τρόπους λειτουργίας.

Η προτεινόμενη μέθοδος αξιολογήθηκε μέσω μιας προσομοίωσης που κάλυψε ένα πλήρες έτος λειτουργίας, με αποτέλεσμα τη μείωση της ημερήσιας και εβδομαδιαίας απόκλισης της κατανάλωσης του νησιού σε ποσοστό μεγαλύτερο από 15% και στους δύο τρόπους λειτουργίας. Το προτεινόμενο ημερήσιο σχέδιο λειτουργίας των αντλιοστασίων περιελάμβανε τις πρωινές ώρες, όπου η κατανάλωση είναι συνήθως σχετικά χαμηλή, και τις απογευματινές ώρες, λόγω της παραγωγής ενέργειας που προέρχεται από τα Φ/B . Επιπλέον, τα δυνητικά κέρδη της προτεινόμενης προσέγγισης συνδέονται στενά με την ποσότητα του φορτίου που μπορεί να μετατοπιστεί κάθε μέρα και την ακρίβεια των χρησιμοποιούμενων προβλέψεων, ιδίως αυτών της παραγωγής ηλεκτρικής ενέργειας από Φ/B . Επιπλέον, τα αποτελέσματα δείχνουν ότι η ποσότητα της παραγόμενης ηλεκτρικής ενέργειας, καθώς και η αντιστοίχισή της με την

καταναλισκόμενη ηλεκτρική ενέργεια, μπορεί να επηρεάσει τις δυνατότητες της προτεινόμενης μεθόδου και ότι η υψηλότερη παραγωγή ηλεκτρικής ενέργειας δεν εγγυάται πάντα καλύτερες επιδόσεις όσον αφορά την εξοικονόμηση αιχμής.

Ένα μελλοντικό βήμα για τη βελτίωση της προτεινόμενης μεθόδου είναι η ανάπτυξη μιας φιλικής προς το χρήστη διεπαφής, όπου οι διαχειριστές ενέργειας θα μπορούν να αξιολογούν τα οφέλη των αλγορίθμων που αναπτύχθηκαν, προσομοιώνοντας διαφορετικούς τρόπους λειτουργίας. Ένας άλλος δρόμος για μελλοντική έρευνα είναι η επέκταση του αλγορίθμου βελτιστοποίησης για την υποστήριξη συστημάτων που περιλαμβάνουν αποθήκευση ενέργειας ή άλλους τύπους ΑΠΕ, όπως αιολικές, βιομάζας και γεωθερμικές μονάδες. Τέλος, θα μπορούσαν να διερευνηθούν διαφορετικές στρατηγικές ομαδοποίησης για την περαιτέρω βελτίωση της ακρίβειας πρόβλεψης, λαμβάνοντας υπόψη και άλλες παραλλαγές των βασικών μοντέλων MM.

Βιβλιογραφία

- Abbasi, R. A., Javaid, N., Ghuman, M. N. J., Khan, Z. A., Ur Rehman, S., and Amanullah (2019). Short Term Load Forecasting Using XGBoost. In Barolli, L., Takizawa, M., Xhafa, F., and Enokido, T., editors, *Web, Artificial Intelligence and Network Applications*, pages 1120–1131, Cham. Springer International Publishing.
- Adeniran, A. and Oyelowo, M. (2013). An EPANET analysis of water distribution network of the University of Lagos, Nigeria. *Journal of Engineering Research*, 18(2):69–83.
- Aguilar Madrid, E. and Antonio, N. (2021). Short-Term Electricity Load Forecasting with Machine Learning. *Information*, 12(2).
- Bojer, C. S. and Meldgaard, J. P. (2021). Kaggle forecasting competitions: An overlooked learning opportunity. *International Journal of Forecasting*, 37(2):587–603.
- Bozkurt, O. O., Biricik, G., and Taysi, Z. C. (2017). Artificial neural network and sarima based models for power load forecasting in turkish electricity market. *PLOS ONE*, 12(4):1–24.
- Campana, P. E., Li, H., Zhang, J., Zhang, R., Liu, J., and Yan, J. (2015). Economic optimization of photovoltaic water pumping systems for irrigation. *Energy Conversion and Management*, 95:32–41.
- Carns, K. (2005). Bringing energy efficiency to the water and wastewater industry: How do we get there? *Proceedings of the Water Environment Federation*, 2005(7):7650–7659.
- Chapaloglou, S., Nesiadis, A., Iliadis, P., Atsonios, K., Nikolopoulos, N., Grammelis, P., Yiakopoulos, C., Antoniadis, I., and Kakaras, E. (2019). Smart energy management algorithm for load smoothing and peak shaving based on load forecasting of an island’s power system. *Applied energy*, 238:627–642.
- Chen, T. and Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pages 785–794.
- Chua, K., Yang, W., Er, S., and Ho, C. (2014). Sustainable energy systems for a remote island community. *Applied Energy*, 113:1752–1763.
- Costa, L., Ramos, H., and De Castro, M. (2010). Hybrid genetic algorithm in the optimization of energy costs in water supply networks. *Water Science and Technology: Water Supply*, 10(3):315–326.
- Eseye, A. T., Zhang, J., and Zheng, D. (2018). Short-term photovoltaic solar power forecasting using a hybrid Wavelet-PSO-SVM model based on SCADA and Meteorological information. *Renewable Energy*, 118:357–367.
- Farina, G., Creaco, E., and Franchini, M. (2014). Using EPANET for modelling water distribution systems with users along the pipes. *Civil Engineering and Environmental Systems*, 31(1):36–50.
- Feng, Z.-k., Niu, W.-j., Cheng, C.-t., and Zhou, J.-z. (2017). Peak shaving operation of hydro-thermal-nuclear plants serving multiple power grids by linear programming. *Energy*, 135:210–219.
- Feng, Z.-k., Niu, W.-j., Wang, W.-c., Zhou, J.-z., and Cheng, C.-t. (2019). A mixed integer linear programming model for unit commitment of thermal plants with peak shaving operation aspect in regional power grid lack of flexible hydropower energy. *Energy*, 175:618–629.

- Ferbar Tratar, L. and Strmčnik, E. (2016). The comparison of holt–winters method and multiple regression method: A case study. *Energy*, 109:266–276.
- Ghadami, N., Gheibi, M., Kian, Z., Faramarz, M. G., Naghedi, R., Eftekhari, M., Fathollahi-Fard, A. M., Dulebenets, M. A., and Tian, G. (2021). Implementation of solar energy in smart cities using an integration of artificial neural network, photovoltaic system and classical delphi methods. *Sustainable Cities and Society*, 74:103149.
- Ghoneim, A. (2006). Design optimization of photovoltaic powered water pumping systems. *Energy conversion and management*, 47(11-12):1449–1463.
- Gikas, P. and Angelakis, A. N. (2009). Water resources management in Crete and in the Aegean Islands, with emphasis on the utilization of non-conventional water sources. *Desalination*, 248(1-3):1049–1064.
- Hassan, M. A., Khalil, A., Kaseb, S., and Kassem, M. (2017). Exploring the potential of tree-based ensemble methods in solar radiation modeling. *Applied Energy*, 203:897–916.
- Haykin, S. (1994). *Neural networks: a comprehensive foundation*. Prentice Hall PTR.
- Hewamalage, H., Bergmeir, C., and Bandara, K. (2021). Recurrent Neural Networks for Time Series Forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1):388–427.
- IEA (2016). Energy and air pollution: World energy outlook special report 2016. <https://www.iea.org/reports/energy-and-air-pollution>.
- In, Y. and Jung, J.-Y. (2021). Simple averaging of direct and recursive forecasts via partial pooling using machine learning. *International Journal of Forecasting*.
- Ju, Y., Sun, G., Chen, Q., Zhang, M., Zhu, H., and Rehman, M. U. (2019). A model combining convolutional neural network and LightGBM algorithm for ultra-short-term wind power forecasting. *Ieee Access*, 7:28309–28318.
- Kazantzis, M., Simpson, A., Kwong, D., and Tan, S. (2002). A new methodology for optimizing the daily operations of a pumping plant. In *Proceedings of 2002 Conference on Water Resources Planning*. Roanoke, USA: ASCE.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., and Liu, T.-Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. *Advances in neural information processing systems*, 30:3146–3154.
- Kernan, R., Liu, X., McLoone, S., and Fox, B. (2017). Demand side management of an urban water supply using wholesale electricity price. *Applied Energy*, 189:395–402.
- Kolassa, S. (2016). Evaluating predictive count data distributions in retail sales forecasting. *International Journal of Forecasting*, 32(3):788–803.
- Kong, X., Liu, C., Shen, Y., Hu, W., and Ma, T. (2020). Power supply reliability evaluation based on big data analysis for distribution networks considering uncertain factors. *Sustainable Cities and Society*, 63:102483.
- Korkmaz, D. (2021). SolarNet: A hybrid reliable model based on convolutional neural network and variational mode decomposition for hourly photovoltaic power forecasting. *Applied Energy*, 300:117410.
- Kourentzes, N., Barrow, D. K., and Crone, S. F. (2014). Neural network ensemble operators for time series forecasting. *Expert Systems with Applications*, 41(9):4235–4244.

- Koutsandreas, D., Spiliotis, E., Petropoulos, F., and Assimakopoulos, V. (2021). On the selection of forecasting accuracy measures. *Journal of the Operational Research Society*.
- Kumar, A., Kumar, K., Bharanidharan, B., Matial, N., Dey, E., Singh, M., Thakur, V., Sharma, S., and Malhotra, N. (2015). Design of water distribution system using EPANET. *International Journal of Advanced Research*, 3(9):789–812.
- Kuster, C., Rezgui, Y., and Mourshed, M. (2017). Electrical load forecasting models: A critical systematic review. *Sustainable cities and society*, 35:257–270.
- Lange, C., Rueß, A., Nuß, A., Öchsner, R., and März, M. (2020). Dimensioning battery energy storage systems for peak shaving based on a real-time control algorithm. *Applied Energy*, 280:115993.
- Li, C. (2020). Designing a short-term load forecasting model in the urban smart grid system. *Applied Energy*, 266:114850.
- Liao, S., Liu, H., Liu, Z., Liu, B., Li, G., and Li, S. (2021). Medium-term peak shaving operation of cascade hydropower plants considering water delay time. *Renewable Energy*, 179:406–417.
- Liu, X., Xiao, Z., Zhu, R., Wang, J., Liu, L., and Ma, M. (2020). Edge sensing data-imaging conversion scheme of load forecasting in smart grid. *Sustainable Cities and Society*, 62:102363.
- Liu, Y., Luo, H., Zhao, B., Zhao, X., and Han, Z. (2018). Short-Term Power Load Forecasting Based on Clustering and XGBoost Method. In *2018 IEEE 9th International Conference on Software Engineering and Service Science (ICSESS)*, pages 536–539.
- Loh, W.-Y. (2011). Classification and regression trees. *Wiley interdisciplinary reviews: data mining and knowledge discovery*, 1(1):14–23.
- Loh, W.-Y. (2014). Fifty years of classification and regression trees. *International Statistical Review*, 82(3):329–348.
- Luna, T., Ribau, J., Figueiredo, D., and Alves, R. (2019). Improving energy efficiency in water supply systems with pump scheduling optimization. *Journal of cleaner production*, 213:342–356.
- Ma, F. and Yan, X. (2019). Research on the energy consumption estimation method of pure electric vehicle based on xgboost. In *2019 3rd International Conference on Electronic Information Technology and Computer Engineering (EITCE)*, pages 1021–1026. IEEE.
- Mackle, G., Savic, G., and Walters, G. A. (1995). Application of genetic algorithms to pump scheduling for water supply. In *First international conference on genetic algorithms in engineering systems: innovations and applications*, pages 400–405. IET.
- Makridakis, S., Spiliotis, E., and Assimakopoulos, V. (2018). Statistical and machine learning forecasting methods: Concerns and ways forward. *PLOS ONE*, 13(3):1–26.
- Makridakis, S., Spiliotis, E., and Assimakopoulos, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1):54–74.
- Mankad, A. and Tapsuwan, S. (2011). Review of socio-economic drivers of community acceptance and adoption of decentralised water systems. *Journal of environmental management*, 92(3):380–391.

- Marchi, A., Simpson, A. R., and Lambert, M. F. (2017). Pump operation optimization using rule-based controls. *Procedia Engineering*, 186:210–217.
- Marinakakis, V. (2020). Big data for energy management and energy-efficient buildings. *Energies*, 13(7):1555.
- Marinakakis, V., Doukas, H., Tsapelas, J., Mouzakitis, S., Sicilia, Á., Madrazo, L., and Sgouridis, S. (2020). From big data to smart energy services: An application for intelligent energy management. *Future Generation Computer Systems*, 110:572–586.
- Nasios, I. and Vogklis, K. (2022). Blending gradient boosted trees and neural networks for point and probabilistic forecasting of hierarchical time series. *International Journal of Forecasting*.
- Nespoli, A., Ogliari, E., Leva, S., Massi Pavan, A., Mellit, A., Lughi, V., and Dolara, A. (2019). Day-Ahead Photovoltaic Forecasting: A Comparison of the Most Effective Techniques. *Energies*, 12(9).
- Olcan, C. (2015). Multi-objective analytical model for optimal sizing of stand-alone photovoltaic water pumping systems. *Energy Conversion and Management*, 100:358–369.
- Oreshkin, B. N., Dudek, G., Pelka, P., and Turkina, E. (2021). N-beats neural network for mid-term electricity load forecasting. *Applied Energy*, 293:116918.
- Padmavathi, K. and Daniel, S. A. (2011). Studies on installing solar water pumps in domestic urban sector. *Sustainable Cities and Society*, 1(3):135–141.
- Papapostolou, C. M., Kondili, E. M., and Tzanes, G. (2018). Optimisation of water supply systems in the water–energy nexus: Model development and implementation to support decision making in investment planning. In *Computer Aided Chemical Engineering*, volume 43, pages 1213–1218. Elsevier.
- Papapostolou, C. M., Kondili, E. M., Zafirakis, D. P., and Tzanes, G. T. (2020). Sustainable water supply systems for the islands: The integration with the energy problem. *Renewable Energy*, 146:2577–2588.
- Park, S., Jung, S., Jung, S., Rho, S., and Hwang, E. (2021). Sliding window-based lightgbm model for electric load forecasting using anomaly repair. *The Journal of Supercomputing*, pages 1–22.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., et al. (2011). Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 12:2825–2830.
- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Taieb, S. B., Bergmeir, C., Bessa, R. J., Bijak, J., Boylan, J. E., Browell, J., Carnevale, C., Castle, J. L., Cirillo, P., Clements, M. P., Cordeiro, C., Oliveira, F. L. C., Baets, S. D., Dokumentov, A., Ellison, J., Fiszeder, P., Franses, P. H., Frazier, D. T., Gilliland, M., Gönül, M. S., Goodwin, P., Grossi, L., Grushka-Cockayne, Y., Guidolin, M., Guidolin, M., Gunter, U., Guo, X., Guseo, R., Harvey, N., Hendry, D. F., Hollyman, R., Januschowski, T., Jeon, J., Jose, V. R. R., Kang, Y., Koehler, A. B., Kolassa, S., Kourentzes, N., Leva, S., Li, F., Litsiou, K., Makridakis, S., Martin, G. M., Martinez, A. B., Meeran, S., Modis, T., Nikolopoulos, K., Önköl, D., Paccagnini, A., Panagiotelis, A., Panapakidis, I., Pavía, J. M., Pedio, M., Pedregal, D. J., Pinson, P., Ramos, P., Rapach, D. E., Reade, J. J., Rostami-Tabar, B., Rubaszek, M., Sermpinis, G., Shang, H. L., Spiliotis, E., Syntetos, A. A., Talagala, P. D., Talagala, T. S., Tashman, L., Thomakos, D., Thorarindottir, T., Todini, E., Arenas, J. R. T., Wang, X., Winkler, R. L., Yusupova, A., and Ziel, F. (2021). Forecasting: theory and practice.

- Petropoulos, F., Hyndman, R. J., and Bergmeir, C. (2018). Exploring the sources of uncertainty: Why does bagging for time series forecasting work? *European Journal of Operational Research*, 268(2):545–554.
- Ramana, G. V. and Chekka, V. S. (2018). Validation and examination of existing water distribution network for continuous supply of water using EPANET. *Water resources management*, 32(6):1993–2011.
- Rokach, L. and Maimon, O. (2005). Decision trees. In *Data mining and knowledge discovery handbook*, pages 165–192. Springer.
- Rossman, L. A. (1999). The EPANET programmer’s toolkit for analysis of water distribution systems. In *WRPMD’99: Preparing for the 21st Century*, pages 1–10.
- Ruangpattana, S., Klabjan, D., Arinez, J., and Biller, S. (2011). Optimization of on-site renewable energy generation for industrial sites. In *2011 IEEE/PES Power Systems Conference and Exposition*, pages 1–8. IEEE.
- Saadi, M., Noor, M. T., Imran, A., Toor, W. T., Mumtaz, S., and Wuttisittikulkij, L. (2020). Iot enabled quality of experience measurement for next generation networks in smart cities. *Sustainable Cities and Society*, 60:102266.
- Sarmas, E., Spiliotis, E., Marinakis, V., Koutselis, T., and Doukas, H. (2022). A meta-learning classification model for supporting decisions on energy efficiency investments. *Energy and Buildings*, page 111836.
- Schwertman, N. C., Gilks, A. J., and Cameron, J. (1990). A simple noncalculus proof that the median minimizes the sum of the absolute deviations. *The American Statistician*, 44(1):38–39.
- Sobri, S., Koochi-Kamali, S., and Rahim, N. A. (2018). Solar photovoltaic generation forecasting methods: A review. *Energy Conversion and Management*, 156:459–497.
- Spiliotis, E., Petropoulos, F., Kourentzes, N., and Assimakopoulos, V. (2020). Cross-temporal aggregation: Improving the forecast accuracy of hierarchical electricity consumption. *Applied Energy*, 261:114339.
- Suganthi, L. and Samuel, A. A. (2012). Energy models for demand forecasting — A review. *Renewable and Sustainable Energy Reviews*, 16(2):1223–1240.
- Sun, Y., Haghghat, F., and Fung, B. C. (2020). A review of the-state-of-the-art in data-driven approaches for building energy prediction. *Energy and Buildings*, 221:110022.
- TILOS (2015). Tilos Horizon 2020 Program (GA No (646529). Technology Innovation for the Local Scale, Optimum Integration of Battery Energy Storage. <https://www.tiloshorizon.eu/>.
- Uddin, M., Romlie, M., Abdullah, M., Tan, C., Shafiullah, G., and Bakar, A. (2020). A novel peak shaving algorithm for islanded microgrid using battery energy storage system. *Energy*, 196:117084.
- UN (2015). Transforming our World: The 2030 Agenda for Sustainable Development. <https://sustainabledevelopment.un.org/post2015/transformingourworld/publication>.
- Van Zyl, J. E., Savic, D. A., and Walters, G. A. (2004). Operational optimization of water distribution systems using a hybrid genetic algorithm. *Journal of water resources planning and management*, 130(2):160–170.

- Wang, Y., Sun, S., Chen, X., Zeng, X., Kong, Y., Chen, J., Guo, Y., and Wang, T. (2021). Short-term load forecasting of industrial customers based on SVMD and XGBoost. *International Journal of Electrical Power & Energy Systems*, 129:106830.
- Wanjiru, E. M., Zhang, L., and Xia, X. (2016). Model predictive control strategy of energy-water management in urban households. *Applied Energy*, 179:821–831.
- Yahyaoui, I., Atieh, A., Serna, A., and Tadeo, F. (2017). Sensitivity analysis for photovoltaic water pumping systems: Energetic and economic studies. *Energy Conversion and Management*, 135:402–415.

Κεφάλαιο 10

Μοντέλο Βελτιστοποίησης Λειτουργίας Ηλεκτρικών Οχημάτων και Συστήματος Αποθήκευσης Ενέργειας για την Ενεργειακή Αυτονομία Μικροδικτύου

10.1 Εισαγωγή

Στο κεφάλαιο αυτό προτείνουμε ένα μεθοδολογικό πλαίσιο με στόχο την ελαχιστοποίηση της Αντίστροφης Ροής Ισχύος (*Reverse Power Flow - RPF*) σε επίπεδο μικροδικτύου. Το προτεινόμενο πλαίσιο μπορεί ωστόσο να έχει επίσης θετικό αντίκτυπο σε διάφορες άλλες διαστάσεις, όπως η ενέργεια που καταναλώνεται από το κύριο δίκτυο, η έκταση των αιχμών ζήτησης και η ενεργειακή αυτονομία. Η μεθοδολογία αποτελείται από μια μονάδα μοντέλων πρόβλεψης, η οποία χρησιμοποιείται για την πρόβλεψη της παραγωγής και της κατανάλωσης ηλεκτρικής ενέργειας για την επόμενη ημέρα, και μια μονάδα αλγορίθμων διαχείρισης ενέργειας, η οποία αποτελείται από δύο ευρετικούς αλγορίθμους βελτιστοποίησης. Ο πρώτος αλγόριθμος έχει ως αποστολή να μετατοπίζει τα ευέλικτα φορτία δεδομένου ενός συνόλου προβλέψεων, ενώ ο δεύτερος να ελέγχει τη διαδικασία φόρτισης/εκφόρτισης των Συστημάτων Αποθήκευσης Ενέργειας (*Energy Storage Systems - ESS*).

Μια από τις σημαντικότερες προκλήσεις στον τομέα της ενέργειας σήμερα είναι η αύξηση της ενεργειακής απόδοσης και της αυτονομίας σε παγκόσμιο επίπεδο μέσω της ευρείας χρήσης ΑΠΕ, ώστε να εξασφαλιστεί η πρόσβαση σε οικονομικά προσιτή, αξιόπιστη και βιώσιμη ενέργεια (Wang et al., 2020a). Ένας βασικός παράγοντας για την αντιμετώπιση αυτής της πρόκλησης, η οποία έχει αντιμετωπιστεί από τον Στόχο 7 των Στόχων Βιώσιμης Ανάπτυξης των Ηνωμένων Εθνών, "Προσιτή και καθαρή ενέργεια" (United Nations, 2022), είναι η αποτελεσματική και επεκτάσιμη λειτουργία των μικροδικτύων ηλεκτρικής ενέργειας. Ένα μικροδίκτυο θα μπορούσε να γίνει αντιληπτό ως ένα μικρής κλίμακας, τοπικό δίκτυο ηλεκτρικής ενέργειας που είναι ικανό να λειτουργεί είτε ανεξάρτητα είτε σε σύνδεση με το κύριο δίκτυο (Mahmoud et al., 2022). Ένα βασικό χαρακτηριστικό των μικροδικτύων είναι ότι ενσωματώνουν πολλαπλές ΑΠΕ για την παραγωγή ηλεκτρικής ενέργειας, όπως ηλιακούς συλλέκτες και ανεμογεννήτριες, ενώ συχνά περιλαμβάνουν συστήματα αποθήκευσης ενέργειας, όπως μπαταρίες, για την αποθήκευση της πλεονάζουσας ενέργειας για χρήση σε μεταγενέστερες περιόδους, όταν η παραγωγή ηλεκτρικής ενέργειας δεν μπορεί να ανταποκριθεί στις ανάγκες του μικροδικτύου (Tooryan et al., 2020).

Ο στόχος του σχεδιασμού και της λειτουργίας μικρής κλίμακας, ανεξάρτητων ¹ είναι να παρέχει μια αξιόπιστη και ανθεκτική πηγή ηλεκτρικής ενέργειας σε περιοχές όπου υπάρχει χαμηλή, ή και καθόλου, διαθεσιμότητα του κύριου δικτύου (Kiptoo et al., 2020). Ωστόσο, μια άλλη πολύ διαδεδομένη εφαρμογή είναι η ανάπτυξη μικροδικτύων συνδεδεμένων με το δίκτυο, τα οποία μπορούν να τροφοδοτούν επαρκώς μεμονωμένα κτίρια, ομάδες κτιρίων ή ακόμη και ενεργειακές κοινότητες, έχοντας επίσης τη δυνατότητα να τροφοδοτούνται από το κύριο δίκτυο όταν δεν μπορούν να αυτοεκπληρώσουν τις ενεργειακές τους ανάγκες (Arwa and Folly, 2020). Η ενεργειακή αυτονομία, που αναφέρεται στην ικανότητα μιας ενεργειακής κοινότητας να παράγει και να χρησιμοποιεί τη δική της ενέργεια, αντί να βασίζεται στο κύριο δίκτυο, είναι ένα από τα πιο πολύτιμα οφέλη που παρέχουν τα μικροδίκτυα (Haidar et al., 2020). Προκειμένου να επιτύχει ενεργειακή αυτονομία, ένα μικροδίκτυο πρέπει να είναι σε θέση να παράγει και να αποθηκεύει αρκετή ηλεκτρική ενέργεια για την κάλυψη της τοπικής ζήτησης, ακόμη και όταν είναι αποσυνδεδεμένο από το κύριο δίκτυο (Mohammed et al., 2017). Η υιοθέτηση των ΑΠΕ παρέχει μια αξιόπιστη και βιώσιμη μορφή ενέργειας, βελτιώνοντας περαιτέρω τα επίπεδα ενεργειακής αυτονομίας, ενώ η αξιοποίηση των ESS, όπως οι μπαταρίες και η θερμική αποθήκευση, συμβάλλει επίσης στην αύξηση της ευελιξίας εντός του μικροδικτύου.

Ωστόσο, η ευρεία υιοθέτηση, ο σχεδιασμός και η λειτουργία των μικροδικτύων επιφέρει ορισμένα αξιοσημείωτα ζητήματα που θα μπορούσαν να επηρεάσουν την ομαλή λειτουργία τους, εάν δεν αντιμετωπιστούν αποφασιστικά (Ullah et al., 2020). Το κύριο ζήτημα που συνήθως παρατηρείται κατά τη λειτουργία ενός μικροδικτύου σχετίζεται με το πρόβλημα της αντίστροφης ροής ισχύος (RPF). Ως RPF ορίζεται η συνεχής ροή ηλεκτρικής ενέργειας προς μια κατεύθυνση αντίθετη από την κανονική κατεύθυνση της ροής ισχύος σε ένα δίκτυο (Guerrero et al., 2020). Η ροή αυτή μπορεί να βλάψει το δίκτυο με διάφορους τρόπους, δημιουργώντας σοβαρούς κινδύνους. Σύμφωνα με το Majeed and Nwulu (2022), όταν η ηλεκτρική ενέργεια ρέει προς την αντίθετη κατεύθυνση από την κανονική της, μπορεί να προκαλέσει βλάβη στον ηλεκτρικό εξοπλισμό, όπως μετασχηματιστές και διακόπτες, και να οδηγήσει σε προβλήματα ποιότητας ισχύος, όπως διακυμάνσεις τάσης ή αρμονικές, που επηρεάζουν αρνητικά τη λειτουργία των ηλεκτρικών συσκευών που είναι συνδεδεμένες στο μικροδίκτυο. Όσον αφορά τη σταθερότητα του δικτύου, η RPF μπορεί επίσης να οδηγήσει σε διακοπές ρεύματος ή καταρρεύσεις τάσης (Patil et al., 2014). Επιπλέον, η RPF μπορεί να είναι υπεύθυνη για μεγάλες απώλειες ενέργειας, μειώνοντας τη συνολική απόδοση του δικτύου (Unahalekhaka and Sripakarach, 2020). Συνολικά, η RPF μπορεί να επιδεινώσει την ενεργειακή αυτονομία ενός μικροδικτύου και να το κάνει να εξαρτάται σημαντικά από το κύριο δίκτυο.

Το φαινόμενο του RPF παρατηρείται κυρίως όταν παράγεται περίσσεια ηλεκτρικής ενέργειας από το μικροδίκτυο, δηλαδή όταν η παραγωγή ΑΠΕ είναι μεγαλύτερη από την ηλεκτρική ενέργεια που χρησιμοποιεί η τοπική ενεργειακή κοινότητα σε δεδομένη χρονική στιγμή (Widén et al., 2010), αναγκάζοντας το πλεόνασμα της ηλεκτρικής ενέργειας να εξαχθεί στο κύριο δίκτυο. Έτσι, η κατάλληλη εξισορρόπηση της παραγωγής και της ζήτησης παίζει σημαντικό ρόλο στην επίλυση του ζητήματος αυτού. Η εξισορρόπηση μπορεί να επιτευχθεί είτε μέσω ευέλικτων πηγών παραγωγής, όπως το φυσικό αέριο και οι πηγές παροχής βιοενέργειας (Thrän et al., 2015) είτε με τον βέλτιστο προγραμματισμό των μετατοπίσιμων ² φορτίων του μικροδικτύου, όπως τα συστήματα κλιματισμού και τα ηλεκτρικά οχήματα (Electric Vehicles - EVs) (Huo et al., 2021). Επιπλέον, η εξισορρόπηση συχνά υποστηρίζεται από ESS που αποθηκεύουν την περίσσεια ενέργειας και την απελευθερώνουν πίσω στο μικροδίκτυο όταν χρειάζεται (Lawder et al., 2015). Γίνεται φανερό ότι, στο πλαίσιο αυτό, τα μοντέλα που προβλέπουν με ακρίβεια το φορτίο και την παραγωγή ΑΠΕ και οι αλγόριθμοι που βελτιστοποιούν την αποθήκευση ηλεκτρικής ενέργειας ή προγραμματίζουν σωστά τα μετατοπίσιμα φορτία μπορούν να είναι ιδιαίτερα χρήσιμα για τη μείωση του ΕΠΦ και, κατά συνέπεια, την προώθηση της ενεργειακής αυτονομίας στα μικροδίκτυα.

Η παρούσα εργασία αποσκοπεί στη διερεύνηση της επίδρασης που μπορούν να έχουν τα μοντέλα πρόβλεψης και οι αλγόριθμοι βελτιστοποίησης στην αποδοτική λειτουργία των

¹Χρησιμοποιούνται επίσης οι όροι απομονωμένο, νησιωτικό και αυτόνομο μικροδίκτυο

²Χρησιμοποιούνται επίσης οι όροι flexible και manageable.

μικροδικτύων που περιλαμβάνουν μετατοπίσιμα φορτία και ESS. Για τον σκοπό αυτό, εξετάζουμε ένα ενδεικτικό μικροδίκτυο που αποτελείται από ένα κτίριο γραφείων, έναν Φ/B σύστημα, ένα ESS και έναν αριθμό EVs που ουσιαστικά χρησιμεύουν ως μετατοπίσιμα φορτία. Πραγματοποιούμε λεπτομερείς προσομοιώσεις για τη μέτρηση του RPF και της ζήτησης από το δίκτυο (*Demand from Grid - DfG*) υπό διάφορα σενάρια που βελτιστοποιούν τον προγραμματισμό των περιόδων φόρτισης των EVs, με ή χωρίς να λαμβάνεται υπόψη η υποστήριξη της αποθήκευσης ηλεκτρικής ενέργειας, ενώ εξετάζουμε την επίδραση μεγαλύτερων μπαταριών και στόλων EV στην αυτονομία του μικροδικτύου. Η μελέτη μας για την απόσβεση ολοκληρώνεται με τη μέτρηση της επίδρασης που έχει το σφάλμα πρόβλεψης στη συνολική διαδικασία βελτιστοποίησης.

Το προτεινόμενο πλαίσιο παρέχει μια λύση με βάση τις προβλέψεις για το πρόβλημα χρονοπρογραμματισμού των μετατοπίσιμων φορτίων του μικροδικτύου, η οποία είναι ευέλικτη όσον αφορά τις εξεταζόμενες ΑΠΕ και τα μετατοπίσιμα φορτία, βασιζόμενη στα ακόλουθα βασικά στοιχεία:

- Δύο μοντέλα πρόβλεψης BM, με αποστολή να προβλέπουν σε ωριαίο επίπεδο την ηλεκτρική ενέργεια που παράγεται από τον Φ/B σύστημα και την ηλεκτρική ενέργεια που καταναλώνεται από το μικροδίκτυο την επόμενη ημέρα.
- Ένας ευρετικός αλγόριθμος ο οποίος, δεδομένων των προβλέψεων για τη Φ/B παραγωγή και την κατανάλωση ηλεκτρικής ενέργειας, προγραμματίζει τις συνεδρίες φόρτισης των EV έτσι ώστε να ελαχιστοποιείται η RPF.
- Μια μέθοδος βασισμένη σε κανόνες που αυτοματοποιεί τη φόρτιση και την εκφόρτιση των μπαταριών όταν χρειάζεται.

Η υπόλοιπη εργασία οργανώνεται ως εξής. Στην ενότητα 10.2 γίνεται ανασκόπηση της σχετικής εργασίας που έχει γίνει στον τομέα και προσδιορίζονται τα κενά. Στην ενότητα 10.3 παρουσιάζεται το προτεινόμενο πλαίσιο, συμπεριλαμβανομένων των δύο μοντέλων πρόβλεψης, του αλγορίθμου βελτιστοποίησης και της μεθόδου που βασίζεται σε κανόνες και χρησιμοποιείται για τον έλεγχο του ESS. Στην ενότητα 10.4 παρουσιάζεται μια πραγματική μελέτη περίπτωσης του προτεινόμενου πλαισίου, εξετάζοντας ένα μικροδίκτυο στην Ιταλία. Τέλος, η ενότητα 10.5 ολοκληρώνει την εργασία, συνοψίζει τα συμπεράσματά μας και προτείνει ορισμένα θέματα για μελλοντική έρευνα.

10.2 Αναλυτική Διατύπωση Προβλήματος

Το προτεινόμενο πλαίσιο βασίζεται σε μεθόδους διαχείρισης ESS και τεχνικές μετατόπισης φορτίου, οι οποίες υπόκεινται σε προβλέψεις κατανάλωσης ενέργειας και παραγωγής ΑΠΕ. Ως εκ τούτου, η ανασκόπηση που ακολουθεί επικεντρώνεται στους προαναφερθέντες ερευνητικούς τομείς.

10.2.1 Πρόβλεψη Παραγωγής ΑΠΕ

Οι ΑΠΕ αποκτούν ολοένα και μεγαλύτερη σημασία στο παγκόσμιο ενεργειακό μείγμα (Kraan et al., 2019). Έτσι, η ακριβής πρόβλεψη της παραγωγής από ΑΠΕ, όπως η παραγωγή Φ/B, είναι ζωτικής σημασίας για τη λειτουργία και τη διαχείριση των μικροδικτύων (Dutta et al., 2017). Η Φ/B παραγωγή είναι από τη φύση της στοχαστική και επηρεάζεται από διάφορους παράγοντες, συμπεριλαμβανομένων των καιρικών συνθηκών, όπως η ηλιακή ακτινοβολία, η θερμοκρασία και τα σύννεφα, καθώς και των φυσικών ιδιοτήτων του Φ/B συστήματος, όπως το μέγεθος και ο προσανατολισμός του (Ahmed et al., 2020). Ως αποτέλεσμα, το έργο της ακριβούς πρόβλεψης της ηλεκτρικής ενέργειας που παράγεται από Φ/B συστήματα για μια συγκεκριμένη χρονική περίοδο καθίσταται στην πράξη δύσκολο.

Αρκετές επιστημονικές μελέτες έχουν προσπαθήσει να παρέχουν ακριβείς προβλέψεις παραγωγής Φ/B συστημάτων (Das et al., 2018; Li et al., 2020; Ramsami and Oree, 2015). Παρόλο που έχουν προταθεί διάφορες κατηγοριοποιήσεις για τις χρησιμοποιούμενες μεθόδους, η πιο ευρέως αποδεκτή κατηγοριοποιεί τις μεθόδους πρόβλεψης Φ/B σε φυσικά μοντέλα, στατιστικά μοντέλα και υβριδικά μοντέλα. Τα φυσικά μοντέλα, όπως το μοντέλο καθαρού ουρανού, βασίζονται στις φυσικές ιδιότητες του Φ/B συστήματος και στις καιρικές συνθήκες (Gairaa et al., 2019). Αντίθετα, τα μοντέλα που βασίζονται σε δεδομένα βασίζονται σε ιστορικά δεδομένα παραγωγής Φ/B συστημάτων και καιρικών συνθηκών για την πρόβλεψη της μελλοντικής παραγωγής Φ/B συστημάτων (Gupta and Singh, 2021). Τέλος, τα υβριδικά μοντέλα συνδυάζουν φυσικά μοντέλα και μοντέλα που βασίζονται σε δεδομένα για να βελτιώσουν την ακρίβεια των επιμέρους προσεγγίσεων και να μετριάσουν την αβεβαιότητα (Raza et al., 2016).

Οι πρόσφατες εξελίξεις στην πρόβλεψη της Φ/B παραγωγής δείχνουν ότι η ανάπτυξη μοντέλων BM μπορεί να βελτιώσει περαιτέρω την ακρίβεια της πρόβλεψης (Wang et al., 2019a). Αυτό μπορεί να αποδοθεί στην αυξημένη διαθεσιμότητα δεδομένων, συμπεριλαμβανομένων τόσο των δεδομένων παραγωγής από ΑΠΕ όσο και των δεδομένων από δορυφορικές εικόνες, καθώς και στις βελτιωμένες μεθόδους πρόβλεψης καιρού και στις στρατηγικές εκπαίδευσης νευρωνικών δικτύων (NN) (Qin et al., 2022). Ενδεικτικά, στην εργασία του Abdel-Basset et al. (2021), εισήχθη μια νέα αρχιτεκτονική NN για την πρόβλεψη της ενέργειας των Φ/B την επόμενη ημέρα, η οποία βασίζεται σε μια παραλλαγή του παλινδρομικού μοντέλου μονάδων με πύλες. Με παρόμοιο τρόπο, η Luo et al. (2021) προτείνει ένα πλαίσιο BM βασισμένο σε φυσικούς περιορισμούς, το οποίο χρησιμοποιεί LSTMs και ενσωματώνει τη γνώση του τομέα των Φ/B για την πρόβλεψη της ωριαίας παραγωγής Φ/B ενέργειας.

10.2.2 Πρόβλεψη Κατανάλωσης Κτιρίων

Τα κτίρια αποτελούν σημαντικό μέρος των μικροδικτύων, καθώς καταναλώνουν μεγάλο μέρος της παραγόμενης ηλεκτρικής ενέργειας. Για την ακριβή πρόβλεψη της ηλεκτρικής ενέργειας που καταναλώνεται στα κτίρια και τη βελτιστοποίηση της λειτουργίας τους, μπορούν να αξιοποιηθούν μέθοδοι πρόβλεψης φορτίου (Yildiz et al., 2017). Αν και, τα μοντέλα που βασίζονται σε δεδομένα και χρησιμοποιούνται συνήθως για την πρόβλεψη φορτίου κτιρίων και την πρόβλεψη παραγωγής Φ/B μοιράζονται κάποιες κοινές αρχές, εμφανίζουν επίσης σημαντικές διαφορές όσον αφορά τα χαρακτηριστικά που λαμβάνονται υπόψη σε κάθε περίπτωση ως δεδομένα εισόδου. Σε αντίθεση με τα μοντέλα πρόβλεψης της Φ/B παραγωγής, τα οποία εξαρτώνται σε μεγάλο βαθμό από τις προβλέψεις του καιρού, τα μοντέλα πρόβλεψης φορτίου κτιρίων βασίζονται περισσότερο σε παρελθοντικά δεδομένα της κατανάλωσης ενέργειας του κτιρίου, τα οποία αντιπροσωπεύουν αποτελεσματικά τα υποκείμενα πρότυπα χρήσης και συμπεριφοράς του (Ma et al., 2017).

Συγκεκριμένα, υπάρχουν διάφοροι παράγοντες που επηρεάζουν τη ζήτηση ηλεκτρικής ενέργειας σε ένα κτίριο. Πρώτον, ο τύπος του κτιρίου μπορεί να έχει σημαντικό αντίκτυπο, καθώς είναι προφανές ότι, για παράδειγμα, ένα κτίριο γραφείων που δεν έχει κατοίκους τα Σαββατοκύριακα θα έχει διαφορετικό προφίλ κατανάλωσης ηλεκτρικής ενέργειας από ένα κτίριο κατοικιών. Επιπλέον, το μέγεθος και τα επίπεδα πληρότητας του κτιρίου μπορεί να διαδραματίσουν σημαντικό ρόλο στην κατανάλωση ηλεκτρικής ενέργειας. Για παράδειγμα, ένα κτίριο με μεγάλο αριθμό ενοίκων ή αυξημένο ηλεκτρικό εξοπλισμό αναμένεται να έχει μεγαλύτερες ενεργειακές ανάγκες. Οι προσπάθειες για την πρόβλεψη του φορτίου των κτιρίων είναι έντονες και βασίζονται κυρίως σε στατιστικά μοντέλα και μοντέλα BM. Wang et al. (2020b) συνέχισε διάφορα μοντέλα βασισμένα σε δεδομένα, συμπεριλαμβανομένων των μεθόδων MM, BM και ευρετικών μεθόδων, για την πρόβλεψη του θερμικού φορτίου, καταλήγοντας στο συμπέρασμα ότι το μοντέλο LSTM αποδίδει καλύτερα όταν πρόκειται για βραχυπρόθεσμη, ωριαία πρόβλεψη, ενώ τα μοντέλα που βασίζονται σε δέντρα, όπως το XGBoost, είναι πιο κατάλληλα για προβλέψεις ημέρας. Ομοίως, Fan et al. (2017) διερεύνησε τις δυνατότητες του BM στην πρόβλεψη των προφίλ του ψυκτικού φορτίου κτιρίων για την επόμενη ημέρα, με τα αποτελέσ-

ματα να δείχνουν ότι τα μοντέλα BM επιτυγχάνουν καλύτερες προβλέψεις ψυκτικού φορτίου σε σύγκριση με τα συμβατικά στατιστικά μοντέλα.

10.2.3 Διαχείριση Ευέλικτων Φορτίων

Σύμφωνα με το [Graditi et al. \(2014\)](#), τα μετατοπίσιμα φορτία μπορούν να οριστούν ως ηλεκτρικά φορτία που μπορούν εύκολα να ρυθμιστούν ή να απενεργοποιηθούν σε απόκριση σε αλλαγές στην προσφορά ή τη ζήτηση ηλεκτρικής ενέργειας χωρίς να καταστραφεί ο εξοπλισμός ή να υποβαθμιστεί η ποιότητα λειτουργίας. Ορισμένα παραδείγματα μετατοπίσιμων φορτίων περιλαμβάνουν αντλίες νερού, ηλεκτρικά ρεύματα, ηλεκτρικούς θερμοσίφωνες και συστήματα κλιματισμού. Όπως έχει ήδη αναφερθεί στην ενότητα [10.1](#), η διαχείριση των μετατοπίσιμων φορτίων είναι πολύ σημαντική για τη λειτουργία ενός μικροδικτύου, καθώς μπορούν να συμβάλουν στη βελτίωση της αξιοπιστίας και της αποδοτικότητας του συστήματος, επιτρέποντας την προσαρμογή του φορτίου ανάλογα με τη διαθέσιμη παραγόμενη ηλεκτρική ενέργεια ([Golpîra and Bahramara, 2020](#)). Σε γενικές γραμμές, υπάρχουν τρεις διαφορετικοί τρόποι διαχείρισης των μετατοπίσιμων φορτίων ενός μικροδικτύου προκειμένου να εξισορροπηθεί η προσφορά και η ζήτηση ηλεκτρικής ενέργειας:

- **Load shedding:** Πρόκειται για τη διαδικασία σκόπιμης απενεργοποίησης ή μείωσης ορισμένων ηλεκτρικών φορτίων. Η απόρριψη φορτίου απαιτείται όταν η ζήτηση ενέργειας πλησιάζει τη διαθέσιμη προσφορά, δημιουργώντας τον πιθανό κίνδυνο επικίνδυνης ανισορροπίας ([Bakar et al., 2017](#)). Έτσι, ορισμένα ηλεκτρικά φορτία περιορίζονται προκειμένου να σταθεροποιηθεί το δίκτυο και να αποφευχθούν μεγαλύτερες και μεγαλύτερες σε διάρκεια διακοπές.
- **Load Shifting:** Η πρακτική αυτή αναφέρεται στη μετατόπιση της χρήσης ηλεκτρικών φορτίων σε περιόδους όπου η παροχή ηλεκτρικής ενέργειας είναι πιο άφθονη ([Mohandes et al., 2020](#)). Για παράδειγμα, ένα EV θα μπορούσε να φορτίζει κατά τις ώρες που τα Φ/Β συστήματα παράγουν περίσσεια ηλεκτρικής ενέργειας, αντί για τις περιόδους αιχμής της ζήτησης, ή τις νυχτερινές ώρες που δεν υπάρχει ηλεκτρική ενέργεια από ΑΠΕ ([Van Der Kam and van Sark, 2015](#)).
- **Demand Response Programs:** Τα προγράμματα αυτά περιλαμβάνουν την προσφορά κινήτρων ή οικονομικών ανταμοιβών στους πελάτες για τη μείωση της χρήσης ηλεκτρικής ενέργειας σε περιόδους υψηλής ζήτησης ή έκτακτης ανάγκης ([Pinson et al., 2014](#)). Αυτό μπορεί να συμβάλει στη μείωση της συνολικής ζήτησης στο μικροδίκτυο και στην αποτροπή της RPF.

Τα ηλεκτρικά αυτοκίνητα αποτελούν μια από τις πιο δημοφιλείς κατηγορίες μετακινούμενων φορτίων σε ένα μικροδίκτυο, επειδή μπορούν εύκολα να φορτιστούν (ή να εκφορτιστούν) ανάλογα με την παροχή ηλεκτρικής ενέργειας από ΑΠΕ. Υπάρχουν διάφορες πιθανές επιλογές για την αξιοποίηση των EVs ως πλεονέκτημα ευελιξίας στο πλαίσιο ενός μικροδικτύου. Η πιο προφανής είναι να προτείνονται συνεδρίες φόρτισης κατά τη διάρκεια διαστημάτων εντός της ημέρας, όταν η παροχή ηλεκτρικής ενέργειας είναι πιο άφθονη, όπως όταν οι ηλιακοί συλλέκτες παράγουν περίσσεια ηλεκτρικής ενέργειας, και όχι κατά τη διάρκεια των περιόδων αιχμής της ζήτησης ([Venegas et al., 2021](#)). Ένα ενδεικτικό παράδειγμα παρέχεται στη μελέτη του [Mohsenian-Rad et al. \(2014\)](#), ο οποίος πρότείνει μια μεθοδολογία για το πρόβλημα στοχαστικής βελτιστοποίησης του προγραμματισμού της φόρτισης των EVs με αβέβαιους χρόνους αναχώρησης λαμβάνοντας υπόψη τα τιμολόγια ωριαίας τιμολόγησης. Στο πλαίσιο των μικροδικτύων, ο [Van Der Kam and van Sark \(2015\)](#) πρότείνει τρεις αλγόριθμους ελέγχου που διαχειρίζονται το προφίλ φόρτισης πολλαπλών EVs, είτε σε πραγματικό χρόνο είτε χρησιμοποιώντας γραμμική βελτιστοποίηση. Το προσομοιωμένο μικροδίκτυο στη μελέτη τους αποτελούνταν από μια Φ/Β εγκατάσταση, ένα γραφείο, διακομιστές διαδικτύου, τρία νοικοκυριά και δύο EVs. Μια άλλη δυνατότητα είναι να επωφεληθούν από την τεχνολογία

Vehicle-to-grid (V2G), η οποία επιτρέπει τη φόρτιση και την εκφόρτιση των EVs, λειτουργώντας ως ESS που επιστρέφει την πλεονάζουσα ηλεκτρική ενέργεια που είναι αποθηκευμένη στο EV πίσω στο δίκτυο όταν χρειάζεται (Wei et al., 2022; Lund and Kempton, 2008). Τέλος, λαμβάνοντας υπόψη συμπεριφορικές πτυχές, τα EVs είναι το τέλειο υποψήφιο περιουσιακό στοιχείο για την επιβολή προγραμμάτων απόκρισης στη ζήτηση, ώστε να δοθούν κίνητρα στους ιδιοκτήτες EVs να φορτίζουν τα οχήματά τους σε περιόδους χαμηλής ζήτησης ή να εκφορτίζουν τα οχήματά τους πίσω στο δίκτυο σε περιόδους υψηλής ζήτησης ή έκτακτης ανάγκης (Kumar and Tseng, 2016; Aliasghari et al., 2018).

10.2.4 Διαστασιολόγηση Μέσων Αποθήκευσης Ενέργειας

Ο ρόλος των ESS στην επίτευξη υψηλών επιπέδων ενεργειακής αυτονομίας είναι ουσιαστικός, καθώς επιτρέπουν την αποθήκευση της πλεονάζουσας ενέργειας όταν παράγεται και στη συνέχεια την επιστροφή της στο μικροδίκτυο όταν απαιτείται, βοηθώντας στη διατήρηση της ενεργειακής αυτονομίας σε ώρες χαμηλής παραγωγής από ΑΠΕ. Τα ESS έχουν εισάγει πολλαπλά πλεονεκτήματα για τα μικροδίκτυα, συμπεριλαμβανομένης της εξισορρόπησης της παραγωγής και της ζήτησης, της βελτίωσης της ποιότητας ισχύος και της ενεργοποίησης επικουρικών υπηρεσιών όπως η ρύθμιση της συχνότητας και της τάσης, μεταξύ άλλων (Hajiaghahi et al., 2019). Όλα τα προαναφερθέντα οφέλη έχουν μια κοινή συνιστώσα- την αύξηση της ενεργειακής αυτονομίας. Πιο συγκεκριμένα, με τη χρήση συστημάτων αποθήκευσης ενισχύεται η αξιοπιστία του μικροδικτύου (ακόμη και τη νύχτα ή τις συννεφιασμένες ημέρες), αυξάνεται η ανθεκτικότητα σε διακοπές ρεύματος και μειώνεται το ενεργειακό κόστος, καθώς η αποθηκευμένη ενέργεια μπορεί να χρησιμοποιηθεί σε ώρες με υψηλές τιμές (Hassan et al., 2017).

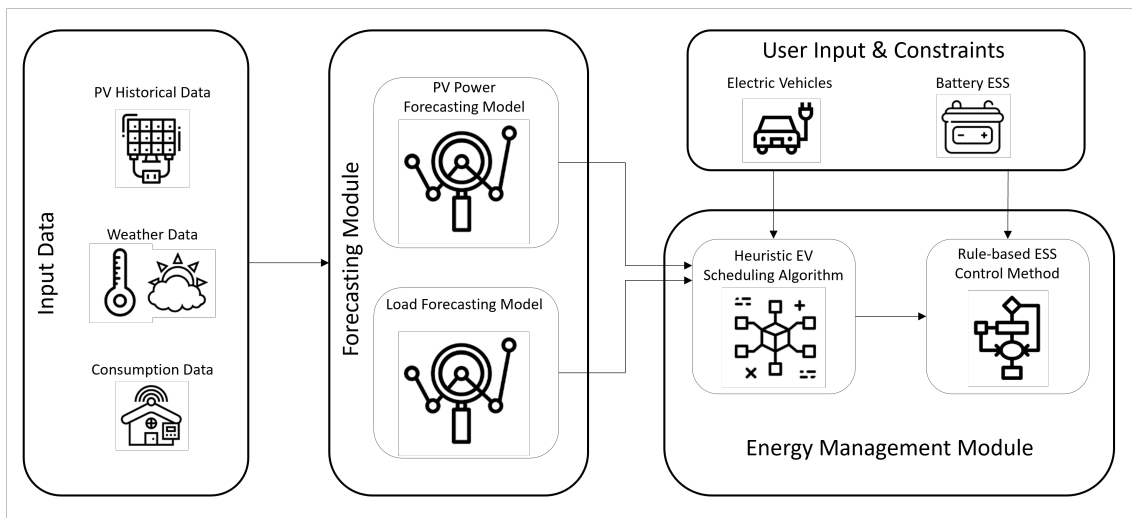
Οι μπαταρίες ESS (BESS) είναι ένα από τα πιο ευρέως χρησιμοποιούμενα ESS. Τα συστήματα αυτά αποθηκεύουν την ηλεκτρική ενέργεια σε χημική μορφή αποτελώντας μια φορητή αλλά αξιόπιστη πηγή ηλεκτρικής ενέργειας. Μια από τις πιο δημοφιλείς χρήσεις των BESS μπορεί να βρεθεί στα μικροδίκτυα, όπου αποθηκεύουν την περίσσεια ενέργειας που βασίζεται σε ΑΠΕ για να την αντλήσουν στο δίκτυο σε μεταγενέστερες χρονικές στιγμές (Yang et al., 2018). Συνολικά, το μέγεθος ενός BESS καθορίζεται από τις ενεργειακές απαιτήσεις του μικροδικτύου στο οποίο λειτουργεί, καθώς και από διάφορους πρόσθετους παράγοντες, όπως τα προφίλ φορτίου σε ημερήσια ή ωριαία βάση και το περιβάλλον λειτουργίας (π.χ. θερμοκρασία αέρα, υγρασία, υψόμετρο), τα οποία μπορούν να επηρεάσουν την απόδοση και τη διάρκεια ζωής του (Hannan et al., 2021). Τις τελευταίες δεκαετίες έχουν προκύψει αρκετές μελέτες, οι οποίες προσπαθούν να διαμορφώσουν το βέλτιστο μέγεθος ενός BESS στο πλαίσιο ενός μικροδικτύου, λαμβάνοντας επίσης υπόψη τεχνικοοικονομικούς παράγοντες (Kaldellis et al., 2009). Riffonneau et al. (2011) παρουσίασθηκε ένας μηχανισμός βέλτιστης διαχείρισης ισχύος για συνδεδεμένα στο δίκτυο Φ/B ο στόχος είναι η βελτίωση του ποσοστού διείσδυσης της Φ/B παραγωγής στο δίκτυο με ταυτόχρονη εκμετάλλευση του BESS. Ομοίως, Aghamohammadi and Abdolahinia (2014) χρησιμοποίησε ένα BESS για τον πρωτογενή έλεγχο συχνότητας ενός μικροδικτύου, καταλήγοντας στο συμπέρασμα ότι το βέλτιστο μέγεθος εξαρτάται κυρίως από την επιτρεπόμενη διάρκεια υπερφόρτωσης.

Οι BESS έχουν επίσης χρησιμοποιηθεί εκτενώς για την αντιμετώπιση του προβλήματος του RPF. Ενδεικτικά, η Unahalekhaka and Sripakarach (2020) έδειξε ότι οι BESS μπορούν να μειώσουν την RPF και να αυξήσουν την εξομάλυνση της καμπύλης φορτίου διανομής. Ωστόσο, μια άλλη μελέτη που αναπτύχθηκε από την Zhou et al. (2022) παρουσίασε πειραματικά στοιχεία, τονίζοντας ότι η πλειοψηφία των επιθεωρημένων BESS είχε φορτιστεί σε πλήρη χωρητικότητα πολύ νωρίς για να μειώσει τις αιχμές του μικροδικτύου, επειδή σε ορισμένες ημέρες (με υψηλή Φ/B παραγωγή και χαμηλά ημερήσια φορτία) οι BESS δεν εκφορτίζονταν πλήρως κατά τη διάρκεια της νύχτας. Συνεπώς, είναι πολύ σημαντικό να διερευνηθεί διεξοδικά το πρόβλημα της βέλτιστης διαστασιολόγησης των BESS στα μικροδίκτυα, καθώς μπορεί να προσφέρει πρακτικές λύσεις για πιο σταθερά, ευέλικτα, οικονομικά αποδοτικά και

βίωσιμα μικροδίκτυα.

10.3 Προτεινόμενο Μοντέλο

Το προτεινόμενο μεθοδολογικό πλαίσιο αποτελείται από δύο μονάδες πρόβλεψης που είναι υπεύθυνες για την παροχή προβλέψεων για την παραγωγή ενέργειας από Φ/Β και την κατανάλωση κτιρίων (παρουσιάζεται στην ενότητα 10.3.1), έναν ευρετικό αλγόριθμο χρονοπρογραμματισμού για τη βελτιστοποίηση των περιόδων φόρτισης ενός στόλου ηλεκτροκίνητων οχημάτων (παρουσιάζεται στην υποενότητα 10.3.2) και μια μέθοδο βασισμένη σε κανόνες για τη διαχείριση ενός συσσωρευτή ESS (συζητείται στην υποενότητα 13). Το πλαίσιο, στο σύνολό του, φιλοδοξεί να αντιμετωπίσει το πρόβλημα της διαχείρισης των καταναμημένων ενεργειακών πόρων ενός μικροδικτύου με ιδιαίτερη έμφαση στον μετριασμό των ζητημάτων που σχετίζονται με το RPF και, ταυτόχρονα, στην αύξηση της ενεργειακής αυτονομίας του μικροδικτύου. Στο πλαίσιο αυτό, μια γενική επισκόπηση του προτεινόμενου πλαισίου παρουσιάζεται στο Σχήμα 10.1




Σχήμα 10.1: Επισκόπηση των δομικών στοιχείων του προτεινόμενου πλαισίου, που απεικονίζει την απαιτούμενη είσοδο (πηγές δεδομένων και περιορισμοί χρήστη), καθώς και τις μονάδες πρόβλεψης (μοντέλα πρόβλεψης Φ/Β και φορτίου) και διαχείρισης ενέργειας (προγραμματισμός συνεδριών φόρτισης EV και έλεγχος φόρτισης/εκφόρτισης ESS) που αναπτύχθηκαν στην παρούσα μελέτη.

10.3.1 Μοντέλα Πρόβλεψης

Το μοντέλο CNN-LSTM χρησιμοποιείται για την πρόβλεψη τόσο της παραγωγής Φ/Β όσο και της κατανάλωσης ηλεκτρικής ενέργειας. Η επιλογή του μοντέλου βασίζεται σε πρόσφατες σχετικές έρευνες που αναδεικνύουν την ανώτερη απόδοσή του έναντι άλλων μοντέλων MM και BM σε παρόμοιες εργασίες πρόβλεψης (Wang et al., 2019b; Agga et al., 2022; Qu et al., 2021; Shao et al., 2020). Στο Σχήμα 10.2 παρουσιάζεται η αρχιτεκτονική του προτεινόμενου μοντέλου CNN-LSTM. Η συνολική του λογική αποτελείται από δύο στάδια. Στο πρώτο στάδιο, τα στρώματα CNN εξάγουν τα χωρικά χαρακτηριστικά των χαρακτηριστικών (μεταβλητές εισόδου) χρησιμοποιώντας στρώματα συνέλιξης και συγκέντρωσης. Το αποτέλεσμα αυτής της ρουτίνας επεξεργασίας περνάει στο στρώμα LSTM με την αφαίρεση μέρους του θορύβου. Στο δεύτερο στάδιο, το στρώμα LSTM αναγνωρίζει τις ακανόνιστες χρονικές πληροφορίες χρησιμοποιώντας τα μεταδιδόμενα χωρικά χαρακτηριστικά. Κατά συνέπεια, το μοντέλο CNN-LSTM μπορεί να προβλέψει με ακρίβεια τη μεταβλητή-στόχο (παραγωγή Φ/Β ή κατανάλωση ηλεκτρικής ενέργειας) χρησιμοποιώντας μια πλήρως συνδεδεμένη αρχιτεκτονική. Οι προβλέψεις

που παρήχθησαν από τα δύο μοντέλα πρόβλεψης αξιολογήθηκαν με τη χρήση τριών μετρικών που χρησιμοποιούνται εκτενώς στην πρόβλεψη ενέργειας.

Σχήμα 10.2: Η συνολική αρχιτεκτονική του χρησιμοποιούμενου μοντέλου πρόβλεψης CNN-LSTM.



Όσον αφορά τα χαρακτηριστικά που χρησιμοποιήθηκαν από τα μοντέλα CNN-LSTM, αυτά επιλέχθηκαν με βάση τα πρόσφατα ευρήματα του [Sarmas et al. \(2022\)](#), ο οποίος αξιολόγησε διάφορα μοντέλα MM και BM για την πρόβλεψη της παραγωγής Φ/Β και της κατανάλωσης ηλεκτρικής ενέργειας σε παρόμοιες συνθήκες, τις καλές πρακτικές που εντοπίστηκαν στη βιβλιογραφία στις υποενότητες 10.2.1 και 10.2.2, καθώς και ορισμένες πρόσθετες δοκιμές που διεξήχθησαν από τους συγγραφείς της παρούσας μελέτης. Ο Πίνακας 10.1 συνοψίζει το σύνολο των μεταβλητών που χρησιμοποιήθηκαν ως δεδομένα εισόδου στα χρησιμοποιούμενα μοντέλα παραγωγής Φ/Β και κατανάλωσης ηλεκτρικής ενέργειας. Όπως φαίνεται, τα χαρακτηριστικά περιλαμβάνουν παρελθοντικές παρατηρήσεις (υστερήσεις) που αποτυπώνουν εποχιακά πρότυπα και τάσεις, NWP's και ημερολογιακές πληροφορίες (ώρα, ημέρα και μήνας της περιόδου που προβλέπεται).

Πίνακας 10.1: Χαρακτηριστικά που χρησιμοποιούνται ως μεταβλητές εισόδου στα μοντέλα παραγωγής Φ/Β και κατανάλωσης ηλεκτρικής ενέργειας.

Model	#	Feature	Description
PV Production	1	Air temperature	Float NWP value of air temperature
	2	Relative humidity	Float NWP value of relative humidity
	3	Global radiation	Float NWP value of global radiation
	4	Hour of the day	Integer value between 0 and 23
	5	Month of the year	Integer value between 0 and 11
Electricity Consumption	1	24-hour lag	Consumption; same hour one days ago
	2	48-hour lag	Consumption; same hour two days ago
	3	168-hour lag	Consumption; same hour one week ago
	4	Hour of the day	Integer value between 0 and 23
	5	Day of the week	Integer value between 0 and 6
	6	Month of the year	Integer value between 0 and 11

Και τα δύο NN εκπαιδεύτηκαν χρησιμοποιώντας τη βιβλιοθήκη Keras (έκδοση 2.2.4), το Tensorflow-GPU backend (έκδοση 1.15.0), το Cuda Toolkit (έκδοση 10.0.130) και το CuDNN (έκδοση 7.6.5) σε ένα μηχάνημα DELL Latitude 3510, το οποίο διαθέτει επεξεργαστή Intel Core i7-10510U και 16 GB RAM.

10.3.2 Μοντέλα Βελτιστοποίησης

Προγραμματισμός Συνεδριών Φόρτισης EV

Σε αυτό το υποκεφάλαιο παρουσιάζεται ο ευρετικός αλγόριθμος που αναπτύχθηκε για τον προγραμματισμό των περιόδων φόρτισης EV. Γενικά, οι ευρετικοί και οι μεταευρετικοί αλγόριθμοι ανήκουν στην ευρύτερη κατηγορία αλγορίθμων βελτιστοποίησης που χρησιμοποιούνται για την εύρεση προσεγγιστικών λύσεων σε σύνθετα προβλήματα βελτιστοποίησης ([Beheshti and Shamsuddin, 2013](#)). Και οι δύο τύποι αλγορίθμων χρησιμοποιούνται για τον υπολογισμό της βέλτιστης λύσης ή ακόμη και λύσεων που βρίσκονται κοντά στη βέλτιστη λύση, αλλά διαφέρουν ως προς τον τρόπο με τον οποίο προσεγγίζουν το πρόβλημα. Οι ευρετικοί αλγόριθμοι είναι αλγόριθμοι βασισμένοι σε κανόνες που αντιμετωπίζουν σχετικά απλά και καλά καθορισμένα προβλήματα, βασιζόμενοι σε ένα σύνολο προκαθορισμένων κανόνων για να καθοδηγήσουν την αναζήτηση μιας λύσης, η οποία όμως δεν είναι πάντα εγγυημένα η βέλτιστη ([Kokash, 2005](#)).

Ο προτεινόμενος αλγόριθμος προγραμματίζει τις συνεδρίες φόρτισης EV σε καθημερινή βάση με τρόπο που βελτιστοποιεί τη λειτουργία του μικροδικτύου όσον αφορά την εκμετάλλευση της παραγωγής με βάση τις ΑΠΕ. Συγκεκριμένα, κάθε μέρα, ο αλγόριθμος αναθέτει τις συνεδρίες φόρτισης EV σε ωριαία διαστήματα με χαμηλό καθαρό φορτίο, που αντιστοιχούν σε ώρες εντός της ημέρας όπου η ζήτηση ενέργειας λαμβάνει τις χαμηλότερες τιμές της. Έτσι, ο αλγόριθμος μειώνει το καθαρό φορτίο κατά τις ώρες αιχμής, με βάση μια λογική πλήρωσης κοιλάδας, δηλαδή εκμεταλλεύεται τις περιόδους χαμηλής ενεργειακής ζήτησης για να αποφύγει την υπερφόρτωση του ενεργειακού δικτύου κατά τις περιόδους υψηλής ζήτησης. Σε αυτό το πλαίσιο, η αντικειμενική συνάρτηση του ευρετικού αλγορίθμου είναι η ελαχιστοποίηση της εξάρτησης από το κύριο δίκτυο ηλεκτρικής ενέργειας και, ως εκ τούτου, η ενίσχυση της συνολικής ενεργειακής αυτονομίας του μικροδικτύου. Ο αλγόριθμος χρησιμοποιεί μια πρακτική προσέγγιση για την επίλυση του προβλήματος, αντί να χρησιμοποιεί εξαντλητική αναζήτηση ή μαθηματική προσέγγιση. Ως αποτέλεσμα, η βέλτιστη³ λύση προσδιορίζεται αποτελεσματικά με ελάχιστο υπολογιστικό κόστος. Ο ψευδοκώδικας του αλγορίθμου βελτιστοποίησης που αναπτύχθηκε για τον προγραμματισμό των περιόδων φόρτισης των EV παρουσιάζεται στον Αλγόριθμο 2.

Όπως φαίνεται στον Αλγόριθμο 2, ο αλγόριθμος πρώτα επαναλαμβάνει όλα τα διαθέσιμα EV. Εντοπίζει το EV με τη μεγαλύτερη ωριαία κατανάλωση και το αναθέτει στη μεταβλητή *utilisedEV*. Στη συνέχεια υπολογίζει τον συνολικό χρόνο φόρτισης για το επιλεγμένο EV σε ώρες, διαιρώντας τη συνολική ενεργειακή ζήτηση που απαιτείται για την πλήρη φόρτιση με την ωριαία ενέργεια που απορροφάται από το EV. Στη συνέχεια, ο αλγόριθμος βρίσκει το διάστημα με το ελάχιστο καθαρό φορτίο εντός του χρόνου φόρτισης αθροίζοντας το καθαρό φορτίο κάθε ωριαίου διαστήματος. Για παράδειγμα, εάν το EV απαιτεί τρεις ώρες για να φορτιστεί πλήρως, τότε διερευνώνται όλα τα τρίωρα διαστήματα (δηλαδή 00:00 έως 03:00, 01:00 έως 04:00, ..., 21:00 έως 00:00). Στη συνέχεια, η φόρτιση του EV προγραμματίζεται για το επιλεγμένο διάστημα ενημερώνοντας τον πίνακα *EV Schedule*. Τέλος, ο αλγόριθμος ενημερώνει το καθαρό φορτίο όλων των ωριαίων διαστημάτων προσθέτοντας την ωριαία κατανάλωση του EV στα επιλεγμένα διαστήματα, καθώς και τον κατάλογο των εξεταζόμενων EV αφαιρώντας το επιλεγμένο EV από τον αντίστοιχο κατάλογο. Η όλη διαδικασία επαναλαμβάνεται μέχρι να αντιστοιχιστούν όλα τα EVs στο βέλτιστο διάστημα, όπως φαίνεται στο διάγραμμα ροής του αλγορίθμου βελτιστοποίησης, το οποίο απεικονίζεται στο Σχήμα 10.3. Η έξοδος είναι ένας διδιάστατος πίνακας που αναφέρεται ως *EV Schedule[i,j]*, όπου η τιμή 1 υποδηλώνει ότι το EV *i* έχει προγραμματιστεί να φορτίσει στο διάστημα *j*, ενώ η τιμή 0 υποδηλώνει το αντίθετο.

Ο αλγόριθμος βελτιστοποίησης απαιτεί τέσσερις εισόδους, ως εξής:

- *N*: Ο αριθμός των EVs που πρέπει να φορτιστούν σε μια δεδομένη ημέρα.

³Ο αλγόριθμος παρέχει μια συνολική βέλτιστη λύση όσον αφορά την επιτυγχάνομενη εξοικονόμηση αιχμής, καθώς αναθέτει πρώτα τα EVs με τις μέγιστες ωριαίες ενεργειακές ανάγκες.

Algorithm 2: Heuristic algorithm for optimally scheduling the charging sessions of EVs

Inputs : N : number of EVs to be charged

$TotalCons$: $\{x_1, x_2, \dots, x_N\}$, electricity required per EV to be fully charged

$HourlyCons$: $\{x_1, x_2, \dots, x_N\}$, hourly electricity required per EV while being charged

$NetLoad$: $\{z_1, z_2, \dots, z_{24}\}$, hourly predicted net load (total consumption minus RES production);

Output: $EVSchedule[i, j]$: the day-ahead plan of the charging sessions (boolean variable);

1 if EV i is scheduled to charge at interval j ; 0 otherwise

```

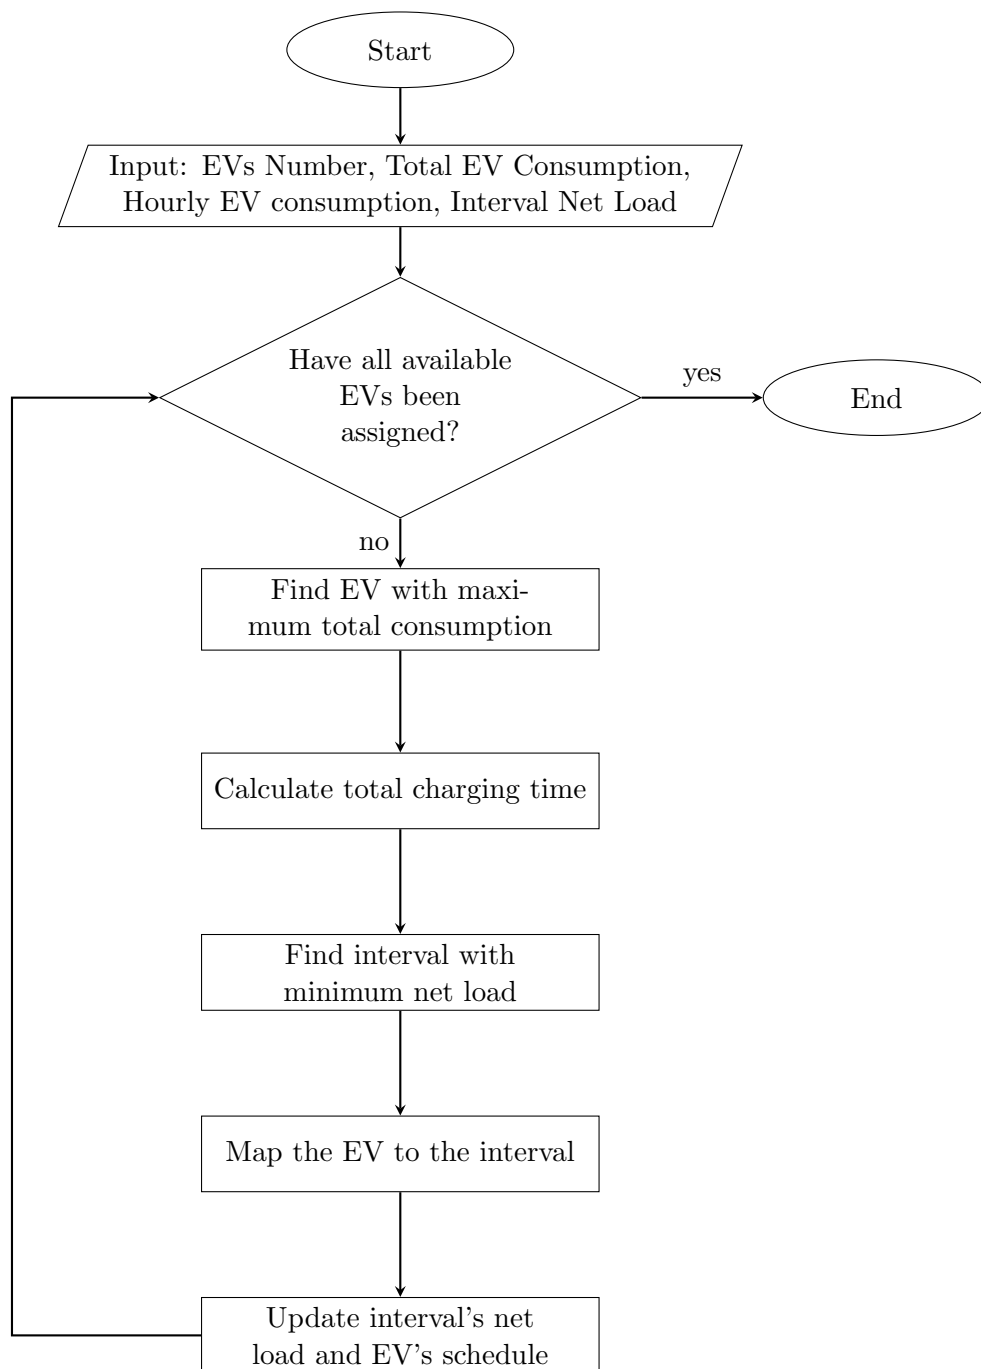
1 for all available EVs do
2     /* Find EV with the greatest hourly consumption */
3     utilizedEV ← max(HourlyCons);
4     /* Calculate total charging time (in hours) */
5     chargingHours ← TotalCons[utilizedEV] ÷ HourlyCons[utilizedEV];
6     /* Find interval with minimum net load */
7     for i ∈ chargingHours hourly intervals within the day do
8         intervalNetLoad[i] ← sum(NetLoad[i : i + chargingHours]);
9         selectedInterval ← min(intervalNetLoad);
10    end
11    /* Update schedule by scheduling the EV in the selected interval */
12    EVSchedule[utilizedEV, selectedInterval] ← 1;
13    /* Update the hourly intervals and the available EVs */
14    for i ∈ selectedInterval do
15        NetLoad[i] ← NetLoad[i] + HourlyCons[utilizedEV];
16    end
17    Erase utilizedEV from available EVs;
18 end

```

- $TotalCons \{x_1, x_2, \dots, x_N\}$: Ένας κατάλογος που περιλαμβάνει την ηλεκτρική ενέργεια που απαιτείται ανά EV προκειμένου να φορτιστεί πλήρως.
- $HourlyCons \{x_1, x_2, \dots, x_N\}$: Ένας κατάλογος που περιλαμβάνει την ωριαία ηλεκτρική ενέργεια που απαιτείται ανά EV κατά τη λειτουργία φόρτισης.
- $NetLoad \{z_1, z_2, \dots, z_{24}\}$: Ένας κατάλογος που περιλαμβάνει το ωριαίο προβλεπόμενο καθαρό ηλεκτρικό φορτίο του μικροδικτύου, δηλαδή την προβλεπόμενη συνολική κατανάλωση μείον την προβλεπόμενη παραγωγή ΑΠΕ.

Σημειώστε ότι οι πληροφορίες εισόδου του αλγορίθμου μπορούν εύκολα να ανακτηθούν από τις προδιαγραφές κάθε EV. Πιο συγκεκριμένα, η ζήτηση ενέργειας ανά EV για την πλήρη φόρτιση του μπορεί να ληφθεί από τη χωρητικότητα της μπαταρίας και την κατάσταση φόρτισης του EV. Η χωρητικότητα της μπαταρίας είναι η μέγιστη χωρητικότητα αποθήκευσης ενέργειας της μπαταρίας του EV και παρέχεται συνήθως σε κιλοβατώρες (kWh), ενώ η κατάσταση φόρτισης είναι το ποσοστό της χωρητικότητας της μπαταρίας που έχει χρησιμοποιηθεί και παρέχεται συνήθως σε δεκαδική μορφή. Έτσι, η ζήτηση ενέργειας ανά EV για πλήρη φόρτιση είναι το γινόμενο της χωρητικότητας της μπαταρίας και της κατάστασης φόρτισης. Από την άλλη πλευρά, η απαιτούμενη ωριαία ηλεκτρική ενέργεια κάθε EV ενώ βρίσκεται σε κατάσταση

Σχήμα 10.3: Διάγραμμα ροής του ευρετικού αλγορίθμου βελτιστοποίησης που αναπτύχθηκε για τη βελτιστοποίηση του προγραμματισμού των ωρών φόρτισης των ηλεκτροκίνητων οχημάτων.




φόρτισης (επίσης γνωστή ως ρυθμός φόρτισης) μετριέται συνήθως σε κιλοβάτ (kW) και αντιπροσωπεύει την ποσότητα ηλεκτρικής ενέργειας που μπορεί να δεχθεί το EV κατά τη διάρκεια της φόρτισης. Ο ρυθμός φόρτισης μπορεί να επηρεαστεί από διάφορους παράγοντες, όπως η τεχνολογία φόρτισης, η κατάσταση της μπαταρίας και η θερμοκρασία της μπαταρίας. Ωστόσο, ο ρυθμός φόρτισης για ένα συγκεκριμένο EV μπορεί να βρεθεί στην τεκμηρίωση του οχήματος ή στον ιστότοπο του κατασκευαστή (Skaloumpakas et al., 2022).

Διαχείριση Φόρτισης/Εκφόρτισης ESS

Αυτό το υποκεφάλαιο επικεντρώνεται στην παρουσίαση της μεθόδου που βασίζεται σε κανόνες και χρησιμοποιείται για τον έλεγχο του ESS στο πλαίσιο του μικροδικτύου. Για το

σκοπό αυτό, είναι απαραίτητο να οριστεί ένα ενιαίο σύστημα σε επίπεδο μικροδικτύου (Ratnam et al., 2015; Ratnam and Weller, 2018), το οποίο περιλαμβάνει τις πηγές παραγωγής, τα ελεγχόμενα και μη ελεγχόμενα φορτία, καθώς και το ESS, όπως απεικονίζεται στο Σχήμα 10.4.



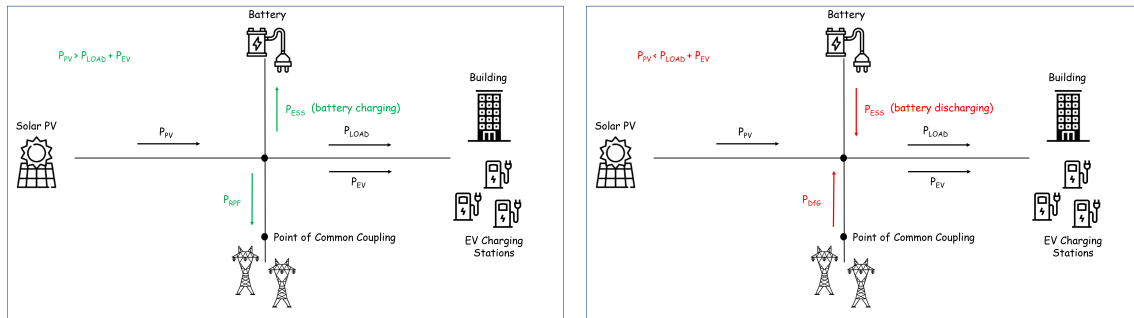
Σχήμα 10.4: Μια επισκόπηση της τοπολογίας του συστήματος μικροδικτύου που εξετάστηκε στην παρούσα μελέτη, απεικονίζοντας την κατεύθυνση των θετικών ρών ισχύος.

Στην περίπτωση μας, η Φ/Β εγκατάσταση είναι η κύρια πηγή παραγωγής ηλεκτρικής ενέργειας στο μικροδίκτυο. Τα μη ελεγχόμενα φορτία αποτελούνται από το κτίριο γραφείων, με τη ζήτηση ενέργειας να κορυφώνεται κατά τη διάρκεια της ημέρας, ενώ τα ελεγχόμενα φορτία αποτελούνται από τη ζήτηση των συνεδριών φόρτισης των EV, οι οποίες προγραμματίζονται από τον ευρετικό αλγόριθμο που προτείνεται στο υποκεφάλαιο 10.3.2, με στόχο την επίτευξη εξοικονόμησης αιχμής του καθαρού φορτίου. Τις ώρες υψηλής Φ/Β παραγωγής η Φ/Β ισχύς χρησιμοποιείται για την κάλυψη τόσο των ευέλικτων όσο και των μη ευέλικτων φορτίων (Saini and Gidwani, 2022). Αυτό αντικατοπτρίζεται από την ακόλουθη εξίσωση ισοζυγίου ισχύος:

$$P_{PV}(t) + P_{ESS}(t) = P_{EV}(t) + P_{Load}(t) + P_{Grid}(t), \quad (10.1)$$

όπου P_{PV} είναι η ισχύς που παράγεται από το Φ/Β σύστημα, P_{Load} είναι η ηλεκτρική κατανάλωση των γραφείων του κτιρίου, P_{EV} είναι η κατανάλωση ισχύος των συνεδριών φόρτισης των EV και P_{ESS} είναι η ισχύς της μπαταρίας. Ενώ τα P_{PV} , P_{Load} και P_{EV} μπορούν να λάβουν μόνο θετικές τιμές, τα P_{ESS} και P_{Grid} μπορούν να λάβουν τόσο θετικές όσο και αρνητικές τιμές. Μια θετική τιμή P_{ESS} υποδηλώνει ότι η μπαταρία παρέχει ενέργεια στο μικροδίκτυο (εκφόρτιση μπαταρίας), ενώ μια αρνητική τιμή P_{ESS} υποδηλώνει ότι η μπαταρία αποθηκεύει την περίσσεια της παραγόμενης ενέργειας από τις ΑΠΕ (φόρτιση μπαταρίας). Η τιμή P_{Grid} αντιπροσωπεύει την ανταλλαγή ενέργειας μεταξύ του μικροδικτύου και του κύριου ηλεκτρικού δικτύου. Υπάρχουν δύο πιθανά σενάρια: Είτε η παραγωγή των Φ/Β συστημάτων υπερβαίνει τις συνολικές ενεργειακές ανάγκες, με αποτέλεσμα να δημιουργείται RPF προς το κύριο δίκτυο ηλεκτρικής ενέργειας, είτε το Φ/Β σύστημα αδυνατεί να ικανοποιήσει τις συνολικές ενεργειακές ανάγκες, με αποτέλεσμα να δημιουργείται ζήτηση από το κύριο δίκτυο ηλεκτρικής ενέργειας και έτσι να περιορίζεται η ενεργειακή αυτονομία. Πιο συγκεκριμένα, εάν η παραγωγή υπερβαίνει τη συνολική κατανάλωση, τότε το πλεόνασμα ενέργειας χρησιμοποιείται για τη φόρτιση της μπαταρίας. Στην περίπτωση όμως που η μπαταρία είναι πλήρως φορτισμένη, η εναπομένουσα πλεονάζουσα ενέργεια διαχετεύεται στο δίκτυο. Στη δεύτερη περίπτωση, όπου η ζήτηση ενέργειας είναι μεγαλύτερη από την παραγόμενη ενέργεια, το μικροδίκτυο χρησιμοποιεί τη μπαταρία για να καλύψει τις ενεργειακές του ανάγκες. Ωστόσο, στην περίπτωση

που η μπαταρία δεν μπορεί να καλύψει τη συνολική ζήτηση του μικροδικτύου, τότε η υπόλοιπη ενέργεια παρέχεται από το κύριο δίκτυο. Αυτές οι δύο περιπτώσεις παρουσιάζονται στο Σχήμα 10.5.



(a) Η παραγωγή ενέργειας από Φ/Β είναι μεγαλύτερη από το άθροισμα της ενεργειακής ζήτησης των κτιρίων και των ηλεκτρικών συσκευών.

(b) Η παραγωγή ηλεκτρικής ενέργειας με βάση τα Φ/Β είναι μικρότερη από το άθροισμα της ενεργειακής ζήτησης των κτιρίων και των ηλεκτρικών συσκευών.

Σχήμα 10.5: Γραφική αναπαράσταση των ροών ισχύος κατά τη διάρκεια των δύο πιθανών σεναρίων: (α) η παραγωγή ενέργειας είναι μεγαλύτερη από τη ζήτηση (αριστερό σχήμα), (β) η ζήτηση είναι μεγαλύτερη από την παραγωγή ενέργειας (δεξί σχήμα).

Σε αυτό το πλαίσιο, η εξίσωση διαχείρισης ενέργειας του μικροδικτύου μπορεί να γραφτεί στην ακόλουθη μορφή:

$$P_{PV}(t) + P_{ESS}(t) + P_{DfG}(t) = P_{EV}(t) + P_{Load}(t) + P_{RPF}(t), \quad (10.2)$$

όπου P_{DfG} είναι η ζήτηση ισχύος από το δίκτυο και P_{RPF} είναι η αντίστροφη ροή ισχύος. Αυτές οι δύο μεταβλητές λαμβάνουν μόνο θετικές τιμές και αντικαθιστούν την P_{Grid} στην προηγούμενη εξίσωση. Στην περίπτωση πλεονάζουσας παραγωγής από Φ/Β, η P_{DfG} είναι ίση με μηδέν, ενώ στην περίπτωση που η ζήτηση είναι μεγαλύτερη από την παραγωγή, η P_{RPF} είναι ίση με μηδέν. Επίσης, η κατάσταση φόρτισης του ESS πρέπει να βρίσκεται μεταξύ του ελάχιστου και του μέγιστου ορίου για τη διασφάλιση της σωστής λειτουργίας της μπαταρίας. Συνεπώς, πρέπει να ικανοποιείται ο ακόλουθος περιορισμός:

$$P_{ESS_{min}}(t) \leq P_{ESS}(t) \leq P_{ESS_{max}}(t). \quad (10.3)$$

Σε σχέση με την προαναφερθείσα μοντελοποίηση του μικροδικτύου και λαμβάνοντας επίσης υπόψη το βελτιστοποιημένο χρονοδιάγραμμα των περιόδων φόρτισης των EV, ο ψευδοκώδικας της μεθόδου που βασίζεται σε κανόνες για τον έλεγχο του ESS την επόμενη ημέρα παρουσιάζεται στον Αλγόριθμο 3. Ο αλγόριθμος λαμβάνει ως είσοδο την παραγωγή και τη ζήτηση των περιουσιακών στοιχείων του δικτύου και υπολογίζει την κατάσταση φόρτισης της μπαταρίας σε κάθε ωριαίο διάστημα. Ο Αλγόριθμος 3 περιλαμβάνει επίσης τον υπολογισμό των RPF και DfG κατά τη διάρκεια της διαδικασίας προσομοίωσης.

10.4 Μελέτη Περίπτωσης

Προκειμένου να καταδειχθεί πώς λειτουργεί το προτεινόμενο πλαίσιο στην πράξη και να αξιολογηθούν τα δυνητικά οφέλη του σε όρους τεσσάρων βασικών δεικτών απόδοσης (KPIs), ήτοι i) ετήσιος RPF, ii) ετήσιος DfG, iii) ενεργειακή αυτονομία (αριθμός ημερών⁴ μέσα σε ένα έτος που η DfG είναι μηδενική), και (iv) εξοικονόμηση αιχμής (μέσο ημερήσιο εύρος της

⁴Στα Σχήματα 10.8 και 10.9, η ενεργειακή αυτονομία μετράται σε ημέρες αντί για ώρες για να διευκολυνθούν οι συγκρίσεις. Ωστόσο, τα αποτελέσματα αυτά δεν αντιπροσωπεύουν πραγματικές ημέρες μηδενικής DfG, αλλά έναν αριθμό μεμονωμένων ωρών, συγκεντρωμένων σε παρτίδες 24 ωρών.

Algorithm 3: Αλγόριθμος βασισμένος σε κανόνες για τον έλεγχο του ESS.

Inputs : *Production*: $\{x_1, x_2, \dots, x_{24}\}$, hourly production of solar PV;
Demand: $\{y_1, y_2, \dots, y_{24}\}$, hourly demand of building and EV charging sessions;

Output: *ESS_end*: $\{z_1, z_2, \dots, z_{24}\}$ the state of charge of the battery at the end of each hour;

Obviously, the following equity applies for all intervals:

$$ESS_end[z_i] = ESS_start[z_{i+1}]$$

```

1 for i in range(24 hours) do
2   if Production[i] ≥ Demand[i] then
3     /* Case 1: Excess of solar PV production */
4     difference ← Production[i] - Demand[i];
5     ESS_potential ← ESS_max - ESS_start[i];
6     if difference ≥ ESS_potential then
7       /* Case 1.1: Excess energy is more than ESS capacity */
8       ESS_end[i] ← ESS_max;
9       DfG ← 0; RPF ← difference - ESS_potential;
10    else
11      /* Case 1.2: Excess energy is less than ESS capacity */
12      ESS_end[i] ← ESS_start[i] + difference;
13      DfG ← 0; RPF ← 0;
14    end
15  else
16    /* Case 2: Demand is more than solar PV production */
17    difference ← Demand[i] - Production[i];
18    if difference ≤ ESS_start[i] then
19      /* Case 2.1: Net demand can be satisfied by the ESS */
20      ESS_end[i] ← ESS_start[i] - difference;
21      DfG ← 0; RPF ← 0;
22    else
23      /* Case 2.2: Net demand cannot be satisfied by the ESS */
24      ESS_end[i] ← 0;
25      DfG ← difference - ESS_start[i]; RPF ← 0;
26    end
27  end
28 end

```

DfG), εξετάζουμε την περίπτωση της ASM Terni S.p.A., ενός οργανισμού που βρίσκεται στο Terni της κεντρικής Ιταλίας.

10.4.1 Σύνολο Δεδομένων

Το μικροδίκτυο που μελετάμε καλύπτει μια έκταση περίπου 3 εκταρίων στα προάστια της Terni, με ένα τριώροφο κτίριο με γραφεία, τρεις αποθήκες για την προμήθεια ηλεκτρικού ρεύματος, φυσικού αερίου και νερού, που χρησιμοποιούνται από την πολυχρηστία, και δύο χώρους στάθμευσης που καλύπτονται από Φ/Β συστήματα (10.6). Το μικροδίκτυο συνδέεται με το εξωτερικό δίκτυο μέσω δύο δευτερευόντων υποσταθμών, οι οποίοι διαθέτουν ηλεκτρικούς μετασχηματιστές γεμάτους με λάδι ονομαστικής ισχύος 250 και 400 kVA.

Η κατανάλωση ηλεκτρικής ενέργειας στο κτίριο και τις αποθήκες, η οποία ανέρχεται σε περίπου 650 MWh ετησίως, αφορά κυρίως τον φωτισμό και την τροφοδοσία ηλεκτρικών συσκευών (π.χ. υπολογιστές και διακομιστές). Το Φ/Β σύστημα παραγωγής αποτελείται από



Σχήμα 10.6: Η υποδομή της πραγματικής περίπτωσης χρήσης στο Terni της Ιταλίας. Το εξεταζόμενο μικροδίκτυο αποτελείται από ένα τριώροφο κτίριο με γραφεία (πάνω αριστερά), δύο χώρους στάθμευσης με Φ/Β πάνελ (πάνω δεξιά), τρεις σταθμούς φόρτισης ηλεκτρικών οχημάτων (κάτω αριστερά) και ένα BESS (κάτω δεξιά).

1.100 μονοκρυσταλλικά πάνελ πυριτίου ισχύος 150 W στα 12 V με διαστάσεις 98,5 x 98,5 cm. Το Φ/Β σύστημα βρίσκεται στο χώρο στάθμευσης και διασυνδέεται με το μικροδίκτυο μέσω ενός μετατροπέα 200 kVA. Τα φορτία και οι Φ/Β γεννήτριες είναι εξοπλισμένα με αισθητήρες παρακολούθησης σε πραγματικό χρόνο με τη χρήση αναλυτών ποιότητας ισχύος, οι οποίοι επιτρέπουν την παρακολούθηση των τιμών τάσης, ρεύματος, ενεργού και άεργου ισχύος των διαφόρων συσκευών και την αποθήκευσή τους σε μια βάση δεδομένων με κοκκομετρία 1 δευτερολέπτου.

Στο χώρο στάθμευσης υπάρχουν 3 σταθμοί φόρτισης ηλεκτρικών οχημάτων, ο καθένας εξοπλισμένος με δύο σημεία φόρτισης έως 22 kW AC και 32 A, μονοφασικά ή τριφασικά. Οι σταθμοί φόρτισης διαθέτουν διεπαφή χρήστη για την έναρξη και τη ρύθμιση της φόρτισης, έξυπνο μετρητή σε πραγματικό χρόνο και δυνατότητα διαμόρφωσης της ισχύος φόρτισης από απόσταση. Ο στόλος EV που χρησιμοποιεί τις εγκαταστάσεις φόρτισης αποτελείται επί του παρόντος από πέντε αυτοκίνητα που ανήκουν στην εταιρεία, αλλά υπάρχουν σχέδια για σημαντική αύξηση του μεγέθους του τα επόμενα χρόνια για την προώθηση των βιώσιμων μεταφορών στην πόλη.

Δεδομένου ότι οι μπαταρίες των EV που αποτελούν το στόλο έχουν μέση χωρητικότητα περίπου 40 kWh, και υποθέτοντας ότι οι οδηγοί είναι πρόθυμοι να φορτίσουν τα αυτοκίνητά τους όταν το επίπεδο φόρτισης της μπαταρίας πέφτει περίπου στο 20%, κάθε περίοδος φόρτισης αναμένεται να καταναλώνει περίπου 33 kWh και να διαρκεί κατά μέσο όρο τρεις ώρες. Πράγματι, οι εκτιμήσεις αυτές βρίσκονται σε γενική συμφωνία με τα πραγματικά διαθέσιμα δεδομένα, που συνοψίζουν τη διάρκεια και την ηλεκτρική ενέργεια που καταναλώνεται ανά συνεδρία φόρτισης. Παρ' όλα αυτά, δεδομένου ότι οι διαθέσιμοι σήμερα φορτιστές υπερκαλύπτουν τη ζήτηση, όπως αναμενόταν, είναι χαρακτηριστικό ότι πολλοί χρήστες συνδέουν

τα αυτοκίνητά τους στους φορτιστές όταν φτάνουν στο κτίριο (περίπου στις 08:00) και τα αποσυνδέουν όταν φεύγουν από την εργασία τους (περίπου στις 17:00).

10.4.2 Επίδοση Προβλεπτικών Μοντέλων

Η ακρίβεια των μοντέλων πρόβλεψης που κατασκευάστηκαν για την πρόβλεψη της κατανάλωσης ηλεκτρικής ενέργειας και της ηλιακής ενέργειας αξιολογήθηκε με τη χρήση του μέσου τετραγωνικού σφάλματος (RMSE) και του συντελεστή συσχέτισης Pearson, ως εξής:

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - f_t)^2},$$

$$r_{y,f} = \frac{\sum_{t=1}^N (y_t - \bar{y})(f_t - \bar{f})}{\sqrt{\sum_{t=1}^N (y_t - \bar{y})^2} \sqrt{\sum_{t=1}^N (f_t - \bar{f})^2}},$$

όπου N είναι ο αριθμός των παρατηρήσεων που εξετάζονται για την αξιολόγηση (8.760 ώρες), y_t είναι η πραγματική μελλοντική τιμή της εξεταζόμενης χρονοσειράς την ώρα t της περιόδου αξιολόγησης, f_t είναι η αντίστοιχη πρόβλεψη, ενώ \bar{y} και \bar{f} ο μέσος όρος των πραγματικών και των προβλεπόμενων τιμών, αντίστοιχα.

Δεδομένου ότι τα τετραγωνικά σφάλματα βελτιστοποιούνται για το μέσο (Kolassa, 2016) και τιμωρούν περισσότερο τα μεγαλύτερα σφάλματα που συνήθως εμφανίζονται κατά τη διάρκεια των ωρών αιχμής (Koutsandreas et al., 2022), τα επιλεγμένα μέτρα είναι χρήσιμα για τον εντοπισμό μοντέλων που παρέχουν καλύτερες προβλέψεις, τόσο κατά μέσο όρο, αλλά και κατά τις πιο κρίσιμες ώρες της ημέρας για τους διαχειριστές και τους παραγωγούς ενέργειας. Παρ' όλα αυτά, προκειμένου να διευκολυνθούν οι συγκρίσεις με τα τυποποιημένα κριτήρια αναφοράς που χρησιμοποιούνται στο πεδίο (Yang et al., 2020), εκτός από τα δύο μέτρα ακρίβειας που παρουσιάστηκαν παραπάνω, υπολογίστηκε επίσης ο δείκτης ικανότητας πρόβλεψης (FSI) για να δείξει τη σχετική απόδοση των μοντέλων πρόβλεψης που αναπτύχθηκαν με εκείνη των μοντέλων επιμονής που θέτουν κάθε πρόβλεψη ίση με την τελευταία γνωστή παρατήρηση της ίδιας εποχικής περιόδου, ως εξής:

$$FSI = 1 - \frac{RMSE_{proposed}}{RMSE_{persistence}}, \quad (10.4)$$

όπου οι προβλέψεις του υποδείγματος επιμονής p είναι ισοδύναμες με εκείνες του εποχιακού υποδείγματος Naive, ως εξής:

$$p_t = y_{t-s}. \quad (10.5)$$

Δεδομένου ότι στις βραχυπρόθεσμες ρυθμίσεις πρόβλεψης η ηλιακή ενέργεια μπορεί να θεωρηθεί ότι έχει εποχικό κύκλο 24 ωρών (ενδοημερήσια εποχικότητα), ενώ η κατανάλωση ηλεκτρικής ενέργειας έχει εποχικό κύκλο 168 ωρών (ενδοεβδομαδιαία εποχικότητα), το s ορίστηκε ίσο με 24 και 168 ώρες, αντίστοιχα.

Ο Πίνακας A1 συνοψίζει τις επιδόσεις των μοντέλων πρόβλεψης της κατανάλωσης ηλεκτρικής ενέργειας και της ηλιακής ενέργειας που χρησιμοποιήθηκαν στη μελέτη περίπτωσης. Όπως φαίνεται, και τα δύο μοντέλα καταφέρνουν να ξεπεράσουν σημαντικά τα μοντέλα επιμονής, βελτιώνοντας την ακρίβεια κατά 34% και 51%, αντίστοιχα. Επιπλέον, με βάση το μέτρο $r_{y,f}$, διαπιστώνουμε ότι οι προβλέψεις συσχετίζονται σε μεγάλο βαθμό με τις πραγματικές μελλοντικές τιμές, διευκολύνοντας έτσι τις βελτιστοποιήσεις που πραγματοποιήθηκαν στη μελέτη μας. Το τελευταίο επιβεβαιώνεται τόσο από το Σχήμα A1, το οποίο απεικονίζει τον τρόπο

συσχέτισης των προβλέψεων κατανάλωσης ηλεκτρικής ενέργειας και ηλιακής ισχύος με τις αντίστοιχες πραγματικές τιμές, όσο και από το Σχήμα A2, το οποίο παρέχει ορισμένα ενδεικτικά παραδείγματα προβλέψεων για μια τυχαία επιλεγμένη καλοκαιρινή και χειμερινή εβδομάδα της περιόδου αξιολόγησης.

Πίνακας B1: Απόδοση πρόβλεψης (ακρίβεια) των μοντέλων που αναπτύχθηκαν και χρησιμοποιήθηκαν στη μελέτη περίπτωσης.

Measure	Electricity Consumption	Solar Power
$RMSE$	8.73	9.59
FSI	0.34	0.51
$r_{y,f}$	0.89	0.97




Figure B1: Διαγράμματα διασποράς που απεικονίζουν τη συσχέτιση των προβλέψεων για την κατανάλωση ηλεκτρικής ενέργειας (αριστερά) και την ηλιακή ενέργεια (δεξιά) με τις αντίστοιχες πραγματικές τιμές. Προκειμένου να ληφθεί υπόψη η πυκνότητα των προβλέψεων, ο χώρος χωρίζεται σε 75 ίσα ορθογώνια και χρησιμοποιείται ένας χάρτης θερμότητας για να απεικονίσει τον αριθμό των προβλέψεων που περιέχονται σε κάθε ορθογώνιο. Η διακεκομμένη διαγώνια γραμμή αντιστοιχεί στις τέλει προβλέψεις.

10.4.3 Βελτιστοποίηση Διαχείρισης Ενέργειας

Για να εκτιμήσουμε τον αντίκτυπο που μπορεί να έχουν στο μέλλον τα διάφορα μεγέθη των στόλων EV στους εξεταζόμενους δείκτες απόδοσης, προσομοιώνουμε την ημερήσια εισροή $N \in \{5, 10, \dots, 35, 40\}$ EVs για περίοδο ενός έτους (365 ημέρες). Για το σκοπό αυτό, επιλέγουμε πρώτα τυχαία N αριθμούς από μια ομοιόμορφη κατανομή $U(0.1, 0.9) * 100\%$, που υποδεικνύει το αρχικό επίπεδο φόρτισης της μπαταρίας για κάθε EV. Στη συνέχεια, υποθέτοντας ότι όλοι οι οδηγοί των οποίων το αυτοκίνητο είναι φορτισμένο κάτω από 20% θα είναι πρόθυμοι να φορτίσουν το όχημά τους, προσδιορίζουμε την εισροή EV της πρώτης ημέρας της περιόδου προσομοίωσης. Για να εκτιμήσουμε την εισροή EV για τις επόμενες ημέρες, υποθέτουμε ότι κάθε αυτοκίνητο καλύπτει μια μέση απόσταση 20 km ανά ημέρα, μειώνοντας έτσι κατάλληλα το προηγούμενο επίπεδο φόρτισης. Παρόμοια με την πρώτη ημέρα της προσομοίωσης, κάθε φορά που το επίπεδο φόρτισης της μπαταρίας ενός EV πέφτει κάτω από το 20%, θεωρείται ότι είναι πλήρως φορτισμένο την επόμενη ημέρα. Για να εξασφαλιστούν δίκαιες και άμεσες συγκρίσεις μεταξύ διαφορετικών προσομοιώσεων, η αρχικοποίηση της κατάστασης φόρτισης των EV πραγματοποιείται μόνο μία φορά.

Για να διευκολύνουμε τις συγκρίσεις και να αξιολογήσουμε την πιθανή επίδραση του προτεινόμενου πλαισίου σε διάφορες συνθήκες χρήσης, εξετάζουμε τα ακόλουθα τρία σενάρια:

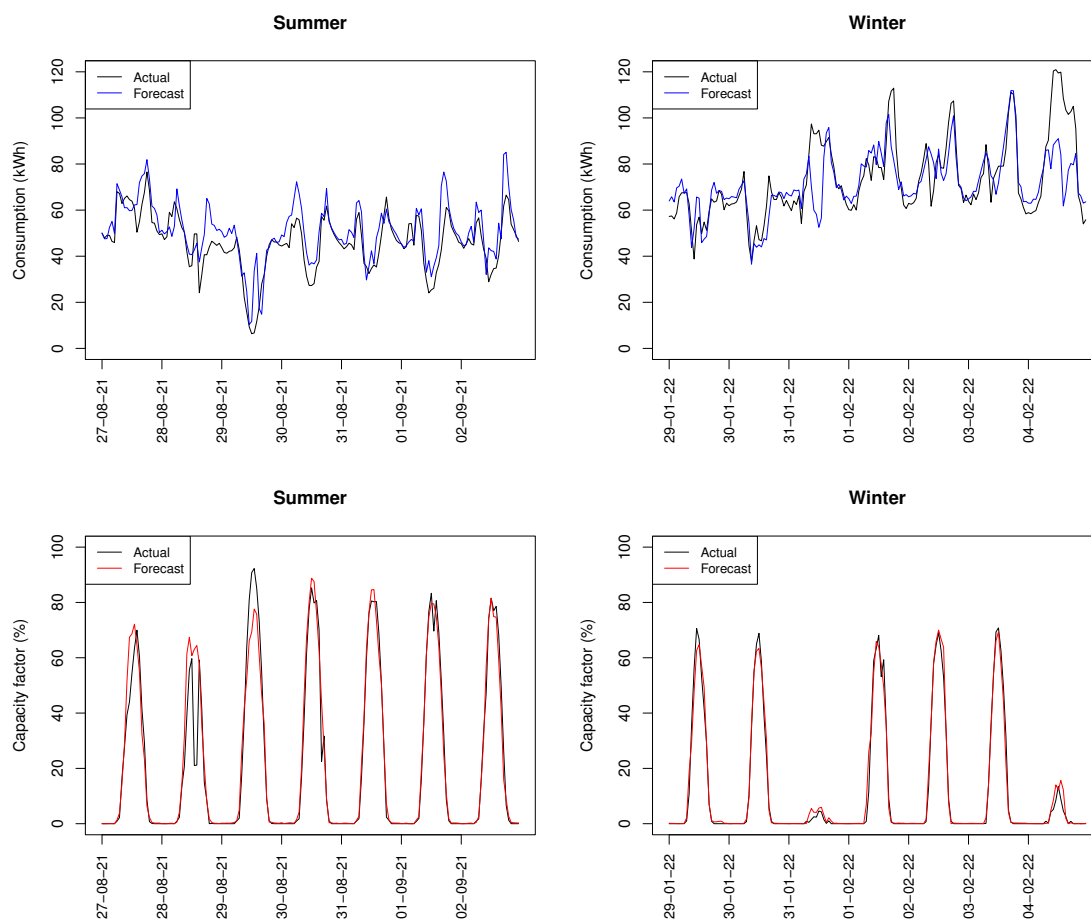


Figure B2: Παραδείγματα που απεικονίζουν τις επιδόσεις των μοντέλων πρόβλεψης της κατανάλωσης ηλεκτρικής ενέργειας (επάνω) και της ηλιακής ενέργειας (κάτω). Τα παραδείγματα αναφέρονται σε δύο τυχαία επιλεγμένες καλοκαιρινές (2021-08-27 έως 2021-09-02) και χειμερινές (2022-01-29 έως 2022-02-04) εβδομάδες της περιόδου αξιολόγησης.

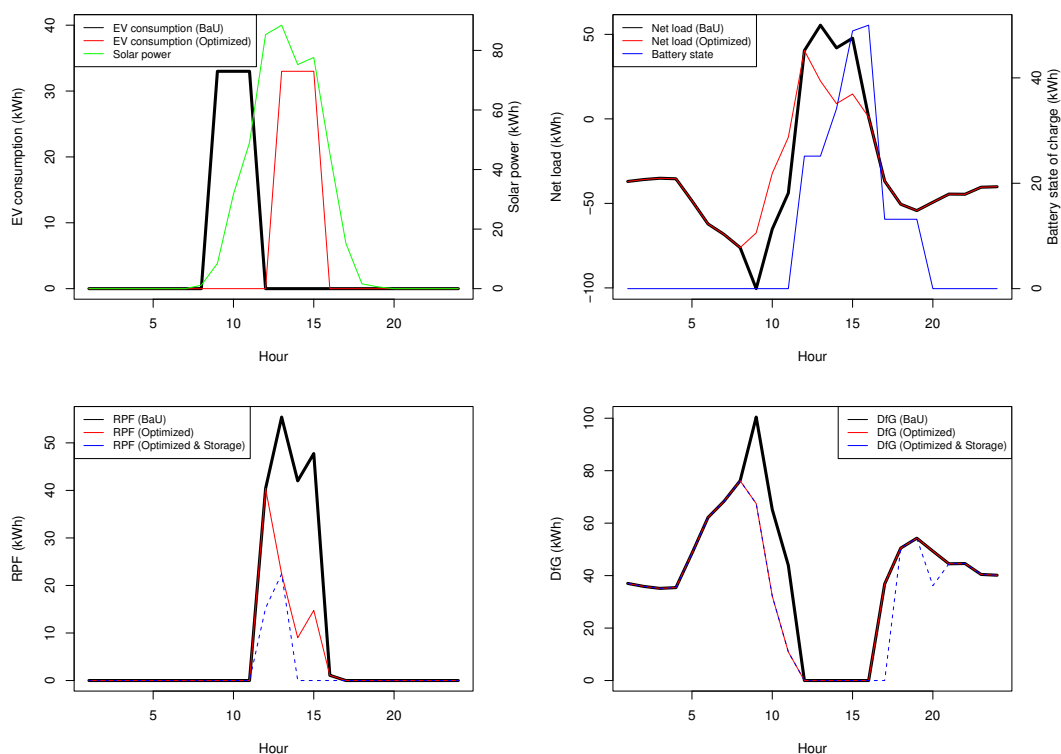
- **Business as usual (BaU):** Σε αυτό το σενάριο, όλοι οι οδηγοί που ενδιαφέρονται να φορτίσουν τα ηλεκτροκίνητα οχήματά τους συνδέουν τα αυτοκίνητά τους στους φορτιστές κατά την άφιξή τους στη δουλειά (08:00). Επίσης, δεν υπάρχει διαθέσιμη μπαταρία για την αποθήκευση της ηλεκτρικής ενέργειας που παράγεται από το Φ/Β σύστημα.
- **Βέλτιστος προγραμματισμός συνεδριών φόρτισης EV:** Σε αυτό το σενάριο, οι οδηγοί που ενδιαφέρονται να φορτίσουν τα EV τους συνδέουν τα αυτοκίνητά τους στους φορτιστές την ώρα που προτείνει ο αλγόριθμος βελτιστοποίησης της υποεπάρκειας 10.3.2. Ωστόσο, παρόμοια με το σενάριο BaU, δεν υπάρχει διαθέσιμη μπαταρία για την αποθήκευση της ηλεκτρικής ενέργειας που παράγεται από το Φ/Β σύστημα.
- **Βέλτιστος προγραμματισμός των συνεδριών φόρτισης των EV και αυτοματοποίηση της αποθήκευσης ηλεκτρικής ενέργειας:** Παρόμοια με το προηγούμενο σενάριο, οι οδηγοί που ενδιαφέρονται να φορτίσουν τα EV τους συνδέουν τα αυτοκίνητά τους στους φορτιστές σύμφωνα με τις προτάσεις του προτεινόμενου αλγορίθμου. Επιπλέον, αφού καθοριστεί ο χρόνος που θα ξεκινήσουν τη φόρτιση των EVs, χρησιμοποιείται μια μπαταρία για την αυτόματη αποθήκευση της ηλεκτρικής ενέργειας που παράγεται από τη Φ/Β μονάδα όταν είναι κατάλληλη και τη χρήση της όταν είναι απαραίτητο, όπως ορίζεται από τον αλγόριθμο του υποκεφαλαίου 13.

Προκειμένου να εκτιμηθεί ο αντίκτυπος που μπορεί να έχουν οι μπαταρίες διαφόρων χωρητικότητων στους εξεταζόμενους KPIs, διεξάγονται ξεχωριστές προσομοιώσεις για μπαταρίες χωρητικότητας $C \in \{5, 10, 15, \dots, 90, 95, 100\}$ kWh.

Τα δεδομένα που χρησιμοποιούνται για την εφαρμογή κάθε σεναρίου και των παραλλαγών του είναι ωριαία και έχουν διάρκεια περίπου 2 έτη και 11 μήνες (25536 ώρες), από τις 6 Σεπτεμβρίου 2019 έως τις 3 Αυγούστου 2022. Η περίοδος από τις 4 Αυγούστου 2021 έως τις 3 Αυγούστου 2022 χρησιμοποιείται για σκοπούς αξιολόγησης, ενώ τα υπόλοιπα δεδομένα για την εκπαίδευση των μοντέλων που θα χρησιμοποιηθούν για την πρόβλεψη της κατανάλωσης ηλεκτρικής ενέργειας στο κτίριο και της Φ/Β ενέργειας για την επόμενη ημέρα (24 ώρες). Ως εκ τούτου, το αρχικό σύνολο δεδομένων περιλαμβάνει τη συνολική ηλεκτρική ενέργεια που καταναλώνεται από το κτίριο και την ηλεκτρική ενέργεια που παράγεται από τη Φ/Β εγκατάσταση, αλλά συμπληρώνεται από τα προσομοιωμένα δεδομένα, τα οποία υποδεικνύουν την ηλεκτρική ενέργεια που καταναλώνεται από τα ηλεκτρικά ρεύματα. Αυτές οι μεταβλητές αποτελούν ουσιαστικά την είσοδο των προτεινόμενων αλγορίθμων βελτιστοποίησης.

Για να αποσαφηνίσουμε τον τρόπο λειτουργίας του προτεινόμενου πλαισίου και να υπολογίσουμε τα μέγιστα δυνητικά οφέλη του, ξεκινάμε την ανάλυσή μας με την εφαρμογή της προσέγγισής μας χρησιμοποιώντας ως είσοδο την πραγματική κατανάλωση ηλεκτρικής ενέργειας του κτιρίου και την παραγωγή Φ/Β ως είσοδο, δηλαδή υποθέτοντας τέλεια πρόβλεψη. Το Σχήμα 10.7 παρέχει ένα ενδεικτικό παράδειγμα του τρόπου με τον οποίο το προτεινόμενο πλαίσιο βελτιστοποίησης επηρεάζει το χρονοδιάγραμμα των συνεδριών φόρτισης EV, το καθαρό φορτίο, την κατάσταση φόρτισης της μπαταρίας, το DfG και το RPF σε μια τυχαία επιλεγμένη ημερομηνία της περιόδου αξιολόγησης. Όπως φαίνεται, δεδομένου ότι η παραγωγή Φ/Β είναι υψηλότερη γύρω στο μεσημέρι, ο αλγόριθμος προγραμματισμού προτείνει τη μετατόπιση του φορτίου EV κατά τέσσερις ώρες. Ως αποτέλεσμα, το RPF μειώνεται σημαντικά, η αιχμή του καθαρού φορτίου ξυρίζεται σε αξιοσημείωτο βαθμό, ενώ το DfG πέφτει ουσιαστικά. Επιπλέον, όταν είναι διαθέσιμη η αποθήκευση ηλεκτρικής ενέργειας, μέρος της πλεονάζουσας ενέργειας που παράγεται από το Φ/Β σύστημα αποθηκεύεται κατά τις απογευματινές ώρες και χρησιμοποιείται κατά τις νυχτερινές ώρες για την περαιτέρω μείωση του RPF και του DfG.

Το Σχήμα 10.8 συνοψίζει τον αντίκτυπο του αλγορίθμου χρονοπρογραμματισμού όταν δεν υπάρχει διαθέσιμη μπαταρία για την αποθήκευση της ενέργειας που παράγεται από το Φ/Β σύστημα κατά το σενάριο BaU. Όπως είναι αναμενόμενο, όσο μεγαλύτερο γίνεται το μέγεθος του στόλου των EV, τόσο περισσότερη ενέργεια καταναλώνεται από το δίκτυο. Παρ' όλα αυτά, η βελτιστοποίηση μπορεί ακόμα να οδηγήσει σε εξοικονόμηση ενέργειας που κυμαίνεται από 1,5% (5 EVs) έως 7,2% (40 EVs). Είναι ενδιαφέρον ότι, αν και οι ποσοστιαίες βελτιώσεις τείνουν να αυξάνονται με τον αριθμό των EV που χρησιμοποιούν την εγκατάσταση, διαπιστώνουμε ότι οι εν λόγω βελτιώσεις δεν είναι γραμμικές, αλλά συγκλίνουν σταδιακά μετά από ένα ορισμένο σημείο. Κατά συνέπεια, δεδομένης της διαστασιολόγησης της εγκατάστασης όσον αφορά τα μη ευέλικτα φορτία και την παραγόμενη ηλεκτρική ενέργεια, θα μπορούσε να προσδιοριστεί ένα σημείο "χρυσού" των χρηστών EV. Όσον αφορά το RPF, παρατηρούμε ότι ο βέλτιστος προγραμματισμός μπορεί πράγματι να αποδειχθεί επωφελής, μειώνοντας το μέγεθός του από 7,2% (5 EVs) σε 44,3% (40 EVs). Αυτή τη φορά, οι βελτιώσεις είναι πάντα μεγαλύτερες για μεγαλύτερους στόλους EV, πράγμα αναμενόμενο δεδομένου ότι περισσότερες συνεδρίες φόρτισης EV συνεπάγονται μικρότερο πλεόνασμα ηλιακής ενέργειας. Ωστόσο, είναι προφανές ότι η RPF δεν μπορεί να εξαλειφθεί, κυρίως επειδή η φόρτιση των EV είναι δυνατή μόνο κατά τις ώρες γραφείου (μέρος της ηλεκτρικής ενέργειας που παράγεται από τη Φ/Β μονάδα τις πρώτες πρωινές και τις τελευταίες απογευματινές ώρες μπορεί να παραμείνει αχρησιμοποίητο). Ωστόσο, εάν οι σταθμοί φόρτισης EV χρησιμοποιούνταν εκτός των ωρών γραφείου, ενδεχομένως από εξωτερικούς οδηγούς του κτιρίου, η RPF θα μπορούσε να μειωθεί περαιτέρω. Όπως αναμενόταν, και δεδομένης της αντικειμενικής του συνάρτησης, ο αλγόριθμος χρονοπρογραμματισμού έχει επίσης σημαντική θετική επίδραση στην εξοικονόμηση αιχμής, μειώνοντας το μέσο ημερήσιο εύρος του DfG από 3,7% (5 EVs) σε 34% (5 EVs). Αντίθετα, η ενεργειακή αυτονομία του μικροδικτύου παραμένει πρακτικά η ίδια για σχετικά μικρά μεγέθη

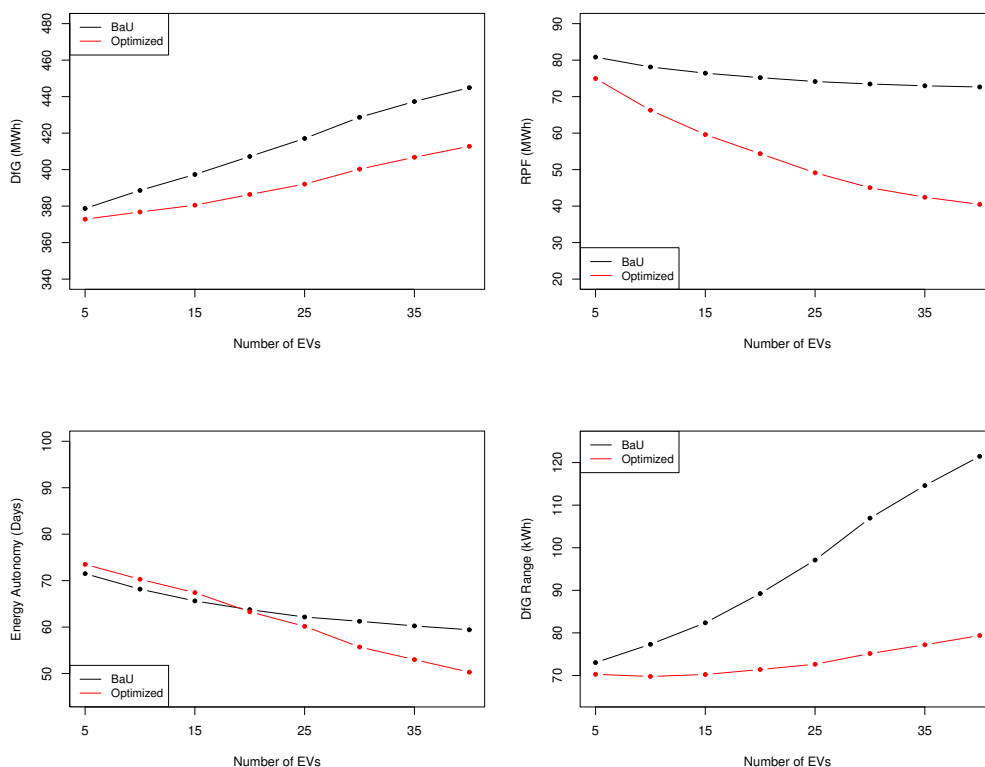


Σχήμα 10.7: Παράδειγμα που δείχνει πώς το προτεινόμενο πλαίσιο βελτιστοποίησης επηρεάζει το χρονοδιάγραμμα των περιόδων φόρτισης EV (πάνω αριστερά), το καθαρό φορτίο και την κατάσταση φόρτισης της μπαταρίας (πάνω δεξιά), το DfG (κάτω αριστερά) και το RPF (κάτω δεξιά). Το παράδειγμα αναφέρεται σε μια τυχαία επιλεγμένη ημερομηνία της περιόδου αξιολόγησης (2021-10-25) υποθέτοντας ότι (i) μια μπαταρία χωρητικότητας ίσης με 50 kWh χρησιμοποιείται για την αποθήκευση της ενέργειας που παράγεται από το Φ/Β σύστημα και (ii) 5 EV ενδιαφέρονται για φόρτιση κατά τη διάρκεια της ημέρας.

στόλου EV, ενώ επιδεινώνεται ελαφρώς για μεγαλύτερα. Αυτό οφείλεται στο γεγονός ότι, όταν το ευέλικτο φορτίο υπερβαίνει έναν ορισμένο βαθμό, η ηλεκτρική ενέργεια που παράγεται από το Φ/Β εργοστάσιο δεν επαρκεί για να επιτρέψει την ενεργειακή αυτονομία, ιδίως δεδομένου ότι οι αλγόριθμοι χρονοπρογραμματισμού προσπαθούν ρητά να εκμεταλλευτούν την εν λόγω παραγωγή τις ώρες αιχμής της ζήτησης.

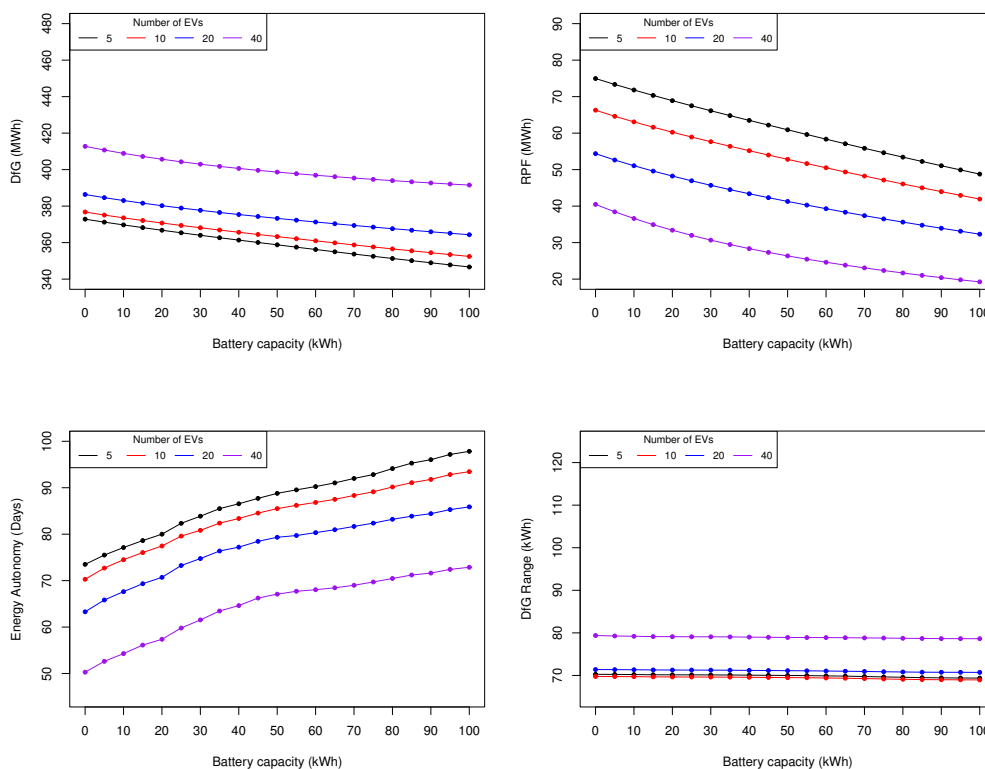
Το Σχήμα 10.9 παρέχει παρόμοιες συγκρίσεις με το Σχήμα 10.8, αλλά αυτή τη φορά εστιάζουν στον αντίκτυπο που έχει το σύστημα αποθήκευσης ενέργειας στο βελτιστοποιημένο χρονοπρογραμματισμό της φόρτισης του EV. Παρατηρούμε ότι οι μπαταρίες μεγαλύτερης χωρητικότητας μπορούν πράγματι να οδηγήσουν τόσο σε μικρότερη DfG όσο και σε RPF. Οι μέγιστες ποσοστιαίες βελτιώσεις (χρήση μηδενικής μπαταρίας έναντι της χρήσης μπαταρίας χωρητικότητας 100 kWh) όσον αφορά το DfG παραμένουν σχετικά σταθερές όταν υποθέσουμε έναν συγκεκριμένο αριθμό EVs, κυμαινόμενες από 5% (40 EVs) έως 7% (5 EVs). Το ίδιο ισχύει και για την εξοικονόμηση αιχμής που μειώνει την εμβέλεια DfG έως και 2%. Αντίθετα, οι αντίστοιχες βελτιώσεις του RPF επηρεάζονται σημαντικά από τον αριθμό των EVs, που κυμαίνονται από 35% (5 EVs) έως 52% (40 EVs). Όσον αφορά την ενεργειακή αυτονομία, τα αποτελέσματα είναι εξίσου ενθαρρυντικά, υποδεικνύοντας ότι για δεδομένο μέγεθος στόλου EV, οι περιπτώσεις μηδενικής DfG μπορούν να αυξηθούν από 33% (5 EVs) έως 45% (40 EVs). Έτσι, καταλήγουμε στο συμπέρασμα ότι η αποθήκευση ηλεκτρικής ενέργειας μπορεί να συμπληρώσει τον αλγόριθμο χρονοπρογραμματισμού και να ενισχύσει περαιτέρω την απόδοσή του όσον αφορά τη μειωμένη RPF και την ενισχυμένη ενεργειακή αυτονομία.

Ως τελικό βήμα στην ανάλυσή μας, και δεδομένου ότι στην πραγματική ζωή τα μοντέλα που



Σχήμα 10.8: Επίδραση του βέλτιστου προγραμματισμού των περιόδων φόρτισης του EV όταν δεν υπάρχει διαθέσιμη μπαταρία για την αποθήκευση της ενέργειας που παράγεται από το Φ/Β σύστημα. Τα στοιχεία αντιστοιχούν στην πλήρη περίοδο προσομοίωσης (σύνολο ενός ημερολογιακού έτους), υποθέτοντας ότι διάφορα EV ενδιαφέρονται να φορτίσουν στην εξεταζόμενη εγκατάσταση. Στο σενάριο BaU (business as usual) υποτίθεται ότι όλοι οι οδηγοί EV ξεκινούν τη φόρτιση των αυτοκινήτων τους στις 8:00, ενώ στο βελτιστοποιημένο σενάριο η ώρα έναρξης της συνεδρίας καθορίζεται με βάση την πραγματική ηλεκτρική ενέργεια που παράγεται από τη Φ/Β εγκατάσταση και καταναλώνεται από την εγκατάσταση.

χρησιμοποιούνται για την πρόβλεψη της κατανάλωσης ηλεκτρικής ενέργειας και της παραγωγής Φ/Β περιλαμβάνουν κάποιο σφάλμα πρόβλεψης, επαναλάβουμε τις προσομοιώσεις του τρίτου σεναρίου χρησιμοποιώντας ως είσοδο ενεργειακές προβλέψεις αντί για πραγματικές τιμές. Στη συνέχεια, για κάθε παραλλαγή του εξεταζόμενου σεναρίου (συνδυασμός χωρητικότητας μπαταρίας και αριθμού EVs) υπολογίσαμε τη σχετική απόδοση των δύο προσεγγίσεων σύμφωνα με τους εξεταζόμενους KPIs. Το Σχήμα 10.10 συνοψίζει την επίδραση του σφάλματος πρόβλεψης στον βέλτιστο προγραμματισμό των συνόδων φόρτισης των EV. Διαπιστώνουμε ότι οι ατελείς προβλέψεις έχουν ελάχιστη αρνητική επίδραση στην DfG, επιδεινώνοντας την απόδοση κατά λιγότερο από 2% σε σύγκριση με την προσομοίωση “τέλειας πρόβλεψης”. Επιπλέον, παρατηρούμε ότι η επιδείνωση είναι πολύ μικρότερη για περιορισμένο αριθμό χρηστών EV (λιγότερο από 0,7% για 10 EV) και μπαταρίες μεγαλύτερης χωρητικότητας. Παρόμοια συμπεράσματα μπορούν να εξαχθούν για την ενεργειακή αυτονομία που παραμένει σχεδόν αμετάβλητη. Από την άλλη πλευρά, καθίσταται σαφές ότι το σφάλμα πρόβλεψης μπορεί να έχει αξιοσημείωτο αντίκτυπο στην RPF, κυρίως όταν πολλά EV χρησιμοποιούν την εγκατάσταση. Σε τέτοιες ρυθμίσεις, η RPF μπορεί να αυξηθεί κατά περίπου 20%. Ωστόσο, η επίδραση των ατελών προβλέψεων αποδεικνύεται λιγότερο σημαντική (λιγότερο από 5% για 10 EV) για μικρότερα μεγέθη στόλων EV. Το ίδιο παρατηρείται και για τον δείκτη KPI εξοικονόμησης αιχμής, ο οποίος επιδεινώνεται έως και 11% για μεγάλα μεγέθη στόλων EV, επηρεαζόμενος



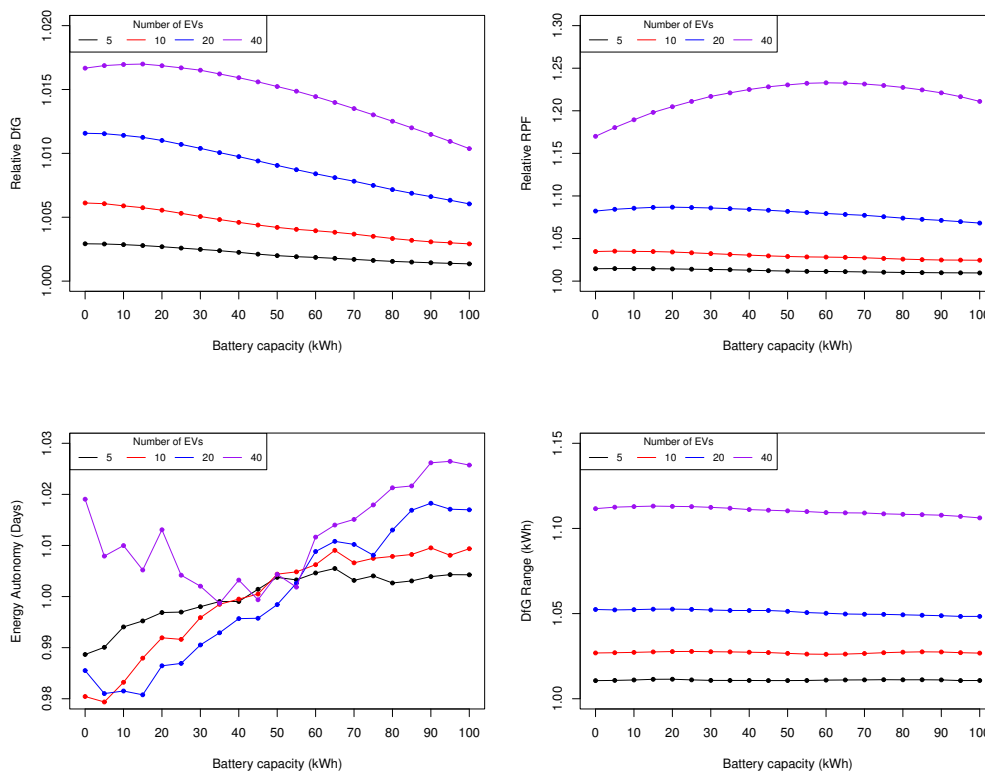
Σχήμα 10.9: Επίδραση του ESS στον βέλτιστο προγραμματισμό των περιόδων φόρτισης EV. Τα στοιχεία αντιστοιχούν στην πλήρη περίοδο προσομοίωσης (σύνολο ενός ημερολογιακού έτους), υποθέτοντας ότι διάφορα EV ενδιαφέρονται να φορτίσουν στην εξεταζόμενη εγκατάσταση και ότι υπάρχουν διαθέσιμες μπαταρίες διαφόρων χωρητικότητας για την αποθήκευση της ενέργειας που παράγεται από το Φ/Β σύστημα. Σε όλες τις περιπτώσεις, ο χρόνος έναρξης της συνεδρίας φόρτισης καθορίζεται με βάση την πραγματική ηλεκτρική ενέργεια που παράγεται από τη Φ/Β εγκατάσταση και καταναλώνεται από την εγκατάσταση.

ωστόσο ασήμαντα (λιγότερο από 2%) για μικρό αριθμό EV. Αναμφισβήτητα, παρόλο που τα μοντέλα πρόβλεψης που αναπτύχθηκαν μπορούν να θεωρηθούν σχετικά ακριβή, η επίτευξη καλύτερων προβλέψεων θα επέτρεπε ακόμη μεγαλύτερη εξοικονόμηση ενέργειας και μειωμένο ενεργειακό κόστος, το οποίο όμως είναι πιο σημαντικό για εγκαταστάσεις που εξυπηρετούν πολλά EVs σε καθημερινή βάση.

10.5 Συμπεράσματα

Τα έξυπνα συστήματα διαχείρισης ενέργειας μπορούν να συμβάλουν στην επίτευξη μικροδικτύων με μεγαλύτερη ενεργειακή αυτονομία, μειωμένο ενεργειακό κόστος και ομαλότερη λειτουργία. Εμπνευσμένη από τις προόδους της BM στην ενεργειακή πρόβλεψη, η παρούσα εργασία διερεύνησε την επίδραση που μπορούν να έχουν οι αλγόριθμοι βελτιστοποίησης με βάση την πρόβλεψη στην αποδοτική λειτουργία μικροδικτύων που περιλαμβάνουν μετατοπίσιμα φορτία και ESS.

Προτείνουμε ένα πλαίσιο που αποτελείται από μια μονάδα πρόβλεψης, η οποία χρησιμοποιείται για την πρόβλεψη της παραγωγής και της κατανάλωσης ηλεκτρικής ενέργειας για την επόμενη ημέρα, και μια μονάδα διαχείρισης ενέργειας, η οποία αποτελείται από δύο ευρετικούς αλγόριθμους βελτιστοποίησης. Ο πρώτος αλγόριθμος έχει ως αποστολή να μετατοπίζει τα ευέλικτα φορτία δεδομένου ενός συνόλου προβλέψεων, ενώ ο δεύτερος να ελέγχει τη διαδικασία



Σχήμα 10.10: Επίδραση του σφάλματος πρόβλεψης στον βέλτιστο προγραμματισμό των περιόδων φόρτισης EV. Τα στοιχεία (σχετική ενέργεια) αντιστοιχούν στην πλήρη περίοδο προσομοίωσης (άθροισμα ενός ημερολογιακού έτους) υποθέτοντας ότι διάφορα EV ενδιαφέρονται να φορτίσουν στην εξεταζόμενη εγκατάσταση και ότι υπάρχουν μπαταρίες διαφόρων χωρητικότητων για την αποθήκευση της ενέργειας που παράγεται από το Φ/Β φόρτισης καθορίζεται με βάση την προβλεπόμενη ηλεκτρική ενέργεια που παράγεται από τη Φ/Β εγκατάσταση και καταναλώνεται από την εγκατάσταση.

φόρτισης/εξφόρτισης των ESS. Ο γενικός στόχος του πλαισίου είναι η ελαχιστοποίηση της RPF του μικροδικτύου, η οποία ωστόσο μπορεί να έχει θετικό αντίκτυπο σε διάφορες άλλες διαστάσεις, όπως η ενέργεια που καταναλώνεται από το κύριο δίκτυο, η έκταση των αιχμών της ζήτησης και η ενεργειακή αυτονομία. Το πλαίσιο αξιολογήθηκε χρησιμοποιώντας ένα μικροδίκτυο που αποτελείται από ένα κτίριο γραφείων (μη μετατοπίσιμα φορτία), ένα Φ/Β σύστημα (παραγωγή ΑΠΕ), μια μπαταρία (αποθήκευση ηλεκτρικής ενέργειας) και έναν αριθμό EV (μετατοπίσιμα φορτία).

Τα αποτελέσματά μας δείχνουν ότι ο αλγόριθμος που προγραμματίζει τις περιόδους φόρτισης των EVs μπορεί να μειώσει σημαντικά το RPF, εξασφαλίζοντας παράλληλα χαμηλότερο ενεργειακό κόστος και μειωμένες αιχμές. Επιπλέον, ο αλγόριθμος ελέγχου του ESS μπορεί να συμπληρώσει τη μετατόπιση φορτίων, μειώνοντας περαιτέρω το RPF και βελτιώνοντας την ενεργειακή αυτονομία του μικροδικτύου. Διαπιστώνουμε ωστόσο ότι οι βελτιώσεις εξαρτώνται σε μεγάλο βαθμό από το μέγεθος του στόλου των EV και τη χωρητικότητα του ESS. Για παράδειγμα, στις προσομοιώσεις μας, ο αλγόριθμος προγραμματισμού μείωσε το RPF κατά 7,2% όταν ήταν διαθέσιμος ένας στόλος 5 EVs και κατά 44,3% όταν επρόκειτο να φορτιστούν 40 EVs. Ομοίως, δεδομένου ενός στόλου 10 EVs, ο βέλτιστος έλεγχος ενός ESS 100kWh αύξησε τις ημέρες ενεργειακής αυτονομίας από 70 ημέρες σε 94, οι οποίες θα ήταν 85 ημέρες αν και με δεδομένη μια μπαταρία της μισής χωρητικότητας.

Μελλοντικές εργασίες θα μπορούσαν να επεκτείνουν την παρούσα έρευνα εκμεταλλευομένες διαφορετικούς τύπους ΑΠΕ από τα Φ/Β συστήματα για την παραγωγή ηλεκτρικής ενέργειας ή περιλαμβάνοντας διαφορετικά ευέλικτα φορτία εκτός από τα EVs, όπως

αντλίες νερού, ηλεκτρικούς θερμοσίφωνες και συστήματα κλιματισμού, μεταξύ άλλων. Σε τέτοιες παραλλαγές, ο χώρος αναζήτησης των αλγορίθμων βελτιστοποίησης θα επεκταθεί και η δυναμική του συστήματος θα γινόταν πιθανότητα δυσκολότερο να μοντελοποιηθεί, επιτρέποντας έτσι μεγαλύτερες βελτιώσεις, αλλά απαιτώντας επίσης πιο γενικευμένες λύσεις. Ένα άλλο ενδιαφέρον πεδίο έρευνας θα ήταν η προσαρμογή των αντικειμενικών συναρτήσεων που χρησιμοποιούνται από τους αλγορίθμους βελτιστοποίησης, ώστε να λαμβάνουν υπόψη τους πρόσθετους παράγοντες που επηρεάζουν τα ενεργειακά συστήματα, όπως οι προτιμήσεις και η άνεση των κατοίκων των κτιρίων και των οδηγών των EVs ή οι τιμές της ενέργειας.

Βιβλιογραφία

- Abdel-Basset, M., Hawash, H., Chakraborty, R. K., and Ryan, M. (2021). Pv-net: An innovative deep learning approach for efficient forecasting of short-term photovoltaic energy production. *Journal of Cleaner Production*, 303:127037.
- Agga, A., Abbou, A., Labbadi, M., El Houm, Y., and Ali, I. H. O. (2022). Cnn-lstm: An efficient hybrid deep learning architecture for predicting short-term photovoltaic power production. *Electric Power Systems Research*, 208:107908.
- Aghamohammadi, M. R. and Abdolahinia, H. (2014). A new approach for optimal sizing of battery energy storage system for primary frequency control of islanded microgrid. *International Journal of Electrical Power & Energy Systems*, 54:325–333.
- Ahmed, R., Sreeram, V., Mishra, Y., and Arif, M. (2020). A review and evaluation of the state-of-the-art in pv solar power forecasting: Techniques and optimization. *Renewable and Sustainable Energy Reviews*, 124:109792.
- Aliasghari, P., Mohammadi-Ivatloo, B., Alipour, M., Abapour, M., and Zare, K. (2018). Optimal scheduling of plug-in electric vehicles and renewable micro-grid in energy and reserve markets considering demand response program. *Journal of Cleaner Production*, 186:293–303.
- Arwa, E. O. and Folly, K. A. (2020). Reinforcement learning techniques for optimal power control in grid-connected microgrids: A comprehensive review. *IEEE Access*, 8:208992–209007.
- Bakar, N. N. A., Hassan, M. Y., Sulaima, M. F., Na'im Mohd Nasir, M., and Khamis, A. (2017). Microgrid and load shedding scheme during islanded mode: A review. *Renewable and Sustainable Energy Reviews*, 71:161–169.
- Beheshti, Z. and Shamsuddin, S. M. H. (2013). A review of population-based meta-heuristic algorithms. *Int. J. Adv. Soft Comput. Appl*, 5(1):1–35.
- Das, U. K., Tey, K. S., Seyedmahmoudian, M., Mekhilef, S., Idris, M. Y. I., Van Deventer, W., Horan, B., and Stojcevski, A. (2018). Forecasting of photovoltaic power generation and model optimization: A review. *Renewable and Sustainable Energy Reviews*, 81:912–928.
- Dutta, S., Li, Y., Venkataraman, A., Costa, L. M., Jiang, T., Plana, R., Tordjman, P., Choo, F. H., Foo, C. F., and Puttgen, H. B. (2017). Load and renewable energy forecasting for a microgrid using persistence technique. *Energy Procedia*, 143:617–622.
- Fan, C., Xiao, F., and Zhao, Y. (2017). A short-term building cooling load prediction method using deep learning algorithms. *Applied energy*, 195:222–233.
- Gairaa, K., Benkaciali, S., and Guermoui, M. (2019). Clear-sky models evaluation of two sites over algeria for pv forecasting purpose. *The European Physical Journal Plus*, 134(10):1–17.
- Golpîra, H. and Bahramara, S. (2020). Internet-of-things-based optimal smart city energy management considering shiftable loads and energy storage. *Journal of Cleaner Production*, 264:121620.
- Graditi, G., Di Silvestre, M. L., Gallea, R., and Sanseverino, E. R. (2014). Heuristic-based shiftable loads optimal management in smart micro-grids. *IEEE Transactions on Industrial Informatics*, 11(1):271–280.

- Guerrero, J., Gebbran, D., Mhanna, S., Chapman, A. C., and Verbič, G. (2020). Towards a transactive energy system for integration of distributed energy resources: Home energy management, distributed optimal power flow, and peer-to-peer energy trading. *Renewable and Sustainable Energy Reviews*, 132:110000.
- Gupta, P. and Singh, R. (2021). Pv power forecasting based on data-driven models: a review. *International Journal of Sustainable Engineering*, 14(6):1733–1755.
- Haidar, A. M., Fakhar, A., and Helwig, A. (2020). Sustainable energy planning for cost minimization of autonomous hybrid microgrid using combined multi-objective optimization algorithm. *Sustainable Cities and Society*, 62:102391.
- Hajiaghahi, S., Salemnia, A., and Hamzeh, M. (2019). Hybrid energy storage system for microgrids applications: A review. *Journal of Energy Storage*, 21:543–570.
- Hannan, M., Wali, S., Ker, P., Abd Rahman, M., Mansor, M., Ramachandramurthy, V., Muttaqi, K., Mahlia, T., and Dong, Z. (2021). Battery energy-storage system: A review of technologies, optimization objectives, constraints, approaches, and outstanding issues. *Journal of Energy Storage*, 42:103023.
- Hassan, A. S., Cipcigan, L., and Jenkins, N. (2017). Optimal battery storage operation for pv systems with tariff incentives. *Applied Energy*, 203:422–441.
- Huo, Y., Bouffard, F., and Joós, G. (2021). Decision tree-based optimization for flexibility management for sustainable energy microgrids. *Applied Energy*, 290:116772.
- Kaldellis, J., Zafirakis, D., and Kavadias, K. (2009). Techno-economic comparison of energy storage systems for island autonomous electrical networks. *Renewable and Sustainable Energy Reviews*, 13(2):378–392.
- Kiptoo, M. K., Lotfy, M. E., Adewuyi, O. B., Conteh, A., Howlader, A. M., and Senjyu, T. (2020). Integrated approach for optimal techno-economic planning for high renewable energy-based isolated microgrid considering cost of energy storage and demand response strategies. *Energy Conversion and Management*, 215:112917.
- Kokash, N. (2005). An introduction to heuristic algorithms. *Department of Informatics and Telecommunications*, pages 1–8.
- Kolassa, S. (2016). Evaluating predictive count data distributions in retail sales forecasting. *International Journal of Forecasting*, 32(3):788–803.
- Koutsandreas, D., Spiliotis, E., Petropoulos, F., and Assimakopoulos, V. (2022). On the selection of forecasting accuracy measures. *Journal of the Operational Research Society*, 73(5):937–954.
- Kraan, O., Chappin, E., Kramer, G. J., and Nikolic, I. (2019). The influence of the energy transition on the significance of key energy metrics. *Renewable and sustainable energy reviews*, 111:215–223.
- Kumar, K. N. and Tseng, K. J. (2016). Impact of demand response management on chargeability of electric vehicles. *Energy*, 111:190–196.
- Lawder, M. T., Viswanathan, V., and Subramanian, V. R. (2015). Balancing autonomy and utilization of solar power and battery storage for demand based microgrids. *Journal of Power Sources*, 279:645–655.
- Li, P., Zhou, K., Lu, X., and Yang, S. (2020). A hybrid deep learning model for short-term pv power forecasting. *Applied Energy*, 259:114216.

- Lund, H. and Kempton, W. (2008). Integration of renewable energy into the transport and electricity sectors through v2g. *Energy policy*, 36(9):3578–3587.
- Luo, X., Zhang, D., and Zhu, X. (2021). Deep learning based forecasting of photovoltaic power generation by incorporating domain knowledge. *Energy*, 225:120240.
- Ma, W., Fang, S., Liu, G., and Zhou, R. (2017). Modeling of district load forecasting for distributed energy system. *Applied Energy*, 204:181–205.
- Mahmoud, A. A., Hafez, A. A., Yousef, A. M., Gaafar, M. A., Orabi, M., and Ali, A. F. (2022). Fault-tolerant modular multilevel converter for a seamless transition between stand-alone and grid-connected microgrid. *IET Power Electronics*.
- Majeed, I. B. and Nwulu, N. I. (2022). Impact of reverse power flow on distributed transformers in a solar-photovoltaic-integrated low-voltage network. *Energies*, 15(23):9238.
- Mohammed, Y., Mustafa, M., Bashir, N., and Ibrahim, I. (2017). Existing and recommended renewable and sustainable energy development in nigeria based on autonomous energy and microgrid technologies. *Renewable and Sustainable Energy Reviews*, 75:820–838.
- Mohandes, B., Acharya, S., El Moursi, M. S., Al-Sumaiti, A. S., Doukas, H., and Sgouridis, S. (2020). Optimal design of an islanded microgrid with load shifting mechanism between electrical and thermal energy storage systems. *IEEE Transactions on Power Systems*, 35(4):2642–2657.
- Mohsenian-Rad, H. et al. (2014). Optimal charging of electric vehicles with uncertain departure times: A closed-form solution. *IEEE Transactions on Smart Grid*, 6(2):940–942.
- Patil, A., Girgaonkar, R., and Musunuri, S. K. (2014). Impacts of increasing photovoltaic penetration on distribution grid—voltage rise case study. In *2014 International Conference on Advances in Green Energy (ICAGE)*, pages 100–105. IEEE.
- Pinson, P., Madsen, H., et al. (2014). Benefits and challenges of electrical demand response: A critical review. *Renewable and Sustainable Energy Reviews*, 39:686–699.
- Qin, J., Jiang, H., Lu, N., Yao, L., and Zhou, C. (2022). Enhancing solar pv output forecast by integrating ground and satellite observations with deep learning. *Renewable and Sustainable Energy Reviews*, 167:112680.
- Qu, J., Qian, Z., and Pei, Y. (2021). Day-ahead hourly photovoltaic power forecasting using attention-based cnn-lstm neural network embedded with multiple relevant and target variables prediction pattern. *Energy*, 232:120996.
- Ramsami, P. and Oree, V. (2015). A hybrid method for forecasting the energy output of photovoltaic systems. *Energy Conversion and Management*, 95:406–413.
- Ratnam, E. L. and Weller, S. R. (2018). Receding horizon optimization-based approaches to managing supply voltages and power flows in a distribution grid with battery storage co-located with solar pv. *Applied Energy*, 210:1017–1026.
- Ratnam, E. L., Weller, S. R., and Kellett, C. M. (2015). An optimization-based approach to scheduling residential battery storage with solar pv: Assessing customer benefit. *Renewable Energy*, 75:123–134.
- Raza, M. Q., Nadarajah, M., and Ekanayake, C. (2016). On recent advances in pv output power forecast. *Solar Energy*, 136:125–144.

- Riffonneau, Y., Bacha, S., Barruel, F., and Ploix, S. (2011). Optimal power flow management for grid connected pv systems with batteries. *IEEE Transactions on sustainable energy*, 2(3):309–320.
- Saini, P. and Gidwani, L. (2022). An investigation for battery energy storage system installation with renewable energy resources in distribution system by considering residential, commercial and industrial load models. *Journal of Energy Storage*, 45:103493.
- Sarmas, E., Spiliotis, E., Marinakis, V., Tzanes, G., Kaldellis, J. K., and Doukas, H. (2022). ML-based energy management of water pumping systems for the application of peak shaving in small-scale islands. *Sustainable Cities and Society*, 82:103873.
- Shao, X., Kim, C.-S., and Sontakke, P. (2020). Accurate deep model for electricity consumption forecasting using multi-channel and multi-scale feature fusion cnn-lstm. *Energies*, 13(8):1881.
- Skaloumpakas, P., Spiliotis, E., Sarmas, E., Lekidis, A., Stravodimos, G., Sarigiannis, D., Makarouni, I., Marinakis, V., and Psarras, J. (2022). A multi-criteria approach for optimizing the placement of electric vehicle charging stations in highways. *Energies*, 15(24):9445.
- Thrän, D., Dotzauer, M., Lenz, V., Liebetrau, J., and Ortwein, A. (2015). Flexible bioenergy supply for balancing fluctuating renewables in the heat and power sector—a review of technologies and concepts. *Energy, Sustainability and Society*, 5(1):1–15.
- Tooryan, F., HassanzadehFard, H., Collins, E. R., Jin, S., and Ramezani, B. (2020). Smart integration of renewable energy resources, electrical, and thermal energy storage in microgrid applications. *Energy*, 212:118716.
- Ullah, S., Haidar, A. M., Hoole, P., Zen, H., and Ahfock, T. (2020). The current state of distributed renewable generation, challenges of interconnection and opportunities for energy conversion based dc microgrids. *Journal of Cleaner Production*, 273:122777.
- Unahalekhaka, P. and Sripakarach, P. (2020). Reduction of reverse power flow using the appropriate size and installation position of a bess for a pv power plant. *IEEE Access*, 8:102897–102906.
- United Nations (2022). Sustainable Development Goals. <https://www.un.org/sustainabledevelopment/energy/>.
- Van Der Kam, M. and van Sark, W. (2015). Smart charging of electric vehicles with photovoltaic power and vehicle-to-grid technology in a microgrid; a case study. *Applied energy*, 152:20–30.
- Venegas, F. G., Petit, M., and Perez, Y. (2021). Active integration of electric vehicles into distribution grids: Barriers and frameworks for flexibility services. *Renewable and Sustainable Energy Reviews*, 145:111060.
- Wang, H., Lei, Z., Zhang, X., Zhou, B., and Peng, J. (2019a). A review of deep learning for renewable energy forecasting. *Energy Conversion and Management*, 198:111799.
- Wang, K., Qi, X., and Liu, H. (2019b). A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network. *Applied Energy*, 251:113315.
- Wang, R., Hsu, S.-C., Zheng, S., Chen, J.-H., and Li, X. I. (2020a). Renewable energy microgrids: Economic evaluation and decision making for government policies to contribute to affordable and clean energy. *Applied Energy*, 274:115287.

- Wang, Z., Hong, T., and Piette, M. A. (2020b). Building thermal load prediction through shallow machine learning and deep learning. *Applied Energy*, 263:114683.
- Wei, H., Zhang, Y., Wang, Y., Hua, W., Jing, R., and Zhou, Y. (2022). Planning integrated energy systems coupling v2g as a flexible storage. *Energy*, 239:122215.
- Widén, J., Wäckelgård, E., Paatero, J., and Lund, P. (2010). Impacts of distributed photovoltaics on network voltages: Stochastic simulations of three swedish low-voltage distribution grids. *Electric power systems research*, 80(12):1562–1571.
- Yang, D., Alessandrini, S., Antonanzas, J., Antonanzas-Torres, F., Badescu, V., Beyer, H. G., Blaga, R., Boland, J., Bright, J. M., Coimbra, C. F., David, M., Ázeddine Frimane, Gueymard, C. A., Hong, T., Kay, M. J., Killinger, S., Kleissl, J., Lauret, P., Lorenz, E., van der Meer, D., Paulescu, M., Perez, R., Perpiñán-Lamigueiro, O., Peters, I. M., Reikard, G., Renné, D., Saint-Drenan, Y.-M., Shuai, Y., Urraca, R., Verbois, H., Vignola, F., Voyant, C., and Zhang, J. (2020). Verification of deterministic solar forecasts. *Solar Energy*, 210:20–37.
- Yang, Y., Bremner, S., Menictas, C., and Kay, M. (2018). Battery energy storage system size determination in renewable energy systems: A review. *Renewable and Sustainable Energy Reviews*, 91:109–125.
- Yildiz, B., Bilbao, J. I., and Sproul, A. B. (2017). A review and analysis of regression and machine learning models on commercial building electricity load forecasting. *Renewable and Sustainable Energy Reviews*, 73:1104–1122.
- Zhou, H. S., Passey, R., Bruce, A., and Sproul, A. B. (2022). Impact of residential battery energy storage systems on the peak reverse power flows from distributed photovoltaic systems. *Journal of Energy Storage*, 52:104817.

Κεφάλαιο 11

Συμπεράσματα - Προοπτικές

Το αντικείμενο της Διδακτορικής Διατριβής ήταν η ανάπτυξη μιας ολοκληρωμένης βιβλιοθήκης μοντέλων μάθησης και τεχνικών βελτιστοποίησης για την υποστήριξη αποφάσεων σε προβλήματα στον ενεργειακό και κτιριακό τομέα, επιδιώκοντας να προσφέρει σύγχρονες λύσεις σε προβλήματα ενεργειακής διαχείρισης και ενεργειακής αποδοτικότητας που απασχολούν την επιστημονική κοινότητα. Η Διατριβή είχε ως στόχο να συμβάλει στην κάλυψη του επιστημονικού “κενού” που εντοπίστηκε σχετικά με την ανάπτυξη σύγχρονων μεθόδων αλγορίθμων για την αντιμετώπιση και επίλυση προβλημάτων ενεργειακής διαχείρισης και ενεργειακής αποδοτικότητας.

Πιο συγκεκριμένα, η Διατριβή επικεντρώθηκε στην ανάπτυξη μοντέλων και αλγορίθμων για προβλήματα που εντάσσονται σε τρεις ευρύτερες κατηγορίες: (α) *Κατανεμημένη Παραγωγή Ενέργειας*, (β) *Ευελιξία Μικροδικτύου* και (γ) *Ενεργειακή Αποδοτικότητα Κτιρίων*. Συνεπώς, στο πλαίσιο της Διατριβής αναπτύχθηκαν και παρουσιάστηκαν μοντέλα TN και μαθηματικής βελτιστοποίησης για εφαρμογές που σχετίζονται με καθεμιά από τις παραπάνω κατηγορίες, μέσα από την εμπειριστατωμένη ανάλυση των βασικών παραμέτρων της κάθε εφαρμογής καθώς και των αλληλεπιδράσεων που υπάρχουν μεταξύ τους.

Το κεφάλαιο αυτό παρουσιάζει τα γενικά συμπεράσματα που απορρέουν από τη Διδακτορική Διατριβή, καθώς και τις προοπτικές που διαφαίνονται για περαιτέρω ερευνητικές δραστηριότητες πάνω στο πρόβλημα που εξετάζεται.

11.1 Συμπεράσματα

Παρακάτω παρουσιάζονται τα γενικά συμπεράσματα που απορρέουν από την ανάλυση που παρατέθηκε στα προηγούμενα κεφάλαια, κατηγοριοποιημένα σύμφωνα με τα τέσσερα επίπεδα συμβολής της Διατριβής:

Ανάπτυξη ολοκληρωμένης βιβλιοθήκης μοντέλων TN και αλγορίθμων βελτιστοποίησης για εφαρμογές στον ενεργειακό τομέα.

Τα βασικότερα συμπεράσματα που μπορούν να εξαχθούν σε αυτό το επίπεδο συμβολής της Διατριβής παρουσιάζονται παρακάτω:

- Το μεθοδολογικό πλαίσιο που παρουσιάστηκε στη Διατριβή αποτελείται από ένα πλήθος μοντέλων TN και αλγορίθμων βελτιστοποίησης και φιλοδοξεί να προσφέρει μια επεκτάσιμη λύση για την αντιμετώπιση συγκεκριμένων προβλημάτων στον τομέα της ενέργειας, για τα οποία έως σήμερα υπάρχουν περιορισμένες λύσεις.
- Τα μοντέλα MM και BM που αναπτύχθηκαν μπορούν να αποτελέσουν ένα ισχυρό εργαλείο στην υποστήριξη της λήψης αποφάσεων για πολύπλοκες και μη τετριμμένες διαδικασίες που σχετίζονται με την ενεργειακή απόδοση, τη διαχείριση της ενέργειας και τη χάραξη πολιτικής σε διαφορετικά επίπεδα.

- Η προτεινόμενη προσέγγιση φιλοδοξεί να προσφέρει προβλεπτικά μοντέλα και αλγόριθμους που επιτρέπουν την εκ των προτέρων εκτίμηση της εξοικονόμησης ενέργειας που προκύπτει από δράσεις ανακαίνισης σε κτίρια καθώς και τη βέλτιστη τοποθέτηση ευέλικτων φορτίων, όπως οι αντλίες νερού και τα EVs, για την εξομάλυνση των αιχμών φορτίου σε αποκεντρωμένα μικροδίκτυα.
- Η χρήση των άφθονων δεδομένων που είναι διαθέσιμα στον ενεργειακό τομέα μπορεί να ενισχύσει την ακρίβεια και την αποτελεσματικότητα των μοντέλων και των αλγορίθμων που αναπτύσσονται, οδηγώντας σε πιο αξιόπιστες και αποδοτικές αποφάσεις. Αυτό ενισχύεται από τα αποτελέσματα που παρουσιάστηκαν στις πειραματικές εφαρμογές που διεξήχθησαν στο πλαίσιο της Διατριβής, οι οποίες επιβεβαιώνουν την επίτευξη πολύ καλών προβλεπτικών επιδόσεων.
- Τα μοντέλα και οι αλγόριθμοι που προκύπτουν ως αποτέλεσμα της παρούσας Διατριβής μπορούν να είναι ωφέλιμα για πλήθος ενδιαφερόμενων φορέων, συμπεριλαμβάνοντας υπεύθυνους χάραξης πολιτικής, ιδιοκτήτες κτιρίων και παρόχους ενεργειακών υπηρεσιών, καθώς παρέχουν πολύτιμες πληροφορίες για την ανάπτυξη αποτελεσματικών στρατηγικών με χρήσιμες προεκτάσεις για την υποστήριξη της λήψης αποφάσεων σε πλήθος προβλημάτων.

Ολοκληρωμένη μεθοδολογία επιλογής μοντέλων, αλγορίθμων και χαρακτηριστικών εισόδου για ενεργειακά προβλήματα διαφορετικών κατηγοριών προβλημάτων (ταξινόμηση, πανινδρόμηση, πρόβλεψη χρονοσειρών και βελτιστοποίηση) και ενοποίηση σε ένα ενιαίο μεθοδολογικό πλαίσιο.

Η παρούσα Διατριβή προτείνει ένα ολοκληρωμένο πλαίσιο για την αντιμετώπιση προβλημάτων MM και βελτιστοποίησης σε διάφορες κατηγορίες. Το πλαίσιο αποτελείται από τέσσερις συνιστώσες που αντιμετωπίζουν συγκεκριμένες προκλήσεις σε κάθε κατηγορία προβλήματος, όπως η συλλογή και προεπεξεργασία δεδομένων, ο σχεδιασμός των χαρακτηριστικών, η επιλογή μοντέλου, η εκπαίδευση και αξιολόγηση και η ανάπτυξη και παρακολούθηση μοντέλων.

Παρέχοντας μια ολοκληρωμένη μεθοδολογία για την επιλογή μοντέλων, αλγορίθμων και χαρακτηριστικών εισόδου, το προτεινόμενο πλαίσιο μπορεί δυνητικά να βελτιώσει την αποτελεσματικότητα και την ακρίβεια της επίλυσης προβλημάτων που σχετίζονται με την ενέργεια. Επιπλέον, η ενοποιημένη προσέγγιση του πλαισίου μπορεί να απλοποιήσει τη διαδικασία επίλυσης προβλημάτων και να επιτρέψει πιο απλές συγκρίσεις μεταξύ διαφορετικών κατηγοριών προβλημάτων. Συνεπώς, το προτεινόμενο πλαίσιο έχει τη δυνατότητα να συμβάλει στον τομέα της MM και βελτιστοποίησης που σχετίζεται με την ενέργεια, παρέχοντας μια συστηματική προσέγγιση που μπορεί να προσαρμοστεί σε διαφορετικούς τομείς προβλημάτων.

Εφαρμογή των προτεινόμενων μεθοδολογιών σε πραγματικά δεδομένα για την επαλήθευση της επιστημονικής ορθότητας τους.

Το τρίτο επίπεδο συμβολής της παρούσας Διδακτορικής Διατριβής επικεντρώνεται στην εφαρμογή των προτεινόμενων μεθοδολογιών σε δεδομένα πραγματικού κόσμου με στόχο την επαλήθευση της επιστημονικής τους εγκυρότητας. Η ανάπτυξη μοντέλων μάθησης και αλγορίθμων βελτιστοποίησης συνδέεται στενά με την επικύρωση και την επαλήθευση των αποτελεσμάτων που παράγονται από αυτά τα μοντέλα σε εφαρμογές που περιλαμβάνουν πραγματικά δεδομένα. Όπως αναφέρθηκε σε προηγούμενες παραγράφους, η ύπαρξη όλων αυτών των δεδομένων έχει οδηγήσει στην ανάγκη για καινοτόμες εφαρμογές. Ως εκ τούτου, όλα τα μοντέλα που αναπτύσσονται στο πλαίσιο της Διδακτορικής Διατριβής εκπαιδεύτηκαν και αξιολογήθηκαν σε πραγματικά δεδομένα προκειμένου να πιστοποιηθεί η ακρίβεια τους και η συνεισφορά τους στη διαδικασία της υποστήριξης λήψης αποφάσεων.

Σε καθένα από τα έξι προηγούμενα κεφάλαια με πειραματικές εφαρμογές που παρουσιάστηκαν παραπάνω, οι εφαρμογές περιλαμβάνουν εκτενή ανάλυση των δεδομένων

που χρησιμοποιήθηκαν κατά τη διαδικασία πειραματικής επαλήθευσης. Παρουσιάστηκαν οπτικοποιήσεις των δεδομένων, πληροφορίες σχετικά με τη στατιστική τους κατανομή, λεπτομέρειες για την προεπεξεργασία τους και ενδιαφέροντα ευρήματα που προέκυψαν κατά την ανάλυσή τους. Επιπλέον, παρόλο που τα μοντέλα αναπτύχθηκαν αρχικά με βάση ένα συγκεκριμένο σύνολο δεδομένων, η τελική μορφή των εφαρμογών που αναπτύχθηκαν σχεδιάστηκε με τέτοιο τρόπο ώστε να επιτρέπει τη χρήση τους και με άλλα σύνολα δεδομένων.

Συμπερασματικά, οι μεθοδολογίες που παρουσιάστηκαν εφαρμόστηκαν με επιτυχία σε πραγματικά δεδομένα και η εκτεταμένη ανάλυση των δεδομένων παρείχε πολύτιμες πληροφορίες για τα χαρακτηριστικά και τη συμπεριφορά τους. Ως συνέπεια, αυτό το επίπεδο συμβολής ενισχύει περαιτέρω την επιστημονική εγκυρότητα και την πρακτική εφαρμογή των προτεινόμενων μεθοδολογιών, δίνοντας τη δυνατότητα για περαιτέρω χρήση τους σε παρόμοια μελλοντικά προβλήματα.

Ανάπτυξη και προσαρμογή καινοτόμων μεθόδων μάθησης σε ενεργειακά προβλήματα: Meta-Learning, Online Learning, Transfer Learning.

Ο ενεργειακός τομέας αντιμετωπίζει πολλές προκλήσεις όσον αφορά τη διαχείριση των ενεργειακών πόρων, την εξοικονόμηση ενέργειας και την ενσωμάτωση των ΑΠΕ. Τις τελευταίες δεκαετίες έχουν αναπτυχθεί μοντέλα MM και BM για την πρόβλεψη της ζήτησης ενέργειας και της παραγωγής ΑΠΕ, αλλά οι παραδοσιακές προσεγγίσεις μάθησης offline μπορεί να οδηγήσουν σε μειωμένη ακρίβεια των μοντέλων μετά την αρχική τους ανάπτυξη. Η online μάθηση, από την άλλη πλευρά, παρέχει μια δυναμική προσέγγιση της μάθησης που είναι κατάλληλη για το συνεχώς μεταβαλλόμενο περιβάλλον του ενεργειακού τομέα. Σε μια πρόσφατη μελέτη, προτάθηκε ένα πλαίσιο online μάθησης για προβλήματα πρόβλεψης χρονοσειρών που σχετίζονται με την ενέργεια. Τα αποτελέσματα έδειξαν ότι τα μοντέλα online μάθησης υπερτερούν των μοντέλων offline μάθησης όσον αφορά το μέσο απόλυτο σφάλμα, γεγονός που είναι επωφελές για την πρόβλεψη της ενεργειακής ζήτησης και των ΑΠΕ.

Μια άλλη πρόκληση στην ενεργειακή πρόβλεψη είναι η έλλειψη επαρκών δεδομένων, ιδίως για πρόσφατα εγκατεστημένους ηλιακούς σταθμούς ή για εκείνους που δεν διαθέτουν έξυπνους μετρητές. Σε τέτοιες περιπτώσεις, η μεταφορά μάθησης μπορεί να είναι ένα χρήσιμο εργαλείο για τη μεταφορά γνώσης από τον τομέα προέλευσης σε διαφορετικούς τομείς-στόχους για την επίλυση σχετικών προβλημάτων. Η προσέγγιση της μεταφοράς μάθησης χρησιμοποιήθηκε στο πλαίσιο της Διατριβής για την πρόβλεψη της παραγωγής Φ/B εγκαταστάσεων με τη χρήση του μοντέλου LSTM. Τα αποτελέσματα έδειξαν ότι τα μοντέλα που είχαν εκπαιδευτεί μέσω μεταφοράς μάθησης υπερτερούν σημαντικά έναντι του συμβατικού μοντέλου και επιτυγχάνουν βελτιωμένη ακρίβεια, ιδίως με περιορισμένα δεδομένα εκπαίδευσης. Η προσέγγιση αυτή άνοιξε νέους δρόμους στην πρόβλεψη της παραγωγής ενέργειας για πρόσφατα εγκατεστημένα Φ/B συστήματα, καθιστώντας τη μεταφορά μάθησης ένα αξιόπιστο εργαλείο για τους αυτοπαραγωγούς στην εξισορρόπηση της ενέργειας και τη διαχείριση της απόκρισης στη ζήτηση.

Τέλος, η μετα-μάθηση μπορεί να χρησιμοποιηθεί αποδοτικά σε πλήθος προβλημάτων όπως το πρόβλημα της χρηματοδότησης δράσεων ενεργειακής απόδοσης, καθώς και το πρόβλημα της πρόβλεψης Φ/B παραγωγής. Παρουσιάστηκε πως μπορούν να αναπτυχθούν διάφορα μοντέλα μετα-μάθησης τα οποία συνδυάζουν μεθόδους ταξινόμησης ή παλινδρόμησης για τη βελτίωση της συνολικής απόδοσης. Τα αποτελέσματα στις πειραματικές εφαρμογές των προηγούμενων Κεφαλαίων οδηγούν στο συμπέρασμα ότι ο μετα-μαθητής υπερείχε έναντι όλων των βασικών ταξινομητών στα προβλήματα που δοκιμάστηκε, στρώνοντας το δρόμο για τη χρήση της μετα-μάθησης σε πλήθος άλλων προβλημάτων και εφαρμογών.

11.2 Προοπτικές

Με την ολοκλήρωση της Διδακτορικής Διατριβής, προέκυψαν μια σειρά από σκέψεις και προτάσεις προοπτικής για περαιτέρω ερευνητικές δραστηριότητες πάνω στο συγκεκριμένο

γνωστικό πεδίο, οι οποίες παρατίθενται παρακάτω.

Επέκταση της Βιβλιοθήκης TN και Εμπλουτισμός με Μοντέλα για Διαφορετικά Προβλήματα

Καθώς το ενεργειακό περιβάλλον βαίνει προς την ψηφιοποίηση του, υπάρχει αυξανόμενη ανάγκη να βρεθούν αποτελεσματικοί και οικονομικά αποδοτικοί τρόποι για την αντιμετώπιση των προβλημάτων που σχετίζονται με την ενέργεια. Σε αυτό το πλαίσιο, η χρήση της TN έχει αποδειχθεί ένα ισχυρό εργαλείο για την αντιμετώπιση ορισμένων από αυτά τα προβλήματα. Συνεπώς, μια ενδιαφέρουσα μελλοντική προέκταση της παρούσας Διατριβής περιλαμβάνει την επέκταση της βιβλιοθήκης μοντέλων και αλγορίθμων ώστε να συμπεριλάβει μοντέλα που μπορούν να αντιμετωπίσουν και άλλα προβλήματα που σχετίζονται με τους τρεις πυλώνες ενεργειακών προβλημάτων που παρουσιάστηκαν στο Κεφάλαιο 3.

Ένας τέτοιος τομέας είναι η πρόβλεψη της παραγωγής διαφόρων ΑΠΕ εκτός από τα Φ/Β, όπως η αιολική, η γεωθερμική, η υδροηλεκτρική κ.λπ. (Wang et al., 2019; Zheng et al., 2023) Για παράδειγμα, τα μοντέλα MM μπορούν να χρησιμοποιηθούν για την ανάλυση ιστορικών δεδομένων σχετικά με την ταχύτητα του ανέμου, τη θερμοκρασία και άλλους παράγοντες που επηρεάζουν την παραγωγή ενέργειας και να προβλέψουν μελλοντικές τάσεις για την παραγωγή από διάφορες ΑΠΕ. Αυτά τα μοντέλα μπορούν στη συνέχεια να χρησιμοποιηθούν για τη βελτιστοποίηση της χρήσης των διαφόρων ΑΠΕ (Sweeney et al., 2020).

Ένας άλλος τομέας που θα μπορούσε να επωφεληθεί από την TN είναι η ομαδοποίηση των καταναλωτών για το σχεδιασμό καλύτερων συστημάτων απόκρισης στη ζήτηση (Okereke et al., 2023). Τα προγράμματα απόκρισης ζήτησης έχουν σχεδιαστεί για να δώσουν κίνητρα στους καταναλωτές να μετατοπίσουν τη χρήση της ενέργειάς τους σε ώρες μη αιχμής, μειώνοντας την επιβάρυνση του ενεργειακού δικτύου κατά τις περιόδους αιχμής της ζήτησης. Η TN μπορεί να χρησιμοποιηθεί για την ανάπτυξη μοντέλων που μπορούν να ομαδοποιήσουν τους καταναλωτές με βάση τα πρότυπα και τις προτιμήσεις τους όσον αφορά τη χρήση ενέργειας και να σχεδιάσουν εξατομικευμένα προγράμματα απόκρισης στη ζήτηση για κάθε ομάδα (Priolkar and Sreeraj, 2023).

Τέλος, ένας τρίτος τομέας που θα μπορούσε να επωφεληθεί από την TN είναι η πρόβλεψη των τιμών ενέργειας. Η TN μπορεί να χρησιμοποιηθεί για την ανάπτυξη μοντέλων που μπορούν να προβλέψουν τις τιμές της ενέργειας με βάση παράγοντες η ζήτηση και η προσφορά ενέργειας και τα γεωπολιτικά γεγονότα (Li and Song, 2023; Grothe et al., 2023). Για παράδειγμα, τα μοντέλα MM μπορούν να χρησιμοποιηθούν για την ανάλυση ιστορικών δεδομένων σχετικά με τις τιμές της ενέργειας και τον εντοπισμό μοτίβων που υποδεικνύουν τον αντίκτυπο των διαφόρων παραγόντων στις τιμές της ενέργειας.

Μελλοντικές Εφαρμογές στον Τομέα της Μεταφοράς Μάθησης

Όπως παρουσιάσαμε και στο κεφάλαιο 6, η μεταφορά μάθησης είναι ένας πολλά υποσχόμενος τομέας έρευνας που έχει δείξει μεγάλες δυνατότητες σε διάφορους τομείς, συμπεριλαμβανομένης της πρόβλεψης Φ/Β, όπου μπορεί να επιτρέψει την ακριβή πρόβλεψη της παραγωγής Φ/Β εγκαταστάσεων με περιορισμένα δεδομένα εκπαίδευσης. Έτσι, καθίσταται ένα πολύτιμο εργαλείο για διάφορα ενεργειακά θέματα όπως η εξισορρόπηση της προσφοράς και της ζήτησης, η ενεργειακή αποδοτικότητα και ο προγραμματισμός της λειτουργίας των δικτύων διανομής στο πλαίσιο των έξυπνων πόλεων και των ενεργειακών κοινοτήτων (Panjapornpon et al., 2023).

Μια πιθανή μελλοντική κατεύθυνση της έρευνας για τη μεταφορά μάθησης είναι η διερεύνηση της εφαρμογής της σε άλλους τομείς, όπως η πρόβλεψη της αιολικής ενέργειας και η πρόβλεψη της κατανάλωσης των κτιρίων. Αφενός, η πρόβλεψη της αιολικής ενέργειας είναι πολύ σημαντική στον τομέα των ΑΠΕ και η μεταφορά μάθησης μπορεί δυνητικά να βελτιώσει την ακρίβεια των μοντέλων πρόβλεψης της ειδικά σε περιπτώσεις που δεν υπάρχει πληθώρα διαθέσιμων δεδομένων. Αφετέρου, η πρόβλεψη της κτιριακής κατανάλωσης είναι ένας ακόμη τομέας όπου θα μπορούσε να αξιολογηθεί η μεταφορά μάθησης για την παροχή προβλέψεων

σε νεοσύστατα κτίρια, αξιοποιώντας δεδομένα από παρόμοια κτίρια ή τομείς.

Μια άλλη μελλοντική κατεύθυνση για την έρευνα σε αυτό τον τομέα είναι η διερεύνηση νέων τεχνικών μεταφοράς μάθησης, όπως η τεχνική του Domain Adaptation (Yu et al., 2023). Η τεχνική αυτή είναι μια υποκατηγορία της μεταφοράς μάθησης που αποσκοπεί στην προσαρμογή ενός μοντέλου που έχει εκπαιδευτεί σε κάποιο συγκεκριμένο πρόβλημα με στόχο να αξιοποιηθεί σε ένα παρόμοιο πρόβλημα, το οποίο μπορεί να έχει διαφορετικές κατανομές ή χαρακτηριστικά δεδομένων. Το Domain Adaptation μπορεί να βρει πιθανές εφαρμογές στην πρόβλεψη ενέργειας, όπου οι κατανομές δεδομένων μπορεί να αλλάξουν με την πάροδο του χρόνου λόγω διαφόρων παραγόντων, όπως οι διαφορετικές καιρικές συνθήκες, η κατάσταση του εξοπλισμού και οι περιβαλλοντικές συνθήκες. Με την προσαρμογή των μοντέλων που εκπαιδεύονται σε ιστορικά δεδομένα σε νέους τομείς, η τεχνική του Domain Adaptation μπορεί να επιτρέψει ακριβείς προβλέψεις της κατανάλωσης ενέργειας και της παραγωγής ΑΠΕ ακόμη και σε μεταβαλλόμενα περιβάλλοντα.

Προστασία του Απορρήτου των Δεδομένων μέσω Αλγορίθμων Κατανεμημένης Μάθησης

Τα αποτελέσματα που προέκυψαν στο πλαίσιο αυτής της Διατριβής δείχνουν ότι τα μοντέλα TN που σχετίζονται με την ενέργεια μπορούν να αναπτυχθούν με τη χρήση διαφόρων τεχνικών MM παρουσιάζοντας πολύ μεγάλη ακρίβεια. Ωστόσο, η προστασία της ιδιωτικότητας και η ασφάλεια των ενεργειακών δεδομένων είναι πολύ μεγάλης σημασίας, ιδίως όταν πρόκειται για ευαίσθητα δεδομένα. Η τεχνική του *Federated Learning* είναι μια πολλά υποσχόμενη τεχνική που αντιμετωπίζει αυτές τις προκλήσεις, επιτρέποντας την εκπαίδευση των μοντέλων πιο κοντά στις πηγές δεδομένων (*Edge Computing*), χωρίς τη διαβίβαση ευαίσθητων δεδομένων σε μια κεντρική τοποθεσία (Tang et al., 2023).

Οι μελλοντικές εργασίες στον τομέα αυτό θα μπορούσαν να διερευνήσουν τις δυνατότητες του Federated Learning στην ανάπτυξη μοντέλων που σχετίζονται με την ενέργεια όπως η πρόβλεψη της ζήτησης ενέργειας, η πρόβλεψη της παραγωγής ΑΠΕ και η πρόβλεψη της κατανάλωσης ενέργειας σε κτίρια. Το Federated Learning μπορεί να βελτιώσει την ακρίβεια των μοντέλων με την ενσωμάτωση δεδομένων από πολλαπλές πηγές και την ενίσχυση της ιδιωτικότητας και της προστασίας των δεδομένων (Otoum et al., 2022).

Τέλος, η ανάπτυξη τέτοιων τεχνικών και αλγορίθμων Federated Learning που αντιμετωπίζουν τις συνεχώς αυξανόμενες προκλήσεις των ενεργειακών δεδομένων μπορεί να συμβάλει αποφασιστικά στην καλλιέργεια της εμπιστοσύνης μεταξύ των διαφόρων ενδιαφερόμενων μερών, ώστε να μοιράζονται με μεγαλύτερη προθυμία τα δεδομένα. Ένα τέτοιο παράδειγμα θα μπορούσε να είναι η ανάπτυξη αλγορίθμων Federated Learning με διαφορετικά επίπεδα ιδιωτικότητας, παρέχοντας μια πιο ολιστική προσέγγιση για το συγκεκριμένο πρόβλημα και ικανοποιώντας ανάγκες διαφορετικών χρηστών.

Βιβλιογραφία

- Grothe, O., Kächele, F., and Krüger, F. (2023). From point forecasts to multivariate probabilistic forecasts: The schaaake shuffle for day-ahead electricity price forecasting. *Energy Economics*, 120:106602.
- Li, R. and Song, X. (2023). A multi-scale model with feature recognition for the use of energy futures price forecasting. *Expert Systems with Applications*, 211:118622.
- Okereke, G. E., Bali, M. C., Okwueze, C. N., Ukekwe, E. C., Echezona, S. C., and Ugwu, C. I. (2023). K-means clustering of electricity consumers using time-domain features from smart meter data. *Journal of Electrical Systems and Information Technology*, 10(1):1–18.
- Otoutoum, S., Al Ridhawi, I., and Mouftah, H. (2022). A federated learning and blockchain-enabled sustainable energy-trade at the edge: A framework for industry 4.0. *IEEE Internet of Things Journal*.
- Panjarornpon, C., Bardeeniz, S., Hussain, M. A., and Chomchai, P. (2023). Explainable deep transfer learning for energy efficiency prediction based on uncertainty detection and identification. *Energy and AI*, 12:100224.
- Priolkar, J. and Sreeraj, E. (2023). Analysis of price based demand response program using load clustering approach. *IETE Journal of Research*, pages 1–14.
- Sweeney, C., Bessa, R. J., Browell, J., and Pinson, P. (2020). The future of forecasting for renewable energy. *Wiley Interdisciplinary Reviews: Energy and Environment*, 9(2):e365.
- Tang, L., Xie, H., Wang, X., and Bie, Z. (2023). Privacy-preserving knowledge sharing for few-shot building energy prediction: A federated learning approach. *Applied Energy*, 337:120860.
- Wang, H., Lei, Z., Zhang, X., Zhou, B., and Peng, J. (2019). A review of deep learning for renewable energy forecasting. *Energy Conversion and Management*, 198:111799.
- Yu, Z., Li, J., Du, Z., Zhu, L., and Shen, H. T. (2023). A comprehensive survey on source-free domain adaptation. *arXiv preprint arXiv:2302.11803*.
- Zheng, J., Du, J., Wang, B., Klemeš, J. J., Liao, Q., and Liang, Y. (2023). A hybrid framework for forecasting power generation of multiple renewable energy sources. *Renewable and Sustainable Energy Reviews*, 172:113046.

Λίστα Δημοσιεύσεων

Δημοσιευμένες Εργασίες σε Επιστημονικά Περιοδικά

- **Sarmas E.**, Dimitropoulos N., Marinakis V., Mylona Z., & Doukas H. (2022). Transfer learning strategies for solar power forecasting under data scarcity. *Scientific Reports*, 12(1), 14643.
- **Sarmas E.**, Spiliotis E., Stamatopoulos, E., Marinakis, V., & Doukas, H. (2023). Short-term photovoltaic power forecasting using meta-learning and numerical weather prediction independent Long Short-Term Memory models. *Renewable Energy*, 118997.
- **Sarmas E.**, Spiliotis E., Marinakis V., Tzanes G., Kaldellis J. K., & Doukas H. (2022). ML-based energy management of water pumping systems for the application of peak shaving in small-scale islands. *Sustainable Cities and Society*, 82, 103873.
- **Sarmas E.**, Spiliotis E., Marinakis V., Koutselis T., & Doukas H. (2022). A meta-learning classification model for supporting decisions on energy efficiency investments. *Energy and Buildings*, 258, 111836.
- **Sarmas E.**, Marinakis V., & Doukas H. (2022). A data-driven multicriteria decision making tool for assessing investments in energy efficiency. *Operational Research*, 22(5), 5597-5616.
- **Sarmas E.**, Strompolas S., Marinakis V., Santori F., Bucarelli M. A., & Doukas H. (2022). An Incremental Learning Framework for Photovoltaic Production and Load Forecasting in Energy Microgrids. *Electronics*, 11(23), 3962.
- **Sarmas E.**, Spiliotis E., Dimitropoulos N., Marinakis V., & Doukas H. (2023). Estimating the Energy Savings of Energy Efficiency Actions with Ensemble Machine Learning Models. *Applied Sciences*, 13(4), 2749.
- **Sarmas E.**, Kleideri, M., Zučika, A., Marinakis, V., & Doukas, H. (2023). Improving energy performance of buildings: Dataset of implemented energy efficiency renovation projects in Latvia. *Data in Brief*, 48, 109225.
- **Sarmas E.**, Skaloumpakas, P., Kafetzis, N., Spiliotis, V., Lekidis, A., Marinakis, V., & Doukas, H. (2023). Optimal site selection of electric vehicle charging stations exploiting multi-criteria decision analysis: The case of Greek municipalities. *Technical Annals*, 1(2).

- Tsolkas, C., Spiliotis, E., **Sarmas E.**, Marinakis, V., & Doukas, H. (2023). Dynamic energy management with thermal comfort forecasting. *Building and Environment*, 237, 110341.
- Skaloumpakas P., Spiliotis E., **Sarmas E.**, Lekidis A., Stravodimos G., Sari-
giannis D., Makarouni I., Marinakis V., & Psarras, J. (2022). A Multi-Criteria
Approach for Optimizing the Placement of Electric Vehicle Charging Stations
in Highways. *Energies*, 15(24), 9445.
- Xidonas P., Doukas H., & **Sarmas E.** (2021). A python-based multicriteria
portfolio selection DSS. *RAIRO-Operations Research*, 55, S3009-S3034.
- Mexis F. D., Papapostolou A., Karakosta C., **Sarmas E.**, Koutsandreas D.,
& Doukas H. (2021). Leveraging energy efficiency investments: An innovative
web-based benchmarking tool. *Adv. Sci. Technol. Eng. Syst. J*, 6(5), 237-
248.

Δημοσιευμένες Εργασίες σε Επιστημονικά Συνέδρια

- **Sarmas E.**, Dimitropoulos N., Marinakis V., Zucika A., & Doukas H. (2022).
Monitoring the impact of Energy Conservation Measures with Artificial Neural
Networks. In 2022 ECEEE Summer Study.
- **Sarmas E.**, Dimitropoulos N., Strompolas S., Mylona Z., Marinakis V., Gi-
annadakis A., Romaios A. & Doukas, H. (2022, July). A web-based Building
Automation and Control Service. In 2022 13th International Conference on
Information, Intelligence, Systems and Applications (IISA). IEEE.
- **Sarmas E.**, Koutsellis T., Ververidis C., Papapolyzos T., Choumas S., Bit-
sikis A., & Doukas H. (2022, July). Comparison of Machine Learning Clas-
sifiers for Exchange Rate Trend Forecasting. In 2022 13th International Con-
ference on Information, Intelligence, Systems and Applications (IISA). IEEE.
- Arsenopoulos A., **Sarmas E.**, Stavrakaki A., Giannouli I., & Psarras J. (2021,
July). A data-driven decision support tool at the service of energy suppliers
and utilities for tackling energy poverty: A case study in greece. In 2021 12th
International Conference on Information, Intelligence, Systems and Applica-
tions (IISA). IEEE.
- Papapostolou A., Mexis F. D., **Sarmas E.**, Karakosta C., & Psarras J. (2020,
July). Web-based application for screening energy efficiency investments: A
meda approach. In 2020 11th International Conference on Information, Intel-
ligence, Systems and Applications (IISA). IEEE.
- Testasecca, T., Lazzaro, M., **Sarmas E.**, & Stamatopoulos, S. (2023, May).
Recent advances on data-driven services for smart energy systems optimiza-
tion and pro-active management. In 2023 IEEE International Workshop on
Metrology for Living Environment (MetroLivEnv) (pp. 146-151). IEEE.

- Skaloumpakas, P., **Sarmas E.**, Mylona, Z., Cavadenti, A., Santori, F., & Marinakis, V. (2023, May). Predicting Thermal Comfort in Buildings With Machine Learning and Occupant Feedback. In 2023 IEEE International Workshop on Metrology for Living Environment (MetroLivEnv) (pp. 34-39). IEEE.
- Dimitropoulos, N., **Sarmas E.**, Lampkowski, M., & Marinakis, V. (2023, July). A Quantitative Methodology to Support Local Governments in Climate Change Adaptation and Mitigation Actions. In International Symposium on Distributed Computing and Artificial Intelligence (pp. 99-108). Cham: Springer Nature Switzerland.
- Touloumis, K., Kapsalis, P., **Sarmas E.**, Stamatopoulos, S., Marinakis, V., & Doukas. (2023) A data acquisition framework for building energy management.
- Pelekis, S., **Sarmas E.**, Georgiadou, A., Karakolis, E., Ntanos, C., Dimitropoulos, N., ... & Doukas, H. TWINP2G: A digital twin architecture for optimal power-to-gas planning.