



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΗΣ ΙΣΧΥΟΣ

**ΥΒΡΙΔΙΚΟ ΜΟΝΤΕΛΟ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΓΙΑ
ΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ ΠΑΡΑΓΩΓΗΣ
ΦΩΤΟΒΟΛΤΑΪΚΩΝ ΚΑΙ ΕΦΑΡΜΟΓΗ ΣΤΗΝ ΑΓΟΡΑ
ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Νικόλαος Ι. Ζωίδης

Επίβλεψη : Παύλος Σ. Γεωργιλάκης, Καθηγητής Ε.Μ.Π.

Επόπτευση : Μάρκος Κουσουνάδης Κνούσεν, Υποψήφιος Διδάκτορας Ε.Μ.Π.

Αθήνα, Οκτώβριος 2023



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΗΣ ΙΣΧΥΟΣ

**ΥΒΡΙΔΙΚΟ ΜΟΝΤΕΛΟ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΓΙΑ
ΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ ΠΑΡΑΓΩΓΗΣ
ΦΩΤΟΒΟΛΤΑΪΚΩΝ ΚΑΙ ΕΦΑΡΜΟΓΗ ΣΤΗΝ ΑΓΟΡΑ
ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Νικόλαος Ι. Ζωίδης

Επίβλεψη : Παύλος Σ. Γεωργιλιάκης, Καθηγητής Ε.Μ.Π

Επόπτευση : Μάρκος Κουσούνάδης Κνούσεν, Υποψήφιος Διδάκτορας Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 16^η Οκτωβρίου 2023

.....
Παύλος Γεωργιλιάκης
Καθηγητής Ε.Μ.Π.

.....
Γεώργιος Κορρές
Καθηγητής Ε.Μ.Π.

.....
Ιωάννης Γκόνος
Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2023

.....

Νικόλαος Ι. Ζωίδης

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

Copyright © Νικόλαος Ζωίδης, 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.

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.

ΠΕΡΙΛΗΨΗ

Σκοπός της παρούσας διπλωματικής εργασίας είναι η βραχυπρόθεσμη πρόβλεψη φωτοβολταϊκής παραγωγής, μέσω της ανάπτυξης ενός υβριδικού μοντέλου βαθιάς μάθησης, και η εξέτασή του σε ένα πραγματικό πρόβλημα της αγοράς ηλεκτρικής ενέργειας. Το προτεινόμενο μοντέλο πρόβλεψης αποτελείται από μέθοδο αποσύνθεσης πακέτου κυματιδίων και αναδρομικά νευρωνικά δίκτυα μακράς βραχύχρονης μνήμης, διαθέτοντας χρονικό ορίζοντα πρόβλεψης μίας ώρας.

Η εκπαίδευση και η αξιολόγηση του υβριδικού μοντέλου πραγματοποιούνται με ετήσια πραγματικά ιστορικά δεδομένα ενός φωτοβολταϊκού σταθμού στη Ροδόπη και διενεργούνται με τη μέθοδο επιτηρούμενης εκπαίδευσης. Στόχος του αναπτυσσόμενου μοντέλου πρόβλεψης αποτελεί η προσέγγιση της δοσμένης πραγματικής παραγόμενης ισχύος μέσω συσχέτισής της με μετρούμενα μετεωρολογικά μεγέθη.

Η απόδοση του προτεινόμενου υβριδικού μοντέλου συγκρίνεται με αυτή άλλων κατασκευασμένων μοντέλων μέσω υπολογισμού κατάλληλων μετρητικών σφάλματος. Η ανάπτυξη του κώδικα για τη δημιουργία των μοντέλων πρόβλεψης φωτοβολταϊκής παραγωγής της παρούσας διπλωματικής εργασίας υλοποιείται στη γλώσσα προγραμματισμού Python. Για την ενδελεχή αξιολόγηση του μοντέλου πρόβλεψης διενεργείται πλήρης εποχική και μετεωρολογική ανάλυση, μέσω των οποίων διασαφηνίζονται τα ποιοτικά χαρακτηριστικά της διαδικασίας πρόβλεψης.

Η παρούσα διπλωματική εργασία καινοτομεί με την εφαρμογή του προτεινόμενου υβριδικού μοντέλου σε μία ρεαλιστική διαδικασία πρόβλεψης στην αγορά ηλεκτρικής ενέργειας. Τα παραγόμενα αποτελέσματα υπόκεινται σε μηνιαία αξιολόγηση υπό το ρυθμιστικό πλαίσιο του μηχανισμού βέλτιστης ακρίβειας πρόβλεψης, μέσω της οποίας ποσοτικοποιείται η απόδοσή τους.

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ

Πρόβλεψη φωτοβολταϊκής παραγωγής, τεχνητά νευρωνικά δίκτυα, δίκτυα μακράς βραχύχρονης μνήμης, αποσύνθεση πακέτου κυματιδίων, αγορά ηλεκτρικής ενέργειας, επίδραση συσσώρευσης

ABSTRACT

The purpose of this diploma thesis is the short-term forecasting of photovoltaic power production, through the development of a hybrid deep learning model, and its testing on a real-world electricity market problem. The proposed forecasting model consists of a wavelet packet decomposition method and recurrent long short-term memory neural networks, having a one-hour prediction horizon.

Training and evaluation of the hybrid model are carried out with annual real historical data of a photovoltaic plant in Rhodope and are performed using the supervised training method. The aim of the developed hybrid model is to approximate the given actual generated power by correlating it with measured meteorological variables.

The performance of the proposed hybrid model is compared with that of other constructed models by calculating appropriate error metrics. The code development to create the solar power generation forecasting models of this thesis is implemented in the Python programming language. For the thorough evaluation of the forecasting model, a full seasonal and meteorological analysis is carried out, through which the qualitative characteristics of the forecasting process are clarified.

This diploma thesis innovates by applying the proposed hybrid model to a realistic forecasting process in the electricity market. Generated results are subjected to a monthly evaluation under the regulatory framework of the optimal forecasting accuracy mechanism, through which their performance is quantified.

KEY WORDS

Photovoltaic power forecasting, artificial neural networks, long short-term memory networks, wavelet packet decomposition, energy market, aggregation effect

ΕΥΧΑΡΙΣΤΙΕΣ

Η παρούσα διπλωματική εργασία εκπονήθηκε κατά το ακαδημαϊκό έτος 2022–2023 υπό την επίβλεψη του κ. Παύλου Γεωργιάκη, καθηγητή της σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Ε.Μ.Π. στον οποίο οφείλω ιδιαίτερες ευχαριστίες για την ανάθεσή της, δίνοντάς μου την ευκαιρία να ασχοληθώ με ένα τόσο ενδιαφέρον και σύγχρονο θέμα. Επίσης, θα ήθελα να ευχαριστήσω δεόντως τον υποψήφιο διδάκτορα Μάρκο Κουσουνάδη - Κνούσεν για την καθοδήγηση και τις πολύτιμες συμβουλές που μου παρείχε σε όλη τη διάρκεια της εργασίας, καθώς και για το ότι ήταν πάντα διαθέσιμος και υποστηρικτικός.

Θα ήθελα να ευχαριστήσω θερμά όλους τους, δυστυχώς πρώην, συναδέλφους της Motor Oil Renewable Energy, οι οποίοι κατά την πρακτική μου άσκηση με βοήθησαν ποικιλοτρόπως, τόσο σε γνωστικό όσο και σε προσωπικό επίπεδο. Ιδιαίτερες ευχαριστίες οφείλω στη Σοφία Χατζηθεοδωρίδη για την ανυπολόγιστη αξίας βοήθειά της σε οποιοδήποτε σημείο χρειάστηκε και στον Δημήτρη Ζάρρα για την καθοριστικής σημασίας προσφορά των δεδομένων της παρούσας διπλωματικής εργασίας.

Τέλος, θα ήθελα να ευχαριστήσω την οικογένειά μου για τη στήριξή τους σε όλη τη διάρκεια των σπουδών μου στο Ε.Μ.Π. και τη Δηρένα, χωρίς τη συμπαράσταση, την κατανόηση και τη βοήθεια της οποίας, δεν θα είχα καταφέρει ό,τι έχω μέχρι σήμερα.

ΠΕΡΙΕΧΟΜΕΝΑ

| | |
|---|-----------|
| ΚΕΦΑΛΑΙΟ 1: ΕΙΣΑΓΩΓΗ | 1 |
| 1.1 Αντικείμενο εργασίας | 1 |
| 1.2 Ανασκόπηση βιβλιογραφίας | 2 |
| 1.3 Κύριες συνεισφορές | 4 |
| 1.4 Δομή διπλωματικής εργασίας | 5 |
| | |
| ΚΕΦΑΛΑΙΟ 2: ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ | 7 |
| 2.1 Γενικά | 7 |
| 2.2 Τρόπος λειτουργίας φωτοβολταϊκού σταθμού | 7 |
| 2.3 Αξία πρόβλεψης φωτοβολταϊκής παραγωγής | 8 |
| 2.4 Παράγοντες που επηρεάζουν τη φωτοβολταϊκή παραγωγή | 10 |
| 2.5 Μέθοδοι πρόβλεψης φωτοβολταϊκής παραγωγής | 11 |
| 2.5.1 Φυσικές μέθοδοι | 11 |
| 2.5.2 Στατιστικές μέθοδοι | 12 |
| 2.5.3 Μοντέλα μηχανικής μάθησης | 12 |
| 2.6 Χρονική ταξινόμηση μοντέλων πρόβλεψης | 13 |
| 2.6.1 Βραχυπρόθεσμη πρόβλεψη | 13 |
| 2.6.2 Μεσοπρόθεσμη πρόβλεψη | 14 |
| 2.6.3 Μακροπρόθεσμη πρόβλεψη | 14 |
| | |
| ΚΕΦΑΛΑΙΟ 3: ΒΑΘΙΑ ΜΑΘΗΣΗ, ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΔΙΚΤΥΑ LSTM | 15 |
| 3.1 Γενικά | 15 |
| 3.2 Νευρωνικά δίκτυα | 16 |
| 3.3 Βαθιά Μάθηση | 21 |
| 3.4 Δίκτυα LSTM | 25 |
| 3.4.1 Τρόπος λειτουργίας LSTM | 25 |
| 3.4.2 Πλεονεκτήματα LSTM | 28 |
| 3.5 Υβριδικά μοντέλα | 30 |
| | |
| ΚΕΦΑΛΑΙΟ 4: ΑΝΑΛΥΣΗ ΚΑΙ ΠΡΟΕΠΕΞΕΡΓΑΣΙΑ ΔΕΔΟΜΕΝΩΝ | 33 |
| 4.1 Γενικά | 33 |
| 4.2 Δεδομένα εισόδου | 33 |

| | | |
|--|--|-----------|
| 4.2.1 | Προέλευση δεδομένων | 33 |
| 4.2.2 | Επεξεργασία δεδομένων | 34 |
| 4.3 | Τεχνικές επεξεργασίας δεδομένων | 35 |
| 4.4 | Αποσύνθεση χρονοσειράς | 36 |
| ΚΕΦΑΛΑΙΟ 5: ΥΒΡΙΔΙΚΟ ΜΟΝΤΕΛΟ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ | | 39 |
| 5.1 | Γενικά | 39 |
| 5.2 | Μεθοδολογία υβριδικού μοντέλου | 39 |
| 5.3 | Βελτιστοποίηση παραμέτρων υβριδικού μοντέλου | 45 |
| 5.3.1 | Υπολογιζόμενα σφάλματα | 46 |
| 5.3.2 | Μεθοδολογία βελτιστοποίησης | 46 |
| 5.3.3 | Αποτελέσματα βελτιστοποίησης | 48 |
| 5.4 | Αριθμητική αναπαράσταση ώρας στα δεδομένα εισόδου | 49 |
| 5.4.1 | Μεθοδολογία αριθμητικής αναπαράστασης | 50 |
| 5.4.2 | Αποτελέσματα βελτιστοποίησης | 51 |
| ΚΕΦΑΛΑΙΟ 6: ΑΠΟΤΕΛΕΣΜΑΤΑ | | 53 |
| 6.1 | Ανάλυση υπολογιζόμενων σφαλμάτων | 53 |
| 6.2 | Αποτελέσματα αρχικών μοντέλων, υβριδικού και βελτιωμένου υβριδικού | 55 |
| 6.3 | Αποτελέσματα εποχικής ανάλυσης | 57 |
| 6.4 | Αποτελέσματα μετεωρολογικής ανάλυσης | 66 |
| 6.5 | Ταχύτητα εκπαίδευσης αρχικών μοντέλων, υβριδικού και βελτιωμένου υβριδικού | 74 |
| ΚΕΦΑΛΑΙΟ 7: ΕΦΑΡΜΟΓΗ ΥΒΡΙΔΙΚΟΥ ΜΟΝΤΕΛΟΥ ΣΤΗΝ ΑΓΟΡΑ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ | | 75 |
| 7.1 | Γενικά | 75 |
| 7.2 | Ρυθμιστικό πλαίσιο λειτουργίας αγοράς ηλεκτρικής ενέργειας | 76 |
| 7.3 | Τρόπος υπολογισμού χρεώσεων | 77 |
| 7.4 | Υπολογισμός μηνιαίας απόδοσης | 81 |
| 7.5 | Ενσωμάτωση 2 ^{ου} φωτοβολταϊκού σταθμού | 85 |
| 7.6 | Υπολογισμός μηνιαίας απόδοσης χαρτοφυλακίου | 87 |
| 7.7 | Νέο ρυθμιστικό πλαίσιο – Συνεχής ενδοημερήσια αγορά | 88 |

| | |
|--------------------------------------|-----------|
| ΚΕΦΑΛΑΙΟ 8: ΣΥΜΠΕΡΑΣΜΑΤΑ | 91 |
| 8.1 Σύνοψη μοντέλων και μεθοδολογιών | 91 |
| 8.2 Συνολικά συμπεράσματα | 91 |
| 8.3 Προτάσεις μελλοντικής επέκτασης | 93 |
| | |
| ΚΕΦΑΛΑΙΟ 9: ΒΙΒΛΙΟΓΡΑΦΙΑ | 95 |

ΕΙΣΑΓΩΓΗ

1.1 ΑΝΤΙΚΕΙΜΕΝΟ ΕΡΓΑΣΙΑΣ

Αντικείμενο της παρούσας διπλωματικής εργασίας αποτελεί η πρόβλεψη φωτοβολταϊκής παραγωγής μέσω της ανάπτυξης ενός υβριδικού μοντέλου βαθιάς μάθησης, το οποίο βασίζει τη λειτουργία του σε αναδρομικά νευρωνικά δίκτυα και σύνθετες τεχνικές επεξεργασίας δεδομένων. Η επιτακτική ανάγκη για μείωση των εκπομπών διοξειδίου του άνθρακα και περιορισμό των επιπτώσεων της κλιματικής αλλαγής, καθώς και η μηδενική βιωσιμότητα των ορυκτών καυσίμων, έχουν οδηγήσει στην αυξανόμενη διεύθυνση των ανανεώσιμων πηγών ενέργειας στα συστήματα ηλεκτρικής ενέργειας. Αναμφίβολα, οι φωτοβολταϊκοί σταθμοί αποτελούν κύρια πηγή «πράσινης» ενέργειας τόσο στην Ελλάδα όσο και σε παγκόσμιο επίπεδο, εξαιτίας της αναμενόμενης παραγωγής, της εύκολης εγκατάστασης και της οικονομικής προσιτότητάς τους. Ωστόσο, η ένταξη της φωτοβολταϊκής ενέργειας στο δίκτυο έχει ως αποτέλεσμα την αύξηση της στοχαστικότητας και της μεταβλητότητας, την οποία αναπόφευκτα φέρουν οι περισσότερες ανανεώσιμες πηγές ενέργειας. Η παραγωγή ηλεκτρικής ενέργειας από φωτοβολταϊκούς σταθμούς εξαρτάται χρονικά και ποσοτικά από πληθώρα μετεωρολογικών συνθηκών, κυριότερη εκ των οποίων είναι η προσπίπτουσα ηλιακή ακτινοβολία. Η πιθανή απρόσμενη μεταβολή των μετεωρολογικών φαινομένων και κατά επέκταση η μη τήρηση των ιδανικών συνθηκών ενός φωτοβολταϊκού σταθμού, καθιστούν την πρόβλεψη της φωτοβολταϊκής παραγωγής μία απαιτητική διαδικασία με τεράστια πρακτική σημασία. Η ακριβής πρόβλεψη παραγωγής διαδραματίζει καθοριστικό ρόλο για μία σειρά φορέων του ενεργειακού τοπίου, καθώς όσο μεγαλύτερο μερίδιο καταλαμβάνει η φωτοβολταϊκή παραγωγή, τόσο περισσότερο επηρεάζεται και διακυβεύεται η εύρυθμη λειτουργία του συστήματος ηλεκτρικής ενέργειας. Σημαντικές αποκλίσεις μεταξύ προβλεπόμενης και παραγόμενης φωτοβολταϊκής ισχύος ενδέχεται να οδηγήσουν στη δημιουργία ποικίλων προβλημάτων στον ενεργειακό προγραμματισμό, στην ανεπιθύμητη εξάρτηση από συμβατικές μονάδες παραγωγής, στη μη αξιοποίηση περίσσειας παραγόμενης φωτοβολταϊκής ενέργειας και στη συνολική αύξηση του κόστους παραγωγής της ηλεκτρικής ενέργειας.

Η παραγωγή προβλέψεων φωτοβολταϊκής παραγωγής δύναται να προκύψει μέσω διαφόρων μεθόδων και για διαφορετικούς χρονικούς ορίζοντες. Οι πιο συχνά χρησιμοποιούμενες μέθοδοι αφορούν τις φυσικές, όπου η φωτοβολταϊκή παραγωγή συσχετίζεται με εξωγενείς μεταβλητές μέσω μαθηματικών εκφράσεων, τις στατιστικές, οι οποίες αξιοποιούν ιστορικά δεδομένα προσπαθώντας να προσεγγίσουν τη μελλοντική μεταβολή των μεγεθών, και τα μοντέλα μηχανικής μάθησης, τα οποία εκπαιδεύονται ομοίως με ιστορικά δεδομένα ώστε να αναγνωρίζουν μοτίβα συσχέτισης μεταξύ αιτίου και αποτελέσματος. Αναφορικά με τον χρονικό ορίζοντα της διαδικασίας προβλέψεων, πέραν αυτών με μακροπρόθεσμο ή μεσοπρόθεσμο χαρακτήρα, τα τελευταία χρόνια δίνεται ιδιαίτερη

έμφαση στη βραχυπρόθεσμη πρόβλεψη, με χρονική απόσταση μεταξύ παρατήρησης και πρόβλεψης ακόμη και μερικών λεπτών, η οποία καθιστά δυνατό τον βέλτιστο χειρισμό και έλεγχο των φωτοβολταϊκών συστημάτων σε πραγματικό χρόνο. Η συγκεκριμένη παράμετρος συνδυάζεται με την πρόσφατη άνθηση της τεχνητής νοημοσύνης, λόγω της ευελιξίας και της δυνατότητας των μοντέλων μηχανικής μάθησης να αποτυπώνουν δυσνόητες σχέσεις αλληλεξάρτησης μεταξύ εισόδου και εξόδου, βασιζόμενα αποκλειστικά σε ιστορικά δεδομένα.

Στην παρούσα διπλωματική εργασία αναπτύσσεται ένα υβριδικό μοντέλο βαθιάς μάθησης, το οποίο εκπαιδεύεται με ιστορικά δεδομένα παραγωγής και μετεωρολογικών μεταβλητών, επιχειρώντας την πρόβλεψη της φωτοβολταϊκής παραγωγής σε χρονικό ορίζοντα μίας ώρας. Οι επιμέρους τεχνικές επεξεργασίας του προτεινόμενου υβριδικού μοντέλου περιλαμβάνουν την αποσύνθεση της χρονοσειράς ισχύος σε τέσσερις συνιστώσες διαφορετικής συχνότητας μέσω της μεθόδου αποσύνθεσης πακέτου κυματιδίων (Wavelet Packet Decomposition / WPD), τέσσερα διακριτά αναδρομικά νευρωνικά δίκτυα μακράς βραχύχρονης μνήμης (Long Short Term Memory / LSTM), και τη μέθοδο γραμμικού συνδυασμού για την παραγωγή των τελικών προβλέψεων. Η ακρίβεια των παραγόμενων προβλέψεων αξιολογείται με προσεκτικά επιλεγμένα μετρητικά σφάλματος, με σκοπό τη διεξοδική εξέταση της αποτελεσματικότητάς του. Πέραν αυτού, υλοποιείται πλήρης εποχική και μετεωρολογική ανάλυση, ώστε να ερευνηθεί η απόδοση του προτεινόμενου μοντέλου πρόβλεψης υπό διαφορετικές μετεωρολογικές συνθήκες και να αποτυπωθούν τα ποιοτικά χαρακτηριστικά της διαδικασίας προβλέψεων. Προκειμένου να αξιολογηθεί περαιτέρω η ακρίβεια του προτεινόμενου υβριδικού μοντέλου, επιχειρείται η εφαρμογή του σε ένα πραγματικό πρόβλημα στα πλαίσια της αγοράς ηλεκτρικής ενέργειας. Η εν λόγω διαδικασία πιστοποιεί εμφατικά την αποτελεσματικότητά του και καθιστά έκδηλη την αυξανόμενη πρακτική αξία των βραχυπρόθεσμων μοντέλων πρόβλεψης, όπως αυτό της παρούσας διπλωματικής εργασίας.

1.2 ΑΝΑΣΚΟΠΗΣΗ ΒΙΒΛΙΟΓΡΑΦΙΑΣ

Η ακριβής πρόβλεψη της φωτοβολταϊκής παραγωγής αποτελεί διαδικασία κρίσιμου χαρακτήρα για την ορθή λειτουργία του συστήματος ηλεκτρικής ενέργειας και για την απρόσκοπτη διείσδυση ανανεώσιμων πηγών ενέργειας στο ενεργειακό μίγμα. Τα τελευταία χρόνια, τα μοντέλα μηχανικής μάθησης γνωρίζουν ραγδαία ανάπτυξη, λόγω της ικανότητάς τους να αναγνωρίζουν δυσνόητα μοτίβα αλληλεξάρτησης μεταξύ των δεδομένων. Σε αυτή την κατεύθυνση, παρουσιάζονται ενδεικτικά ορισμένες εργασίες της διαθέσιμης βιβλιογραφίας που αφορούν την ανάπτυξη μοντέλων μηχανικής μάθησης για πρόβλεψη της φωτοβολταϊκής παραγωγής.

Οι P. Li, K. Zhou, X. Lu, S. Yang στην εργασία [1] αναπτύσσουν ένα υβριδικό μοντέλο για πρόβλεψη φωτοβολταϊκής παραγωγής με χρονικό ορίζοντα μίας ώρας και ενδιάμεσο διάστημα πέντε λεπτών. Οι χρησιμοποιούμενες τεχνικές επεξεργασίας δεδομένων περιλαμβάνουν αποσύνθεση πακέτου κυματιδίων (WPD) και αναδρομικά νευρωνικά δίκτυα LSTM. Στη συγκεκριμένη εργασία θεωρείται πως υπάρχουν τέλειες προβλέψεις μετεωρολογικών δεδομένων σε χρονική απόσταση μίας ώρας, ενώ η αξιολόγηση του μοντέλου πρόβλεψης περιλαμβάνει μόνο στατιστικά μετρητικά σφάλματος.

Στην εργασία [2] οι D. Al Hakeem, P. Mandal, A. Haque, A. Yona, T. Senjyu και T. L. Tseng περιγράφουν μία υβριδική μεθοδολογία πρόβλεψης φωτοβολταϊκής παραγωγής

αποτελούμενη από μετασχηματισμό κυματιδίων (Wavelet Transformation / WT) και ένα νευρωνικό δίκτυο γενικευμένης παλινδρόμησης (Generalized Regression Neural Network / GRNN) με χρήση βελτιστοποίησης σμήνους σωματιδίων (Particle Swarm Optimization / PSO). Το συγκεκριμένο υβριδικό μοντέλο διαθέτει χρονικό ορίζοντα πρόβλεψης μερικών ωρών (μία έως έξι) και εισάγει διαστήματα εμπιστοσύνης bootstrap με σκοπό την ποσοτικοποίηση της αβεβαιότητας της εκτίμησης των παραγόμενων προβλέψεων.

Οι P. Mandal, S. Madhira, A. Haque, J. Meng και R.L. Pineda στην εργασία [3] αναπτύσσουν ένα υβριδικό μοντέλο βραχυπρόθεσμης φωτοβολταϊκής πρόβλεψης με χρονικό ορίζοντα μίας ώρας. Το μοντέλο περιλαμβάνει μετασχηματισμό κυματιδίων και ένα νευρωνικό δίκτυο συνάρτησης ακτινικής βάσης (radial basis function neural network), ενώ επίσης γίνεται εισαγωγή δεδομένων χρονικής υστέρησης με σκοπό τη μείωση του όγκου των χρησιμοποιούμενων δεδομένων και τη βελτίωση της ακρίβειας πρόβλεψης.

Το βραχυπρόθεσμο υβριδικό μοντέλο των Y. Wu, C. Chen και H. A. Rahman που περιγράφεται στην εργασία [4] χρησιμοποιείται για πρόβλεψη με χρονικό ορίζοντα μίας ώρας και περιλαμβάνει διαδικασία πρόβλεψης δύο σταδίων. Το πρώτο στάδιο περιλαμβάνει τη μέθοδο αυτοπαλινδρομικού ολοκληρωμένου κινητού μέσου όρου (Auto-Regressive Integrated Moving Average / ARIMA), μηχανές διανυσματικής υποστήριξης ελάχιστων τετραγώνων (least squares support vector machines), τεχνητά νευρωνικά δίκτυα (Artificial Neural Networks / ANN), και δίκτυα προσαρμοστικού νευροασαφούς συστήματος επαγωγής (adaptive neuro-fuzzy inference system). Τα αποτελέσματα του πρώτου σταδίου εισάγονται στο δεύτερο στάδιο, το οποίο με χρήση ενός προσαρμοστικού γενετικού αλγορίθμου εκτιμά τους συντελεστές βάρους κάθε επιμέρους μεθόδου του πρώτου σταδίου.

Οι K. Wang, X. Qi και H. Liu στην εργασία [5] προτείνουν ένα μοντέλο βαθιάς μάθησης, αποτελούμενο από ένα δίκτυο LSTM συνδεδεμένο σειριακά με ένα συνελκτικό νευρωνικό δίκτυο (Convolutional Neural Network / CNN). Κατά τη συγκεκριμένη μεθοδολογία, τα χρονικά χαρακτηριστικά των δεδομένων εισόδου εξάγονται αρχικά από το δίκτυο LSTM, ενώ στη συνέχεια εξάγονται τα χωρικά χαρακτηριστικά αυτών από το CNN.

Στο ίδιο πλαίσιο αλλά σε διαφορετική κατεύθυνση, οι X. Huang, Q. Li, Y. Tai, Z. Chen, J. Zhang, J. Shi, B. Gao και W. Liu περιγράφουν στην εργασία [6] ένα πολυμεταβλητό υβριδικό μοντέλο για την πρόβλεψη της ηλιακής ακτινοβολίας σε χρονικό ορίζοντα μίας ώρας. Η μεθοδολογία περιλαμβάνει αποσύνθεση πακέτου κυματιδίων, δίκτυα CNN και LSTM, καθώς και έναν πολυστρωματικό ταξινομητή (Multi-Layer Perceptron / MLP).

Ένα παρόμοιο μοντέλο βαθιάς μάθησης ανέπτυξαν οι D. Kothona, I.P. Panapakidis και G.C. Christoforidis στην εργασία [7], το οποίο απαρτίζεται από ένα σύνολο τεσσάρων LSTM με διαφορετικούς αλγόριθμους βελτιστοποίησης και ένα νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης. Το συγκεκριμένο μοντέλο εκπαιδεύεται με ιστορικά δεδομένα και χρησιμοποιείται για προβλέψεις πολλαπλών χρονικών οριζόντων (multi-step ahead forecasting). Συγκεκριμένα, κάθε επιμέρους πρόβλεψη χρονικού ορίζοντα δεκαπέντε λεπτών αξιοποιείται ως είσοδος για την παραγωγή της επόμενης πρόβλεψης χρονικού ορίζοντα μίας ώρας.

1.3 ΚΥΡΙΕΣ ΣΥΝΕΙΣΦΟΡΕΣ

Αδιαμφισβήτητα, στη διαθέσιμη βιβλιογραφία συναντάται πληθώρα μοντέλων μηχανικής μάθησης, τα οποία προσεγγίζουν αποτελεσματικά την πρόβλεψη φωτοβολταϊκής παραγωγής μέσω του συνδυασμού πολύπλοκων διαδικασιών και μεθόδων. Ωστόσο, στην πλειονότητά τους στερούνται ρεαλιστικής προσέγγισης, καθώς η αξιολόγησή τους περιορίζεται σε καθαρό ακαδημαϊκό πλαίσιο. Τα πιο συχνά χρησιμοποιούμενα βραχυπρόθεσμα μοντέλα φωτοβολταϊκής πρόβλεψης με χρονικό ορίζοντα λεπτών ή λίγων ωρών, θεωρούν δεδομένο ότι κατά τη χρονική απόσταση μεταξύ παρατήρησης και πρόβλεψης οι μετεωρολογικές μεταβλητές εμφανίζουν ελάχιστη μεταβολή. Επομένως, θεωρούν εκ των προτέρων γνωστά τα μελλοντικά μετεωρολογικά μεγέθη και δεν λαμβάνουν υπόψη το αναπόφευκτο σφάλμα πρόβλεψης, βελτιώνοντας έτσι πλασματικά την υπολογιζόμενη ακρίβεια. Συνολικά, η πλειονότητα των προτεινόμενων μοντέλων της διαθέσιμης βιβλιογραφίας προσανατολίζονται αποκλειστικά σε ακαδημαϊκές επιδιώξεις και αξιολογούνται μόνο υπό στατιστικό πρίσμα, χωρίς να εξετάζεται η αποτελεσματικότητά τους σε κάποιο πραγματικό πρόβλημα των συστημάτων ηλεκτρικής ενέργειας.

Στον αντίποδα, σε όλη την έκταση της παρούσας διπλωματικής εργασίας είναι έκδηλη η ρεαλιστική προσέγγιση που ακολουθείται, καθώς σε κανένα στάδιο δεν γίνονται παραδοχές εξιδανίκευσης και απλουστευτικές θεωρήσεις. Πιο αναλυτικά, τα ιστορικά δεδομένα με τα οποία τροφοδοτείται το προτεινόμενο υβριδικό μοντέλο προέρχονται από πραγματικό φωτοβολταϊκό σταθμό στην περιοχή της Ροδόπης και έχουν καταγραφεί από κατάλληλο εξοπλισμό. Το γεγονός αυτό καθιστά ευκολότερη την αποτύπωση της πραγματικής συμπεριφοράς των παρατηρούμενων μεγεθών, χωρίς να υπεισέρχεται σε κανένα σημείο η ανθρώπινη προκατάληψη. Επιπλέον, για την παραγωγή προβλέψεων, χρησιμοποιούνται μόνο ιστορικά δεδομένα και μετρήσεις σε πραγματικό χρόνο, επομένως δεν θεωρείται πως υπάρχει τέλεια εκ των προτέρων γνώση των μελλοντικών μετεωρολογικών συνθηκών. Το αναπόφευκτο σφάλμα των δεδομένων εισόδου, στην περίπτωση που τα δεδομένα αφορούν μελλοντικές χρονικές στιγμές, επηρεάζει σημαντικά την ακρίβεια της τελικής πρόβλεψης. Επομένως, όταν δεν λαμβάνεται υπόψη το έμφυτο σφάλμα των χρησιμοποιούμενων δεδομένων, δημιουργούνται εξιδανικευμένες συνθήκες εκπαίδευσης του μοντέλου, με αποτέλεσμα τη μεροληπτική αξιολόγησή του. Η μη συμπερίληψη προβλέψεων μετεωρολογικών δεδομένων στην είσοδο του μοντέλου καθιστά αναγκαία την εισαγωγή ενός ρεαλιστικού τρόπου αριθμητικής αναπαράστασης της ώρας ως μία επιπλέον χρονοσειρά στα δεδομένα εισόδου, ώστε το μοντέλο να αντιληφθεί ευκολότερα την περιοδική ημερήσια φωτοβολταϊκή παραγωγή και τη θέση του ηλίου στον ορίζοντα. Παράλληλα, με αυτόν τον τρόπο αυξάνεται η ακρίβεια των παραγόμενων προβλέψεων χωρίς να απαιτείται περαιτέρω αύξηση της πολυπλοκότητας των δικτύων LSTM.

Συμπληρωματικά, η απόδοση του προτεινόμενου υβριδικού μοντέλου αξιολογείται πλήρως μέσω εποχικής ανάλυσης, προκειμένου να γίνει αντιληπτό υπό ποιες συνθήκες εμφανίζει αυξημένη ή μειωμένη αποτελεσματικότητα. Κατά την εν λόγω διαδικασία οι παραγόμενες προβλέψεις αναλύονται ανά εποχή σε μηνιαίο επίπεδο και αναδεικνύονται τα ποιοτικά χαρακτηριστικά της μεθοδολογίας προβλέψεων. Πέραν αυτού, υλοποιείται ενδελεχής μετεωρολογική ανάλυση η οποία περιλαμβάνει χειροκίνητη ταξινόμηση του συνόλου των ημερών σε τρεις κατηγορίες, βάσει της πραγματικής παρατηρούμενης ηλιακής ακτινοβολίας: ηλιόλουστες, συννεφιασμένες και ημέρες με δυναμικά μετεωρολογικά φαινόμενα. Η

συγκεκριμένη κατηγοριοποίηση επιτρέπει την επιμέρους αξιολόγηση του προτεινόμενου υβριδικού μοντέλου και προσδιορίζει τις ιδανικές και τις δυσχερείς συνθήκες για την παραγωγή της φωτοβολταϊκής πρόβλεψης. Συνολικά, τόσο η εποχική όσο και η μετεωρολογική ανάλυση κατέχουν καίριο ρόλο στην διερεύνηση της απόδοσης της προτεινόμενης μεθοδολογίας και συνεισφέρουν ποικιλοτρόπως στην κατεύθυνση της μελλοντικής βελτίωσης αυτής.

Η ρεαλιστική προσέγγιση που ακολουθείται σε όλα τα στάδια δημιουργίας, εκπαίδευσης και αξιολόγησης του προτεινόμενου υβριδικού μοντέλου, καθιστά εφικτή την εφαρμογή του σε ένα πραγματικό πρόβλημα της αγοράς ηλεκτρικής ενέργειας. Συνεπώς, πέρα από τη θεωρητική αξιολόγηση με χρήση κλασικών μετρητικών σφάλματος, προσδιορίζεται η πρακτική αποτελεσματικότητα του προτεινόμενου υβριδικού μοντέλου μέσω ποσοτικοποίησης της ακρίβειας πρόβλεψης και μετατροπής της σε πραγματική αξία, διαδικασία που αποτελεί και τη βασική συνεισφορά της παρούσας διπλωματικής εργασίας. Υπό αυτό το καθεστώς, εξετάζεται η απόδοση του υβριδικού μοντέλου στο θεσμοθετημένο ρυθμιστικό πλαίσιο της αγοράς ενέργειας του έτους 2022, διαδικασία η οποία πιστοποιεί την αξιοπιστία του καθώς και τη μεγάλη πρακτική του αξία. Επιπλέον, μέσω επέκτασης της στοχευμένης πρακτικής εφαρμογής και χρήση επιπρόσθετου συνόλου δεδομένων που αφορούν δεύτερο φωτοβολταϊκό σταθμό, επισημαίνεται η επίδραση συσσώρευσης (aggregation effect) στη διαδικασία πρόβλεψης φωτοβολταϊκής παραγωγής και αναλύεται η επιρροή της χωρικής διασποράς στη συνολική ακρίβεια των προβλέψεων. Εν κατακλείδι, καθίσταται εμφανές πως το υβριδικό μοντέλο της παρούσας διπλωματικής εργασίας θα μπορούσε – υπό ελάχιστες τροποποιήσεις – να χρησιμοποιηθεί πρακτικά από κάποιον συμμετέχοντα στην αγορά ηλεκτρικής ενέργειας.

1.4 ΔΟΜΗ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία οργανώνεται σε εννέα κεφάλαια:

- Στο Κεφάλαιο 2 παρουσιάζεται ο βασικός τρόπος λειτουργίας ενός φωτοβολταϊκού σταθμού και επισημαίνεται η αξία της πρόβλεψης φωτοβολταϊκής παραγωγής. Επίσης, καταγράφονται οι κυριότεροι παράγοντες που επηρεάζουν τη φωτοβολταϊκή παραγωγή και υλοποιούνται διαχωρισμοί με βάση τις μεθόδους και τον χρονικό ορίζοντα των χρησιμοποιούμενων μοντέλων πρόβλεψης.
- Στο Κεφάλαιο 3 προσφέρεται το θεωρητικό υπόβαθρο των νευρωνικών δικτύων και παρουσιάζονται οι κυριότερες κατηγορίες αυτών. Επιπλέον, αναφέρεται ο τρόπος λειτουργίας των δικτύων LSTM, καθώς και τα σημαντικότερα πλεονεκτήματά τους.
- Στο Κεφάλαιο 4 παρέχονται οι απαραίτητες πληροφορίες για την προέλευση των χρησιμοποιούμενων δεδομένων και περιγράφονται οι τεχνικές επεξεργασίας τους. Επίσης, επεξηγείται αναλυτικά η χρησιμοποιούμενη μέθοδος αποσύνθεσης της ιστορικής χρονοσειράς ισχύος.
- Στο Κεφάλαιο 5 παρουσιάζεται η μεθοδολογία του προτεινόμενου υβριδικού μοντέλου και η διαδικασία βελτιστοποίησης των παραμέτρων του. Συμπληρωματικά, αναλύεται η εφαρμοζόμενη αριθμητική αναπαράσταση της ώρας και οι ωφέλιμες συνέπειές της.

- Στο Κεφάλαιο 6 εξηγούνται τα χρησιμοποιούμενα μετρητικά σφάλματος και αναλύονται τα αποτελέσματα της αξιολόγησης του υβριδικού μοντέλου. Επίσης, παρουσιάζονται και σχολιάζονται τα αποτελέσματα της εποχικής και μετεωρολογικής ανάλυσης.
- Στο Κεφάλαιο 7 περιγράφεται το ρυθμιστικό πλαίσιο της αγοράς ηλεκτρικής ενέργειας και παρουσιάζεται η απόδοση του προτεινόμενου υβριδικού μοντέλου στη συγκεκριμένη εφαρμογή. Επίσης, αναλύεται η επίδραση ενός δεύτερου φωτοβολταϊκού σταθμού στις χρεώσεις του εν λόγω κανονιστικού πλαισίου και στη γενικότερη ακρίβεια της συνολικής πρόβλεψης.
- Στο Κεφάλαιο 8 πραγματοποιείται η σύνοψη της διπλωματικής εργασίας, παρουσιάζονται τα συνολικά συμπεράσματα και καταγράφονται προτάσεις μελλοντικής επέκτασης.
- Στο Κεφάλαιο 9 περιλαμβάνεται η χρησιμοποιούμενη βιβλιογραφία για την εκπόνηση της παρούσας διπλωματικής εργασίας.

ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

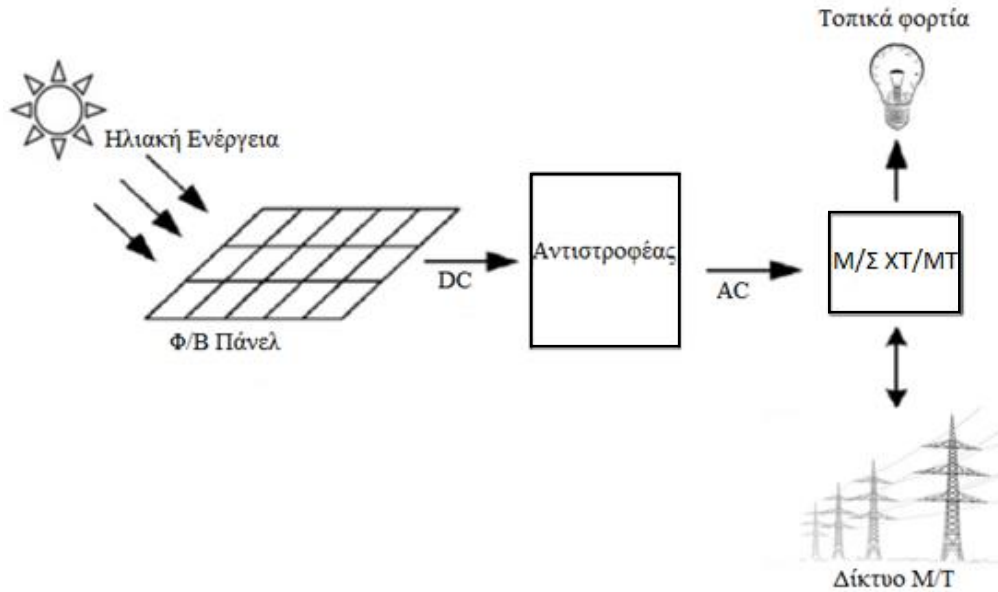
2.1 ΓΕΝΙΚΑ

Τα τελευταία χρόνια, εξαιτίας της έντονης κλιματικής αλλαγής και της αυξημένης ανάγκης αναζήτησης βιώσιμων τρόπων παραγωγής ηλεκτρικής ενέργειας, παρατηρείται μία εμφανής αλλαγή προσανατολισμού η οποία εστιάζει στις Ανανεώσιμες Πηγές Ενέργειας (ΑΠΕ) ως βασική πηγή παραγωγής. Σε αυτή την κατεύθυνση, παρουσιάζεται μία σαφής προτίμηση στην υδροηλεκτρική, αιολική, και ηλιακή παραγωγή, καθώς το 2022 οι τρεις αυτές τεχνολογίες συγκέντρωσαν το 99,15% της συνολικής παγκόσμιας εγκατεστημένης ισχύος μεταξύ των ΑΠΕ [8]. Πιο αναλυτικά, η εγκατεστημένη ισχύς των φωτοβολταϊκών (Φ/Β) σταθμών το ίδιο έτος ανήλθε στο 31,20% της συνολικής παγκόσμιας εγκατεστημένης ισχύος ΑΠΕ, ενώ αντίστοιχα το 2021 η ετήσια Φ/Β παραγωγή έφτασε στο 12,98% της συνολικής παραγόμενης ενέργειας από ΑΠΕ. Σε ότι αφορά την ελληνική επικράτεια, το 2021 τα Φ/Β πάρκα συνεισέφεραν σε ποσοστό 23,72% στη συνολική παραγόμενη ενέργεια από ΑΠΕ, ενώ το 2022 το ποσοστό της εγχώριας εγκατεστημένης ισχύος Φ/Β σταθμών ανήλθε στο 39,78% της συνολικής ισχύος ΑΠΕ. Προχωρώντας σε μία ευρύτερη αξιολόγηση της προσφοράς της ηλιακής ενέργειας στην Ελλάδα και λαμβάνοντας υπόψη όλο το ενεργειακό μίγμα παραγωγής για το 2022, συμπεριλαμβανομένων όλων των τεχνολογιών, διαπιστώνεται πως η ηλιακή ενέργεια συνεισφέρει το 13,63% της συνολικής εγχώριας παραγωγής [9].

2.2 ΤΡΟΠΟΣ ΛΕΙΤΟΥΡΓΙΑΣ ΦΩΤΟΒΟΛΤΑΪΚΟΥ ΣΤΑΘΜΟΥ

Όπως προκύπτει από την Ενότητα 2.1, οι Φ/Β σταθμοί αποτελούν τεχνολογία αιχμής προς την επιζητούμενη ενεργειακή μετάβαση, επομένως είναι αναγκαία η ενδελεχής κατανόηση της λειτουργίας τους. Τα κυριότερα μέρη τα οποία απαρτίζουν έναν Φ/Β σταθμό είναι τα ακόλουθα [10]:

- Φ/Β Πάνελ
- Αντιστροφέας
- Μετασχηματιστής Χαμηλής Τάσης / Μέσης Τάσης (Μ/Σ ΧΤ/ΜΤ)
- Κτίριο Τοπικών Χειρισμών

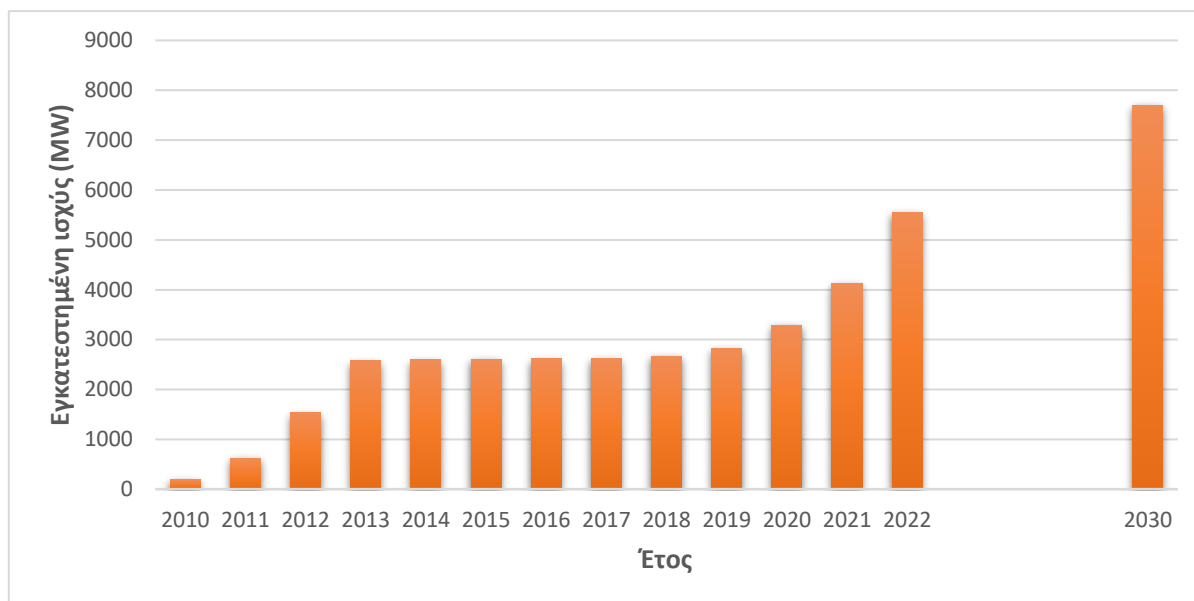


Σχήμα 2.1 : Τυπική λειτουργία Φ/Β σταθμού

Όπως απεικονίζεται στο Σχήμα 2.1, τα Φ/Β πάνελ, ή αλλιώς ηλιακοί συλλέκτες, απορροφούν την ηλιακή ακτινοβολία, και αξιοποιώντας τα ημιαγωγικά υλικά κατασκευής τους παράγουν ηλεκτρικό ρεύμα το οποίο μεταφέρεται στον αντιστροφέα (inverter). Ο αντιστροφέας διαθέτει DC είσοδο και AC έξοδο, ούτως ώστε να είναι εφικτή η έγχυση της παραγόμενης ενέργειας στο δίκτυο μέσω του Μ/Σ ΧΤ/ΜΤ, ο οποίος ανυψώνει το επίπεδο τάσης από τη χαμηλή τάση στη μέση τάση. Παράλληλα, πριν πραγματοποιηθεί η ανύψωση τάσης, τροφοδοτούνται τα τοπικά φορτία στο κτίριο τοπικών χειρισμών, όπως τα μετρητικά όργανα και ο φωτισμός του σταθμού. Εκτός των άλλων, στο κτίριο τοπικών χειρισμών τοποθετείται ο απαραίτητος εξοπλισμός για τον έλεγχο του Φ/Β σταθμού, όπως οι απαραίτητοι διακόπτες ισχύος, οι αποζεύκτες, και εξοπλισμός για την απρόσκοπτη λειτουργία του σταθμού (Uninterrupted Power Supply / UPS, τοπική μπαταρία).

2.3 ΑΞΙΑ ΠΡΟΒΛΕΨΗΣ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

Όπως αναπτύχθηκε στην Ενότητα 2.1, η συμμετοχή των Φ/Β σταθμών στην παραγωγή ηλεκτρικής ενέργειας στην Ελλάδα είναι ανώτερη του παγκόσμιου μέσου όρου, γεγονός το οποίο οφείλεται εν πολλοίς σε γεωγραφικούς και μετεωρολογικούς παράγοντες. Επομένως, είναι λογικό η συνολική διαδικασία της Φ/Β παραγωγής να φέρει αυξημένες απαιτήσεις απόδοσης και αξιοπιστίας, καθώς εκ φύσεως οι ΑΠΕ συνοδεύονται από σημαντικό βαθμό αβεβαιότητας λόγω της εξάρτησής τους από μετεωρολογικούς παράγοντες. Προκειμένου να συνεχιστεί η απρόσκοπτη διεξόδυση νέων Φ/Β σταθμών και να ικανοποιηθούν οι απαιτήσεις του *Εθνικού Σχεδίου για την Ενέργεια και το Κλίμα*, οι οποίες προβλέπουν 7,7 GW εγκατεστημένης Φ/Β ισχύος μέχρι το 2030, η πρόβλεψη της Φ/Β παραγωγής οφείλει να είναι όσο το δυνατόν ακριβέστερη. Αυτό αποτελεί αναγκαία προϋπόθεση ώστε να διασφαλιστεί η ευστάθεια του ηλεκτρικού δικτύου και να αποφευχθούν προβλήματα διακύμανσης τάσης και ρύθμισης συχνότητας [11].



Σχήμα 2.2 : Εγκατεστημένη ισχύς Φ/Β σταθμών στην Ελλάδα

Όπως παρουσιάζεται στο Σχήμα 2.2, η κατασκευή νέων Φ/Β σταθμών στην Ελλάδα ακολουθεί αυξητική τάση και αναμένεται να εκτοξευθεί τα προσεχή έτη [12]. Επομένως, γίνεται κατανοητό πως η πρόβλεψη Φ/Β παραγωγής παρουσιάζει ιδιαίτερη χρησιμότητα για μία σειρά φορέων του ενεργειακού τοπίου, οι οποίοι εξασφαλίζουν την εύρυθμη λειτουργία του συστήματος. Πιο αναλυτικά, τα τελευταία χρόνια καταβάλλεται προσπάθεια βελτίωσης και ανάπτυξης του Ελληνικού Συστήματος Μεταφοράς (ΕΣΜ) με τη δημιουργία του Χρηματιστηρίου Ενέργειας (ΧΕ) και την υιοθέτηση του ευρωπαϊκού μοντέλου στόχου (target model) σε μία απόπειρα ευθυγράμμισης της ελληνικής και της ευρωπαϊκής αγοράς ενέργειας. Σε αυτή την κατεύθυνση, έχουν σχηματιστεί οι ακόλουθες αγορές ενεργειακών προϊόντων [13]:

- Ενεργειακή χρηματοπιστωτική αγορά (Forward Market / FM): Εκπλήρωση σε χρονικό διάστημα μεγαλύτερο του ενός έτους.
- Αγορά επόμενης ημέρας (Day-Ahead Market / DAM): Εκπλήρωση την επόμενη ημέρα.
- Ενδοημερήσια αγορά (Intra-Day Market / IDM): Εκπλήρωση τις επόμενες ώρες.
- Αγορά εξισορρόπησης ενέργειας/ισχύος (Balancing Market / BM): Εκπλήρωση τις επόμενες ώρες.

Βασική επιδίωξη όλων των ανωτέρω αγορών αποτελεί η αντιστοίχιση σε πραγματικό χρόνο της ζήτησης και της παραγωγής ηλεκτρικής ενέργειας. Προκειμένου αυτό να επιτευχθεί, οι Φορείς Σωρευτικής Εκπροσώπησης (ΦοΣΕ) παραγωγών και προμηθευτών ηλεκτρικής ενέργειας οφείλουν να καταρτίζουν και να υποβάλλουν τις προβλέψεις παραγωγής και ζήτησης, ώστε μέσω του ΧΕ να πραγματοποιείται η σύζευξη των δύο αντιπαραβαλλόμενων μερών στο προκαθορισμένο χρονικό επίπεδο. Επιπλέον, η πρόβλεψη Φ/Β παραγωγής αποτελεί διαδικασία κρίσιμου χαρακτήρα για τον Ανεξάρτητο Διαχειριστή Μεταφοράς Ηλεκτρικής Ενέργειας (ΑΔΜΗΕ), τόσο σε μακροπρόθεσμο ορίζοντα, ώστε να συντελείται ο απαραίτητος ενεργειακός προγραμματισμός, όσο και σε βραχυπρόθεσμο επίπεδο, για να διασφαλίζεται η αδιάλειπτη επάρκεια και ορθή λειτουργία του ηλεκτρικού δικτύου. Σε αυτό το σημείο, πρέπει να αναφερθεί πως η ακρίβεια μιας πρόβλεψης έχει άμεσο αντίκτυπο και σε οικονομικό επίπεδο για όλους τους εμπλεκόμενους. Πέραν των χρεώσεων που επιβάλλονται στους ΦοΣΕ σε

περίπτωση σημαντικής απόκλισης μεταξύ πραγματικής και προβλεπόμενης ενέργειας, μία αναντιστοιχία παραγωγής και ζήτησης είναι πιθανό να οδηγήσει είτε σε περιορισμό παραγωγής ΑΠΕ από τον ΑΔΜΗΕ (σε περίπτωση απρόσμενα υψηλότερης παραγωγής από ΑΠΕ) άρα σε διαφυγόντα κέρδη του παραγωγού, είτε στην ανάγκη άμεσης λειτουργίας θερμικών μονάδων και εφεδρειών (σε περίπτωση αισιόδοξης πρόβλεψης παραγωγής από ΑΠΕ που δεν ικανοποιήθηκε), άρα σε αυξημένη τιμή εκκαθάρισης της αγοράς.

2.4 ΠΑΡΑΓΟΝΤΕΣ ΠΟΥ ΕΠΗΡΕΑΖΟΥΝ ΤΗ ΦΩΤΟΒΟΛΤΑΪΚΗ ΠΑΡΑΓΩΓΗ

Η παραγωγή ενός Φ/Β σταθμού εξαρτάται, όπως και η συντριπτική πλειονότητα των ΑΠΕ, από πληθώρα μη ελεγχόμενων εξωτερικών παραγόντων. Ο λόγος για τον οποίο η Φ/Β πρόβλεψη αποκτά αναγκαίο αλλά και ταυτόχρονα απαιτητικό χαρακτήρα, αφορά τη μη ελεγχόμενη φύση ενός Φ/Β σταθμού, ο οποίος αναπόφευκτα εναπόκειται σε μετεωρολογικούς, γεωγραφικούς και εν γένει δυναμικά μεταβαλλόμενους παράγοντες. Οι κυριότεροι από αυτούς παρουσιάζονται στη συνέχεια.

- **Ηλιακή Ακτινοβολία:** Αδιαμφισβήτητη, κρισιμότερη μεταβλητή για την Φ/Β παραγωγή είναι η προσπίπτουσα ηλιακή ακτινοβολία στους ηλιακούς συλλέκτες, η οποία, όσο λεπτομερής μελέτη και να έχει διεξαχθεί κατά την κατασκευή του Φ/Β πάρκου, μπορεί να ποικίλει έντονα κατά τη διάρκεια του έτους ή ακόμη και κατά τη διάρκεια της ίδιας ημέρας. Η έντονη παρουσία πυκνών και καθολικών τοπικών νεφώσεων μειώνει σε τεράστιο βαθμό τη Φ/Β παραγωγή, εξαιτίας της άμεσης συσχέτισής της με την ηλιοφάνεια. Πιο συγκεκριμένα, προκειμένου ένας ηλιακός συλλέκτης να απορροφήσει το μέγιστο ποσοστό της ακτινοβολίας, πρέπει η επιφάνειά του να είναι κάθετη στις ηλιακές ακτίνες, προϋπόθεση δύσκολα επιτεύξιμη, καθώς η θέση του ήλιου στον ορίζοντα μεταβάλλεται κατά την διάρκεια του έτους. Για αυτόν τον λόγο έχουν εισαχθεί Φ/Β πάνελ νεότερης τεχνολογίας τα οποία έχουν τη δυνατότητα περιστροφής, ώστε να επιτυγχάνουν γωνία πρόσπτωσης 90° για όσο το δυνατόν περισσότερο χρονικό διάστημα εντός της ημέρας. Τα Φ/Β αυτά πάνελ, μπορούν να αυξήσουν την παραγωγή έως 50% και 300% το καλοκαίρι και τον χειμώνα, αντίστοιχα [14].
- **Θερμοκρασία:** Η πλειονότητα των Φ/Β πάνελ έχουν κατασκευαστεί με ιδανική θερμοκρασία λειτουργίας τους 25°C, τιμή η οποία αν ξεπεραστεί συνεπάγεται μείωση της παραγόμενης ισχύος, καθώς αυξάνεται ο ρυθμός των εσωτερικών φορέων ανασυνδυασμού του ημιαγωγού κατασκευής τους. Αυτό έχει ως αποτέλεσμα τη μικρή αύξηση του ηλεκτρικού ρεύματος, η οποία όμως συνοδεύεται από μεγαλύτερη πτώση τάσης άρα και μείωση της ισχύος εξόδου. Σε μία ηλιόλουστη ημέρα, ιδίως τους καλοκαιρινούς μήνες, η θερμοκρασία του συλλέκτη είναι πολύ πιθανόν να ξεπεράσει τους 65°C, φαινόμενο το οποίο μπορεί να οδηγήσει έως και σε 0,5% μείωση της απόδοσης ανά αυξανόμενο βαθμό πέραν των 25°C [14].
- **Γήρανση:** Όλος ο τεχνολογικός εξοπλισμός ενός Φ/Β σταθμού υπόκειται σε εξωτερικούς παράγοντες οι οποίοι σταδιακά φθείρουν τα παρεμβαλλόμενα μέρη και μειώνουν την

απόδοσή του. Ακόμη και στο ενδεχόμενο άρτιας συντήρησης του εξοπλισμού, η χρόνια γήρανση μόνο των ηλιακών συλλεκτών μπορεί να μειώσει την απόδοση του σταθμού κατά 10% τα πρώτα 10 χρόνια και κατά 20% σε μία χρονική περίοδο 20 έως 25 ετών από την έναρξη λειτουργίας του σταθμού [15].

- Σκόνη – Συντήρηση: Είναι αναμενόμενο πως μία ευαίσθητη τεχνολογική κατασκευή, όπως ένα Φ/Β πάνελ το οποίο βρίσκεται σε όλη τη διάρκεια ζωής του εκτεθειμένο σε εξωτερικό χώρο θα παρουσιάσει με μεγάλη συχνότητα επικαθήμενη σκόνη, η οποία αποτελεί ανασταλτικό παράγοντα στη μέγιστη απορρόφηση ηλιακής ακτινοβολίας. Ειδικότερα, μιας και η πλειονότητα των Φ/Β σταθμών εγκαθίστανται σε αγροτικές περιοχές, η αυξημένη παρουσία σκόνης στην επιφάνεια των συλλεκτών μπορεί να μειώσει την απόδοση του σταθμού έως και 21% [16]. Γενικότερα, η ολοκληρωμένη και σε τακτά χρονικά διαστήματα συντήρηση είναι καθοριστικής σημασίας παράγοντας για την ορθή λειτουργία και επιμήκυνση της διάρκειας ζωής ενός Φ/Β σταθμού. Η διαδικασία αυτή περιλαμβάνει πέρα από τον ηλεκτρομηχανολογικό εξοπλισμό, την επιμέλεια καθαριότητας των συλλεκτών και του περιβάλλοντα χώρου και την απομάκρυνση βλάστησης που μπορεί να προκαλέσει ανεπιθύμητη σκίαση.

2.5 ΜΕΘΟΔΟΙ ΠΡΟΒΛΕΨΗΣ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

Η αξιοποίηση της ηλιακής ακτινοβολίας για παραγωγή ηλεκτρικής ενέργειας έχει αυξηθεί ραγδαία τα τελευταία χρόνια, καθώς η ευκολία εγκατάστασης, η ευελιξία, και το μειούμενο κόστος παραγωγής, έχουν καταστήσει τους Φ/Β σταθμούς ελκυστικό πεδίο επένδυσης. Ταυτόχρονα, στην προσπάθεια να περιοριστούν τα μειονεκτήματα που απορρέουν κυρίως από την τυχαιότητα της Φ/Β παραγωγής, έχουν αναπτυχθεί πολυάριθμες μέθοδοι πρόβλεψης, οι οποίες, χρησιμοποιώντας διαφορετικές τεχνικές, επιδιώκουν να προσεγγίσουν την πραγματική Φ/Β παραγωγή στον αντίστοιχο επιθυμητό χρονικό ορίζοντα. Ο διαφορετικός τρόπος παραγωγής των προβλέψεων διαφοροποιεί σημαντικά της υφιστάμενες μεθόδους, με την κάθε μία από αυτές να παρουσιάζει συγκεκριμένα πλεονεκτήματα και μειονεκτήματα.

2.5.1 Φυσικές μέθοδοι

Οι φυσικές μέθοδοι χρησιμοποιούν μαθηματικά μοντέλα τα οποία συσχετίζουν άμεσα τις μεταβλητές που επηρεάζουν τη λειτουργία ενός Φ/Β σταθμού με την παραγόμενη ισχύ. Ουσιαστικά πρόκειται για μαθηματικές εξισώσεις, οι οποίες χρησιμοποιούν παράγοντες όπως η ηλιακή ακτινοβολία, η θερμοκρασία, η ταχύτητα του ανέμου, και η γήρανση, για να προβλέψουν τη Φ/Β παραγωγή. Για παράδειγμα, όπως αναλύθηκε στην Ενότητα 2.4, καθοριστικό ρόλο διαδραματίζει η ηλιακή ακτινοβολία και η γωνία πρόσπτωσης των ακτινών του ηλίου στους συλλέκτες. Ωστόσο, η γωνία πρόσπτωσης δεν είναι σταθερή ώστε να διατηρείται ιδανικά στις 90°, αλλά μεταβάλλεται ανάλογα με την γωνία απόκλισης δ , η οποία είναι η γωνία ανάμεσα στην ευθεία ήλιου - γης και την προβολή της, και οφείλεται στην κλίση της γης επί του άξονα περιστροφής της. Η γωνία αυτή ποικίλει ανάλογα με το γεωγραφικό πλάτος και την ημέρα του έτους n και ισούται με:

$$\delta \approx 23,45^\circ \cdot \sin\left(360 \cdot \frac{284 + n}{365}\right) \quad (2.1)$$

Με παρόμοιο τρόπο υπολογίζονται όλες οι μεταβλητές του εμπλεκόμενου εξοπλισμού, οι οποίες όμως εξαρτώνται σε μεγάλο βαθμό από τα τεχνικά χαρακτηριστικά των κατασκευαστών. Τα δεδομένα αυτά είναι πιθανόν να μην είναι διαθέσιμα, να είναι μειωμένης ακρίβειας ή να έχουν προκύψει σε εργαστηριακό περιβάλλον, εισάγοντας έτσι τον ανθρώπινο εμπειρικό παράγοντα και δυσχεραίνοντας την αποτελεσματικότητα της μεθόδου [17]. Οι φυσικές μέθοδοι δεν απαιτούν ιστορικά δεδομένα και είναι ιδιαίτερα αποτελεσματικές, εφόσον η μοντελοποίηση έχει καταστρωθεί με άρτιες μετεωρολογικές προβλέψεις, ακριβή δεδομένα και έχουν ληφθεί υπόψη όλες οι απαιτούμενες παράμετροι. Ωστόσο, καθίστανται εξαιρετικά χρονοβόρες και απαιτητικές στην εφαρμογή τους, καθώς τα χαρακτηριστικά κάθε περίπτωσης μπορεί να διαφέρουν. Επομένως, αν και ορισμένες σύνθετες μέθοδοι είναι πιθανό να εμφανίζουν ικανοποιητική απόδοση, η εξειδίκευση που χρειάζονται και η μη ευελιξία τους αποτελούν σημαντικό μειονέκτημα.

2.5.2 Στατιστικές μέθοδοι

Σε αντίθεση με τις φυσικές μεθόδους, οι στατιστικές μέθοδοι χρησιμοποιούν ιστορικά δεδομένα ενός Φ/Β σταθμού και προσπαθούν μέσω της πρότερης συμπεριφοράς τους να προβλέψουν τη μελλοντική τους μεταβολή. Τα τελευταία χρόνια έχουν αναπτυχθεί ποικίλα μοντέλα που χρησιμοποιούν σύνθετες τεχνικές ανάλυσης δεδομένων, παρουσιάζοντας μάλιστα τη δυνατότητα πολλών επιπέδων πρόβλεψης. Στην περίπτωση ενός Φ/Β πάρκου, είναι πιθανό να προηγείται η πρόβλεψη των μετεωρολογικών δεδομένων και στη συνέχεια βάσει αυτών να δημιουργείται η τελική πρόβλεψη παραγωγής, καθιστώντας έτσι τη διαδικασία καθολικά εφαρμόσιμη και περισσότερο αξιόπιστη. Παρόλα αυτά, οι στατιστικές μέθοδοι εμφανίζουν ιδιαίτερη ευαισθησία στο πλήθος και την ποιότητα των δεδομένων εισόδου τους, τα οποία απαιτείται να είναι πλήρως αντιπροσωπευτικά και εκκαθαρισμένα από ακραίες τιμές και ανωμαλίες. Παράλληλα, ένα ακόμα σημαντικό μειονέκτημά τους είναι η δυσκολία να εξάγουν σύνθετες μη γραμμικές σχέσεις μεταξύ των δεδομένων, φαινόμενο συχνό στη Φ/Β παραγωγή. Επομένως, η πρόκληση μεταφέρεται στην απόκτηση και επεξεργασία ιστορικών δεδομένων υψηλής ποιότητας, εγείροντας με αυτόν τον τρόπο και ζητήματα αξιοπιστίας των μετρητικών οργάνων [18].

2.5.3 Μοντέλα μηχανικής μάθησης

Η ραγδαία ανάπτυξη που γνωρίζει η επιστήμη των υπολογιστών και ο κλάδος της τεχνητής νοημοσύνης τις τελευταίες δεκαετίες, έχει διαδώσει ευρέως καινοτόμα εργαλεία τα οποία βρίσκουν εφαρμογή και σε προβλήματα μελλοντικών προβλέψεων. Τα μοντέλα μηχανικής μάθησης (Machine Learning / ML) αξιοποιούν τα ιστορικά δεδομένα μέσω μίας διαδικασίας εκπαίδευσης, κατά την οποία προσπαθούν να αναγνωρίσουν μοτίβα αλληλεξάρτησης μεταξύ των δεδομένων εισόδου και εξόδου. Η συγκεκριμένη προσέγγιση συνδυάζει πλεονεκτήματα των φυσικών και στατιστικών μεθόδων απαλείφοντας την πλειονότητα των μειονεκτημάτων τους, καθώς έχει τη δυνατότητα να αποτυπώνει πολύπλοκες, μη γραμμικές και δύσκολα αναγνωρίσιμες συσχετίσεις των μετεωρολογικών και τεχνικών

παραμέτρων με την παραγόμενη ισχύ. Τα συγκεκριμένα μοντέλα χρησιμοποιούν κάποια δεδομένα εισόδου $x = \{x_1, x_2, x_3, \dots, x_n\}$ και ένα τμήμα του συνολικού σετ δεδομένων με γνωστές τιμές (y, x) , προσπαθώντας να επιτύχουν μία προσέγγιση $f(x)$ της συνάρτησης $f^*(x)$ συσχετίζοντας τα x, y , ελαχιστοποιώντας κάποια συνάρτηση σφάλματος $L(y, f(x))$ ως ακολούθως:

$$f^* = \operatorname{argmin}(Ex(Ey(L(y, f(x))))|x)) \quad (2.2)$$

Όπως είναι λογικό, τα μοντέλα ML απαιτούν και αυτά προσεκτικούς χειρισμούς κατά τον ορισμό των παραμέτρων λειτουργίας τους, καθώς πάντα ενέχει ο κίνδυνος να παρουσιάσουν ορισμένες παθογένειες. Ένα μοντέλο με ελάχιστα δεδομένα εισόδου, απλοϊκά εκπαιδευμένο ή με σημαντική πόλωση (bias) είναι πιθανόν να αδυνατεί να συσχετίσει τις μεταβλητές εισόδου και εξόδου οδηγούμενο σε ανακριβείς προβλέψεις (under-fitting). Όμοια, ένα μοντέλο υπερβολικά πολύπλοκο με αξιοσημείωτη διαφορά μεταξύ δεδομένων εκπαίδευσης και ελέγχου μπορεί να εκπαιδευθεί δογματικά, παρουσιάζοντας έντονη δυσκολία να ανταποκριθεί σε νέα δεδομένα (overfitting) [19]. Οι αρχές λειτουργίας των μοντέλων ML και της βασικής υποκατηγορίας τους που αφορά τα νευρωνικά δίκτυα, παρουσιάζονται αναλυτικότερα στο Κεφάλαιο 3.

2.6 ΧΡΟΝΙΚΗ ΤΑΞΙΝΟΜΗΣΗ ΜΟΝΤΕΛΩΝ ΠΡΟΒΛΕΨΗΣ

Αν και δεν υπάρχουν ευρέως αποδεκτές χρονικές κλίμακες ταξινόμησης της Φ/Β πρόβλεψης, η πλειονότητα της διεθνούς βιβλιογραφίας αναφέρεται σε τρεις βασικές κατηγορίες: βραχυπρόθεσμη, μεσοπρόθεσμη και μακροπρόθεσμη πρόβλεψη. Ο χρονικός ορίζοντας της πρόβλεψης επηρεάζει σημαντικά την ακρίβεια αυτής, καθώς είναι αναμενόμενο πως όσο αυξάνεται το διάστημα της πρόβλεψης τόσο δυσχεραίνει η διαδικασία προσέγγισης της πραγματικής ισχύος. Κάθε είδος πρόβλεψης έχει ιδιαίτερη αξία για τους σκοπούς για τους οποίους προορίζεται, ενώ όλες οι κατηγορίες είναι αλληλοσυμπληρούμενες τόσο χρονικά όσο και πρακτικά.

2.6.1 Βραχυπρόθεσμη πρόβλεψη

Η βραχυπρόθεσμη πρόβλεψη αφορά χρονικό διάστημα λιγότερο της μίας εβδομάδας και είναι το είδος πρόβλεψης με τη μεγαλύτερη πρακτική αξία. Στις περισσότερες περιπτώσεις, η πρόβλεψη γίνεται είτε για την επόμενη ώρα (one-hour ahead), είτε για την επόμενη ημέρα (day-ahead). Εξαιτίας της μεγάλης διαφοράς της φύσης τους, οι συγκεκριμένες προβλέψεις χωρίζονται σε δύο επιμέρους κατηγορίες.

- Υπέρ-βραχυπρόθεσμη πρόβλεψη (ultra-short-term): Αφορά χρονικό ορίζοντα μερικών δευτερολέπτων έως μίας ώρας. Λόγω του πολύ μικρού χρονικού ορίζοντα πρόβλεψης, συνήθως προτιμάται η χρήση δεδομένων πέρα των μετεωρολογικών προβλέψεων, όπως επίγειες φωτογραφίες του ουρανού (ground-based sky images), δορυφορικές φωτογραφίες, και μετρήσεις ηλιακής ακτινοβολίας και θερμοκρασίας. Επίσης, συχνή είναι και η χρήση τεχνικών αποσύνθεσης χρονοσειρών. Η υπέρ-βραχυπρόθεσμη πρόβλεψη είναι καίριας

σημασίας, καθώς χρησιμεύει στην ευστάθεια του δικτύου, την αυτόματη αποδέσμευση μονάδων παραγωγής και στην παρακολούθηση σε πραγματικό χρόνο του δικτύου [20]. Τέτοιου είδους προβλέψεις χρησιμοποιούνται στην ενδοημερήσια αγορά και στην αγορά εξισορρόπησης.

- Βραχυπρόθεσμη πρόβλεψη (short-term): Αφορά χρονικό ορίζοντα μίας ώρας έως μίας εβδομάδας. Αποτελεί την κρισιμότερη και πιο συχνή κατηγορία Φ/Β προβλέψεων, καθώς βρίσκει ευρεία εφαρμογή στον ενεργειακό κλάδο. Αντίστοιχα με την υπέρ-βραχυπρόθεσμη πρόβλεψη, χρησιμοποιούνται κυρίως στατιστικές μέθοδοι και μοντέλα ML, καθώς η πρόσφατη μεταβολή της χρονοσειράς ισχύος επηρεάζει καθοριστικά την πορεία αυτής το αμέσως επόμενο χρονικό διάστημα. Ο κρίσιμος χαρακτήρας της βραχυπρόθεσμης πρόβλεψης οφείλεται στην αναγκαιότητά της όσον αφορά την ενδεχόμενη άμεση εισαγωγή θερμικών μονάδων για την ικανοποίηση της αναμενόμενης ζήτησης, τον προγραμματισμό έκτακτων συντηρήσεων του εμπλεκόμενου εξοπλισμού και, ευρύτερα, για την εντός ορίων λειτουργία των δικτύων διανομής και μεταφοράς [21]. Παράλληλα, η βραχυπρόθεσμη πρόβλεψη χρησιμοποιείται στην αγορά επόμενης ημέρας.

2.6.2 Μεσοπρόθεσμη πρόβλεψη

Η μεσοπρόθεσμη (medium-term) πρόβλεψη αναφέρεται σε χρονική περίοδο μίας εβδομάδας έως ενός έτους. Κατά τη διαδικασία παραγωγής των προβλέψεων αυτών, προτιμώνται πολύπλοκες φυσικές μέθοδοι, μοντέλα ML, καθώς και υβριδικά μοντέλα. Το συγκεκριμένο είδος χρησιμοποιείται για τον ενεργειακό προγραμματισμό του δικτύου, για την κατάρτιση τακτικής συντήρησης των μονάδων παραγωγής και για την πρόληψη έναντι έντονων καιρικών και ενεργειακών φαινομένων.


2.6.3 Μακροπρόθεσμη πρόβλεψη

Στην κατηγορία αυτή εντάσσονται όλες οι προβλέψεις οι οποίες διενεργούνται για ένα χρονικό διάστημα πέραν του ενός έτους. Σε αυτή την περίπτωση, σχεδόν καθολική εφαρμογή βρίσκουν οι φυσικές μέθοδοι, καθώς οι ιστορικές χρονοσειρές των στατιστικών μοντέλων και των μοντέλων ML συγκεντρώνουν μειωμένη αξία για τόσο μεγάλα χρονικά διαστήματα [22]. Η μακροπρόθεσμη πρόβλεψη αποτελεί στρατηγικής σημασίας παράγοντα για τον μακροπρόθεσμο σχεδιασμό του συνολικού ενεργειακού συστήματος, το οποίο μπορεί να περιλαμβάνει νέες κατασκευές υποσταθμών, μονάδων παραγωγής και αναβάθμιση του ηλεκτρικού δικτύου. Επιπλέον, αποτελεί απαραίτητο προαπαιτούμενο για νέες επενδύσεις στον ενεργειακό κλάδο, για τη διαμόρφωση της εθνικής πολιτικής στον κλάδο της ενέργειας και για τη χάραξη κοινής στρατηγικής σε διεθνές ή παγκόσμιο επίπεδο για τα επόμενα έτη ή και δεκαετίες. Ταυτόχρονα, χρησιμοποιείται στην ενεργειακή χρηματοπιστωτική αγορά για συμφωνίες προμήθειας ενεργειακών προϊόντων μεταξύ παραγωγών και προμηθευτών ή καταναλωτών βιομηχανικής κλίμακας.

ΒΑΘΙΑ ΜΑΘΗΣΗ, ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΔΙΚΤΥΑ LSTM

3.1 ΓΕΝΙΚΑ

Η τεχνητή νοημοσύνη έχει αδιαμφισβήτητα κατακλείσει την καθημερινότητα των ανθρώπων σε όλο και περισσότερους τομείς, συνεπικουρούμενη από την άνοδο της πληροφορικής που έχει ήδη συντελεστεί τα τελευταία χρόνια. Σε αυτή την κατεύθυνση, η μηχανική μάθηση – βασική υποκατηγορία της τεχνητής νοημοσύνης – έχει επεκταθεί και στον ενεργειακό τομέα, καθώς αξιοποιείται όλο και περισσότερο για θέματα ταξινόμησης, προβλέψεων, και όχι μόνο. Όπως αναλύθηκε στην Ενότητα 2.5, τα μοντέλα μηχανικής μάθησης παρουσιάζουν εξαιρετικές δυνατότητες διαχείρισης σύνθετων και μη γραμμικών φαινομένων, διακρίνοντας δυσνόητα μοτίβα μεταξύ εισόδου και εξόδου, όπως στην περίπτωση της Φ/Β πρόβλεψης. Γενικότερα, ως μηχανική μάθηση (ML) ορίζεται μια διαδικασία που προσομοιάζοντας την ανθρώπινη συμπεριφορά, βελτιστοποιεί υπολογιστικούς αλγόριθμους μέσω της διαδικασίας της εκπαίδευσης [23]. Οι αλγόριθμοι αυτοί χρησιμοποιούν σύνολα δεδομένων εισόδου – εξόδου και μέσω αρκετών επαναλήψεων και τροποποιήσεων εκπαιδεύουν το μοντέλο, ώστε να λαμβάνει ανεξάρτητες αποφάσεις βελτιστοποίησης. Η συνολική διαδικασία αναπροσαρμογών έχει ως στόχο την επίτευξη μέγιστης δυνατής ακρίβειας σε κάθε επανάληψη της εκπαίδευσης. Στο Σχήμα 3.1 παρουσιάζονται τα κυριότερα υποσύνολα του κλάδου της τεχνητής νοημοσύνης, τα οποία θα αναλυθούν περαιτέρω στις επόμενες ενότητες.



Σχήμα 3.1 : Κυριότερες υποκατηγορίες τεχνητής νοημοσύνης


3.2 ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Τα νευρωνικά δίκτυα, ή πιο συγκεκριμένα τα τεχνητά νευρωνικά δίκτυα (ANN), είναι υπολογιστικά πληροφοριακά συστήματα επεξεργασίας, τα οποία χρησιμοποιούνται ευρέως για μη γραμμικά και σύνθετα προβλήματα. Σε αυτές τις περιπτώσεις η μαθηματική μοντελοποίηση είναι σχεδόν αδύνατη, ενώ είναι σύνθητες η σχέση εισόδου και εξόδου να είναι απροσδιόριστη ή δύσκολα υπολογίσιμη [24]. Τα ANN έχουν το πλεονέκτημα να συσχετίζουν ανεξάρτητα τα δεδομένα εισόδου και εξόδου χωρίς να υπεισέρχεται η ανθρώπινη μεροληψία, όπως συμβαίνει στις φυσικές μεθόδους. Ο λόγος που χρησιμοποιείται ο όρος νευρωνικά είναι διότι η βασική αρχιτεκτονική λειτουργίας των ANN προσομοιάζει σε μεγάλο βαθμό στο ανθρώπινο νευρικό σύστημα [25]. Ένα ANN αποτελείται από νευρώνες τοποθετημένους σε παράλληλα επίπεδα και συνδεδεμένους μεταξύ τους με συνάψεις, οι οποίες αντιπροσωπεύουν βάρη και καθορίζουν την ευρύτερη λειτουργία του. Στο Σχήμα 3.2 απεικονίζεται το μαθηματικό μοντέλο ενός νευρώνα και η αλληλεπίδρασή του με τους υπόλοιπους νευρώνες. Κάθε νευρώνας λαμβάνει σήματα εισόδου είτε από άλλους νευρώνες (x_1, x_2, \dots, x_n), είτε με έξωθεν επιρροή (πόλωση b) και παράγει μία έξοδο y . Σε κάθε είσοδο x_1, x_2, \dots, x_n αντιστοιχεί ένα βάρος w_1, w_2, \dots, w_n . Η αθροιστική είσοδος z του νευρώνα του Σχήματος 3.2 προκύπτει ως εξής:

$$z = w_1 \cdot x_1 + w_2 \cdot x_2 + \dots + w_n \cdot x_n + b \quad (3.1)$$

Αντίστοιχα, η έξοδος y του νευρώνα του Σχήματος 3.2, βάσει της συνάρτησης ενεργοποίησης f ισούται με:

$$y = f(z) \quad (3.2)$$



Σχήμα 3.2 : Μαθηματικό μοντέλο νευρώνα ANN

Η συνάρτηση ενεργοποίησης (activation function) αποτελεί καίρια παράμετρο για το ANN καθώς προσδίδει στους νευρώνες την ικανότητα να διαχειρίζονται μη γραμμικά προβλήματα, απεικονίζοντας τα δεδομένα στις σωστές διαστάσεις [26]. Χαρακτηριστικά παραδείγματα ευρέως χρησιμοποιούμενων συναρτήσεων ενεργοποίησης είναι τα ακόλουθα:

- Σιγμοειδής (Σχήμα 3.3):


$$f(z) = \frac{1}{1 + e^{-z}} \quad (3.3)$$

- Υπερβολική εφαπτομένη (Σχήμα 3.4):


$$f(z) = \frac{1 - e^{-2z}}{1 + e^{-2z}} \quad (3.4)$$

- ReLU (Σχήμα 3.5):


$$f(z) = \max(0, z) \quad (3.5)$$



Σχήμα 3.3 : Η σιγμοειδής συνάρτηση ενεργοποίησης



Σχήμα 3.4 : Η συνάρτηση ενεργοποίησης υπερβολική εφαπτομένη



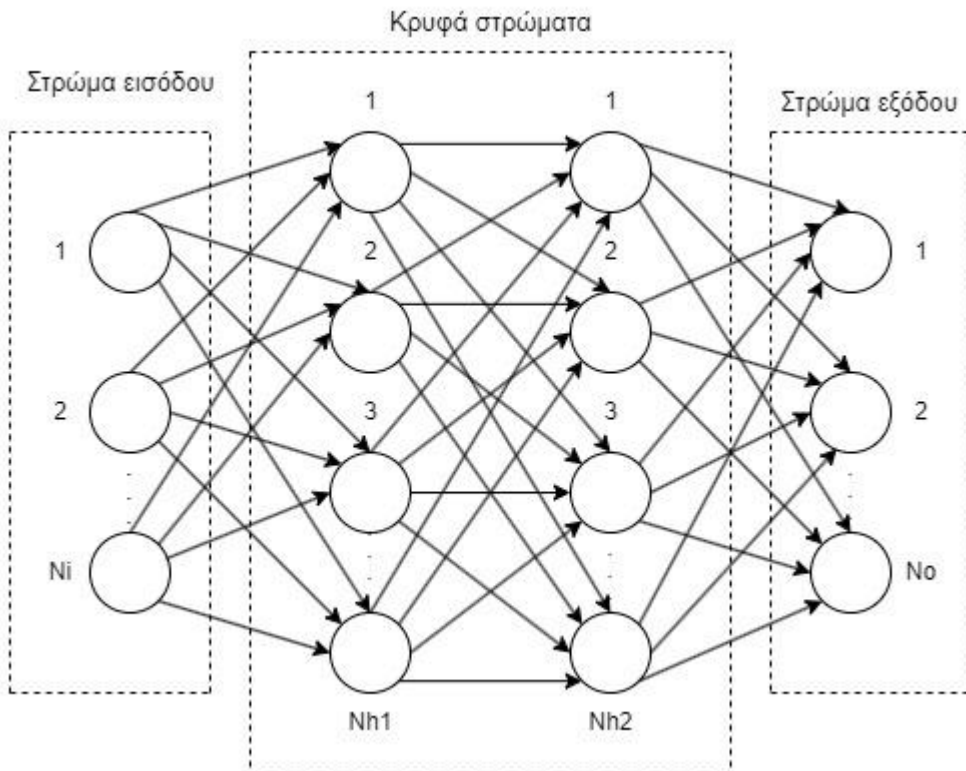
Σχήμα 3.5 : Η συνάρτηση ενεργοποίησης ReLU

Ένα ANN φέρει συνήθως πολυεπίπεδη οργάνωση, συνδυάζει δηλαδή τόσο σειριακή όσο και παράλληλη διάταξη νευρώνων, ώστε να μπορεί να αποτυπώσει αποτελεσματικά διαφορετικές εισόδους και σύνθετες συσχετίσεις μεταβλητών. Όταν πολλαπλοί νευρώνες συνδέονται παράλληλα διαμορφώνουν ένα στρώμα (layer), τα οποία στρώματα με τη σειρά τους διακρίνονται σε τρεις βασικές κατηγορίες. Αρχικά υπάρχει το στρώμα εισόδου, ενδιάμεσα παρεμβάλλονται ένα ή περισσότερα κρυφά στρώματα, τα οποία καταλήγουν στο τελικό στρώμα εξόδου [27]. Για να χαρακτηριστεί μια υπολογιστική δομή ως ANN πρέπει να δομείται σε μορφή κατευθυνόμενου γράφου και για τον λόγο αυτό στη διεθνή βιβλιογραφία ο όρος νευρώνας (neuron) αντικαθίσταται συχνά από τον όρο κόμβος (node) [28]. Τα δεδομένα που τροφοδοτούν ένα ANN εισάγονται στο στρώμα εισόδου το οποίο χαρακτηρίζεται παθητικό, καθώς η κύρια λειτουργία του είναι να μεταφέρει τις τιμές των δεδομένων στα κρυφά στρώματα μέσω των αντίστοιχων βαρών. Τα κρυφά στρώματα και το στρώμα εξόδου υπηρετούν τον υπολογιστικό χαρακτήρα της δομής και μέσω αυτών επιτελείται η εκπαίδευση του ANN. Η έξοδος κάθε κόμβου εξαρτάται αποκλειστικά από την πληροφορία η οποία είτε εισέρχεται στον κόμβο μέσω των συνάψεων, είτε είναι εσωτερικά αποθηκευμένη. Κάθε νευρώνας ξεχωριστά δεν φέρει ιδιαίτερη υπολογιστική δύναμη αλλά παράγει μία απλή βαθμωτή τιμή εξόδου, η οποία προέρχεται από μία μη γραμμική συνάρτηση των εισόδων αυτού [29]. Επομένως, η εξαιρετική απόδοση των ANN ακόμη και σε πολύ απαιτητικά φαινόμενα οφείλεται στη συνολική αρχιτεκτονική του και βασίζεται στο σύνολο των εσωτερικών συνάψεων και λειτουργιών.


Τα ANN χωρίζονται σε δύο βασικές κατηγορίες ανάλογα με την κατεύθυνση της ροής της πληροφορίας εντός της δομής [30]:

- Νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης (Feed-Forward Neural Network / FFNN): Στα FFNN (Σχήμα 3.6) η πληροφορία μεταφέρεται αποκλειστικά προς μία κατεύθυνση και συγκεκριμένα από το στρώμα εισόδου προς το στρώμα εξόδου.

- Αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Network / RNN): Στα RNN (Σχήμα 3.7) η πληροφορία μπορεί να μεταφέρεται αμφίδρομα, καθώς η έξοδος ενός κόμβου αποτελεί εκ νέου είσοδο για τον ίδιο κόμβο.



Σχήμα 3.6 : Νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης δύο κρυφών στρωμάτων



Σχήμα 3.7 : Αναδρομικό νευρωνικό δίκτυο δύο κρυφών στρωμάτων

Για το FFNN του Σχήματος 3.6, η έξοδος του νευρώνα Y_i του στρώματος εξόδου υπολογίζεται από την ακόλουθη μαθηματική εξίσωση:

$$Y_i = f_o \left(\sum_{j=1}^{N_{h2}} W_{oj} \cdot f_2 \left(\sum_{k=1}^{N_{h1}} W_{2kj} \cdot f_1 \left(\sum_{m=1}^{N_i} W_{1mk} \cdot X_m + b_{1k} \right) + b_{2j} \right) + b_o \right) \quad (3.6)$$

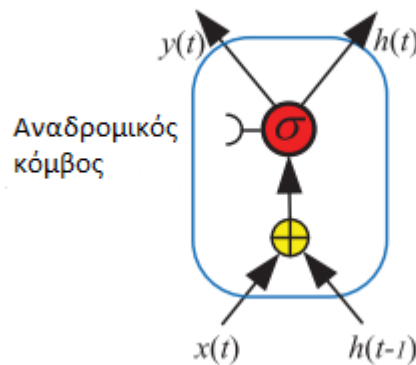
για $i = 1, 2, \dots, N_o$, όπου f_o, f_1, f_2 οι συναρτήσεις ενεργοποίησης του στρώματος εξόδου, του πρώτου κρυφού στρώματος και του δεύτερου κρυφού στρώματος, αντίστοιχα, W_{1mk} το βάρος της σύναψης μεταξύ του νευρώνα m του στρώματος εισόδου και του νευρώνα k του πρώτου κρυφού στρώματος, W_{2kj} το βάρος της σύναψης μεταξύ του νευρώνα k και του νευρώνα j του πρώτου και του δεύτερου κρυφού στρώματος, αντίστοιχα, και W_{oj} το βάρος της σύναψης μεταξύ του νευρώνα j του δεύτερου κρυφού στρώματος και του νευρώνα o του στρώματος εξόδου. Τα b_o, b_{1k}, b_{2j} αφορούν τις πόλωσης του στρώματος εξόδου, του πρώτου και του δεύτερου κρυφού στρώματος, αντίστοιχα, ενώ τα N_i, N_o, N_{h1}, N_{h2} αναφέρονται στον αριθμό των νευρώνων των στρωμάτων εισόδου, εξόδου, πρώτου και δεύτερου κρυφού στρώματος, αντίστοιχα.

Τα κρυφά στρώματα ενός RNN (Σχήμα 3.7) αποτελούνται από αναδρομικούς νευρώνες (recurrent cells) με κυκλική σύνδεση. Η τρέχουσα κατάσταση ενός κόμβου δηλαδή, μπορεί να επηρεαστεί όχι μόνο νευρώνες του προηγούμενου στρώματος αλλά και από την προηγούμενη κατάσταση του ίδιου κόμβου μέσω ανατροφοδότησης [31]. Οι μαθηματικές εκφράσεις του αναδρομικού νευρώνα του Σχήματος 3.8 είναι οι ακόλουθες:

$$h(t) = \sigma(W_h \cdot h(t-1) + W_x \cdot x(t) + b) \quad (3.7)$$

$$y(t) = h(t) \quad (3.8)$$

όπου $x(t)$ η είσοδος από το προηγούμενο επίπεδο, $h(t)$ η αναδρομική πληροφορία, $y(t)$ η έξοδος της τρέχουσας κατάστασης, $h(t-1)$ η πληροφορία της προηγούμενης κατάστασης, b η πόλωση του νευρώνα και W_h, W_x τα βάρη των συνάψεων της αναδρομικής πληροφορίας και της εισόδου, αντίστοιχα.



Σχήμα 3.8 : Νευρώνας αναδρομικού νευρωνικού δικτύου

Όπως έχει ήδη αναφερθεί, η βασική χρησιμότητα των ANN έγκειται στην ικανότητα τους να διαχειρίζονται σύνθετα μη γραμμικά δεδομένα. Προκειμένου να αποτυπωθούν τα συγκεκριμένα μοτίβα μεταξύ των δεδομένων εισόδου και εξόδου, πρέπει να διεξαχθεί η απαραίτητη εκπαίδευση, άρα αυτή η παράμετρος διαφοροποιεί μεταξύ τους τα ANN. Επομένως, τα ANN πέρα από την κατεύθυνση της ροής της πληροφορίας, ταξινομούνται σε δύο κατηγορίες ανάλογα με τη μέθοδο εκπαίδευσής τους. Οι κατηγορίες αυτές είναι οι εξής [32]:

- **Επιτηρούμενη εκπαίδευση (supervised learning):** Κατά την επιτηρούμενη εκπαίδευση παρέχεται στο ANN ένα σύνολο δεδομένων εκπαίδευσης, το οποίο περιέχει τις μεταβλητές εισόδου και εξόδου ή αλλιώς μεταβλητές στόχους (target variables). Σε κάθε επανάληψη τα βάρη συνάψεων προσαρμόζονται με τέτοιο τρόπο, ώστε να ελαχιστοποιείται το σφάλμα μεταξύ εξόδου και μεταβλητών στόχων. Στις περισσότερες περιπτώσεις, η επιτηρούμενη εκπαίδευση απαιτεί περισσότερο χρόνο εκμάθησης εξαιτίας του αναγκαίου υπολογισμού σφάλματος μετά από κάθε παραγόμενη έξοδο. Αυτό το είδος εκπαίδευσης χρησιμοποιείται ευρέως σε προβλήματα όπως η ταξινόμηση, η πρόβλεψη και η ρομποτική.
- **Μη επιτηρούμενη εκπαίδευση (unsupervised learning):** Στη μη επιτηρούμενη εκπαίδευση το ANN τροφοδοτείται μόνο με δεδομένα εισόδου, χωρίς να παρέχεται κάποια αναμενόμενη έξοδος, άρα και χωρίς τον υπολογισμό κάποιου ενδιάμεσου σφάλματος. Σε αυτή την κατηγορία, δεν υπάρχει συγκεκριμένη κατεύθυνση για τον αλγόριθμο εκμάθησης, γεγονός που του επιτρέπει να αναγνωρίσει μοτίβα τα οποία ενδεχομένως να έχει αγνοήσει [33]. Η μη επιτηρούμενη εκπαίδευση βρίσκει εφαρμογή σε προβλήματα ομαδοποίησης, αναγνώρισης ομιλίας και κατάτμησης. Γενικότερα, δεν είναι εφικτό να γίνει πρότερα γνωστό ποια μέθοδος εκπαίδευσης θα αποδώσει με μεγαλύτερη ακρίβεια, κάτι το οποίο εξαρτάται από τη φύση του προβλήματος και τα δεδομένα εισόδου. Στην πλειονότητά τους τα ANN χρησιμοποιούν επιτηρούμενη εκπαίδευση.

3.3 ΒΑΘΙΑ ΜΑΘΗΣΗ

Η βαθιά μάθηση (Deep Learning / DL) αποτελεί ένα υποσύνολο των νευρωνικών δικτύων και του ML, όπως γίνεται εμφανές στο Σχήμα 3.1, εστιάζοντας στη δημιουργία πολύπλοκων ANN ικανά να λαμβάνουν αποφάσεις αλγοριθμικά, ώστε να αποτυπώνουν δυσνόητα μοτίβα (data-driven) [34]. Τα μοντέλα DL είναι κατάλληλα για πιο σύνθετα μη γραμμικά φαινόμενα, τα οποία πιθανώς να έχουν μεγάλα σύνολα δεδομένων (big data) και χρησιμοποιούν ANN εξαιρετικά πολυπληθή σε κρυφά στρώματα. Τα πολλαπλά κρυφά στρώματα δίνουν τη δυνατότητα στα μοντέλα DL να αναπαριστούν ιεραρχικά τα δεδομένα μέσω μετασχηματισμών, όπου τα χαρακτηριστικά υψηλότερων επιπέδων προέρχονται από χαρακτηριστικά χαμηλότερων επιπέδων [35]. Ένα ακόμη σημαντικό πλεονέκτημα των μοντέλων DL αφορά τη μικρή προ-επεξεργασία που χρειάζονται τα δεδομένα εισόδου. Εξαιτίας των δεκάδων ή και εκατοντάδων κρυφών στρωμάτων ενός βαθύς νευρωνικού δικτύου (Deep Neural Network / DNN), η υπολογιστική διαδικασία μπορεί να ανταπεξέλθει ικανοποιητικά ακόμα και σε περιπτώσεις δυσνόητων δεδομένων. Οι βασικότερες κατηγορίες DNN παρουσιάζονται στη συνέχεια [36]:

- Πολυστρωματικός ταξινομητής (MLP): Αποτελεί τη βασικότερη αρχιτεκτονική οργάνωσης ενός DNN και αφορά ένα FFNN με πολλά κρυφά στρώματα.
- Συνελικτικό νευρωνικό δίκτυο (CNN): Το CNN αναφέρεται σε ένα DNN το οποίο αποτελείται κατά σειρά από το στρώμα εισόδου, τα στρώματα συνέλιξης ή αλλιώς φίλτρα, τα στρώματα συγκέντρωσης και το στρώμα εξόδου. Τα στρώματα συνέλιξης περιέχουν πολυδιάστατους πίνακες με τα βάρη που πρέπει να υπολογιστούν και εκπαιδεύονται για να αναγνωρίζουν συγκεκριμένα χαρακτηριστικά [37]. Τα φίλτρα αυτά υλοποιούν τη λειτουργία της συνέλιξης μεταξύ των βαρών, ενώ τα στρώματα συγκέντρωσης μειώνουν τις διαστάσεις των στρωμάτων συνέλιξης συνδυάζοντας τις εξόδους των προηγούμενων στρωμάτων προς τους επόμενους νευρώνες. Τα CNN χρησιμοποιούνται συχνά για ταξινόμηση και ομαδοποίηση εικόνων, καθώς και για τον εντοπισμό αντικειμένων σε μια εικόνα.

Το βασικό πλεονέκτημα των DNN είναι η δυνατότητα να αναγνωρίζουν σύνθετες μη γραμμικές σχέσεις μεταξύ δεδομένων, επιτυγχάνοντας εκεί που αποτυγχάνουν τα ML. Για να το καταφέρουν, τα DNN φέρουν δύο βασικές παραμέτρους υπολογισμού, οι οποίες είναι οι ακόλουθες:

- Αντικειμενική συνάρτηση: Όπως αναφέρθηκε στην Ενότητα 3.2, κατά τη διάρκεια της επιτηρούμενης εκπαίδευσης – κυρίαρχη μέθοδος τόσο στα ANN όσο και στα DNN – το δίκτυο τροφοδοτείται τόσο με δεδομένα εισόδου όσο και με τις αντίστοιχες επιθυμητές εξόδους. Κάθε έξοδος συγκρίνεται με την αντίστοιχη μεταβλητή στόχο και υπολογίζεται η τιμή της αντικειμενικής συνάρτησης. Απώτερος σκοπός είναι είτε η μεγιστοποίηση είτε η ελαχιστοποίηση της αντικειμενικής συνάρτησης, ανάλογα με τη φύση του προβλήματος. Στην πλειονότητα των περιπτώσεων, ως αντικειμενική συνάρτηση επιλέγεται κάποια συνάρτηση σφάλματος, η οποία πρέπει να ελαχιστοποιηθεί. Μετά από κάθε επανάληψη ποσοτικοποιείται η διαφορά μεταξύ πραγματικής και αναμενόμενης εξόδου, ώστε στην επόμενη επανάληψη να πραγματοποιηθεί η κατάλληλη προσαρμογή των εμπλεκόμενων πολώσεων και βαρών των συνάψεων, σε μία προσπάθεια να μειωθεί η παρατηρούμενη διαφορά [38]. Μία συχνά χρησιμοποιούμενη συνάρτηση σφάλματος είναι το μέσο τετραγωνικό σφάλμα (Mean Squared Error / MSE), η οποία περιγράφεται στην εξίσωση (3.9) για N παρατηρήσεις:

$$MSE = \frac{1}{N} \cdot \sum_{i=1}^N [y_i - p_i]^2 \quad (3.9)$$

όπου y_i και p_i η τιμή παρατήρησης και πρόβλεψης του i -οστού δείγματος, αντίστοιχα.

- Αλγόριθμοι βελτιστοποίησης: Ο τρόπος με τον οποίο μεταβάλλονται τα βάρη των συνάψεων και οι πολώσεις μετά από κάθε επανάληψη κατά τη βελτιστοποίηση μιας αντικειμενικής συνάρτησης εξαρτάται από τον χρησιμοποιούμενο αλγόριθμο βελτιστοποίησης. Ο πιο συχνά χρησιμοποιούμενος αλγόριθμός βελτιστοποίησης είναι ο αλγόριθμος οπίσθιας διάδοσης σφάλματος. Ένα ANN το οποίο εκπαιδεύεται με τον αλγόριθμο οπίσθιας διάδοσης ονομάζεται Back-Propagation Neural Network (BPNN). Στα

BPNN, η παραγόμενη έξοδος συγκρίνεται με μία δοσμένη πραγματική τιμή εξόδου και η απόκλισή τους δημιουργεί ένα σήμα σφάλματος. Στη συνέχεια, το σήμα σφάλματος διαδίδεται αντίστροφα περνώντας από τα κρυφά στρώματα με κατεύθυνση προς το στρώμα εισόδου. Κατά την πορεία αυτή, μεταβάλλονται τα βάρη συνάψεων μεταξύ των νευρώνων ώστε να προσεγγιστεί ακριβέστερα η αναμενόμενη έξοδος [39]. Η διαδικασία αυτή επαναλαμβάνεται αρκετές φορές μέχρι να προσεγγιστεί επαρκώς η αναμενόμενη έξοδος, σε μία προσπάθεια να ελαχιστοποιηθεί η συνάρτηση σφάλματος. Οι παράμετροι του DNN αναπροσαρμόζονται με βάση τη μέθοδο μείωσης της κλίσης (gradient descent), μέχρι να επιτευχθεί η επιθυμητή ακρίβεια [27]. Σε κάθε επανάληψη τα βάρη συνάψεων και οι πλώσεις υπολογίζονται εκ νέου με βάση τις ακόλουθες σχέσεις:

$$\Delta w_{pj,qk}(n+1) = lr \cdot \delta_{qk} \cdot OUT_{pj} + m \cdot \Delta w_{pj,qk}(n) \quad (3.10)$$

$$w_{pj,qk}(n+1) = w_{pj,qk}(n) + \Delta w_{pj,qk}(n+1) \quad (3.11)$$

όπου n ο αριθμός της τρέχουσας επανάληψης, $w_{pj,qk}$ η τιμή του βάρους σύναψης μεταξύ του νευρώνα p του στρώματος j και του νευρώνα q του στρώματος k , δ_{qk} η τιμή του συντελεστή δ για τον νευρώνα q του στρώματος k , OUT_{pj} η έξοδος του νευρώνα p του στρώματος j , lr ο ρυθμός μάθησης και m η ορμή (momentum). Η μεταβλητή δ_{qk} που υπεισέρχεται στην εξίσωση (3.10) υπολογίζεται με τον ακόλουθο τρόπο:

- Για βάρος σύναψης μεταξύ νευρώνων κρυφού στρώματος και στρώματος εξόδου:

$$\delta_{qk} = \frac{2}{N} \cdot OUT_{qk} \cdot (1 - OUT_{qk}) \cdot (OUT_{actual\ qk} - OUT_{qk}) \quad (3.12)$$

όπου OUT_{qk} η έξοδος του νευρώνα q του στρώματος εξόδου k , $OUT_{actual\ qk}$ η αναμενόμενη έξοδος του νευρώνα q του στρώματος εξόδου k και N ο αριθμός των επαναλήψεων του συνόλου εκπαίδευσης.

- Για βάρος σύναψης μεταξύ οποιονδήποτε νευρώνων πλην αυτών του στρώματος εξόδου:

$$\delta_{pj} = OUT_{pj}(1 - OUT_{pj}) \cdot \sum_{q=1}^{N_o} \delta_{qk} \cdot w_{pj,qk} \quad (3.13)$$

όπου OUT_{pj} η έξοδος του νευρώνα p του στρώματος j , $w_{pj,qk}$ το βάρος σύναψης μεταξύ του νευρώνα p του στρώματος j και του νευρώνα q του στρώματος k και N_o ο αριθμός νευρώνων του εξωτερικού στρώματος. Ο συντελεστής lr της εξίσωσης (3.10) αναφέρεται στον ρυθμό μάθησης, ο οποίος ελέγχει κατά πόσο μπορούν τα υπολογιζόμενα σφάλματα να αλλάξουν τα βάρη συνάψεων και παίρνει τιμές μεταξύ 0,01 και 1.

Αν και η μέθοδος μείωσης της κλίσης είναι εύκολη στην εφαρμογή της, παρουσιάζει ορισμένα μειονεκτήματα και για αυτόν τον λόγο σε αρκετές εφαρμογές χρησιμοποιείται μία παραλλαγή της, η στοχαστική μείωση της κλίσης (Stochastic Gradient Descent / SGD), η οποία προτάθηκε από τους Robbins και Monro (1951) [40]. Κατά την απλή μείωση της κλίσης, είναι πιθανό ο αλγόριθμος να «εγκλωβιστεί» σε κάποιο τοπικό ακρότατο της αντικειμενικής

συνάρτησης από το οποίο δεν μπορεί να διαφύγει όσες επαναλήψεις και να εκτελεστούν [41]. Αυτό συμβαίνει διότι στο σημείο αυτό ο αλγόριθμος υπολογίζει μηδενική κλίση, άρα θεωρεί λανθασμένα πως βρήκε την βέλτιστη λύση, ενώ στην πραγματικότητα υπάρχει διαφορετικό σημείο όπου η αντικειμενική συνάρτηση εμφανίζει ολικό ακρότατο. Αντίθετα, η μέθοδος SGD εισάγει μία τυχαιότητα στην αναπροσαρμογή των βαρών, ώστε σε κάθε επανάληψη η κλίση να υπολογίζεται από διαφορετικό σημείο, ελαχιστοποιώντας έτσι την πιθανότητα «εγκλωβισμού» [42]. Σε κάθε επανάληψη n , τα βάρη συνάψεων μεταβάλλονται με βάση τη σχέση:

$$w_{n+1} = w_n - lr \cdot H(w_n) \quad (3.14)$$

όπου $H(w)$ είναι μία τυχαία συνάρτηση, η προσδοκία της οποίας είναι η κλίση της αντικειμενικής συνάρτησης $J(w)$, για την οποία ισχύει:

$$E(H(w)) = \nabla_w J(w) \quad (3.15)$$

Σε περιπτώσεις σύνθετων DNN και δεδομένων εισόδου που εμφανίζουν σημαντικό θόρυβο, είναι πιθανό η μέθοδος SGD να παρουσιάσει μειωμένη αποτελεσματικότητα. Ειδικά αν ο θόρυβος ακολουθεί κατανομή «βαριάς ουράς» (heavy-tailed distribution), η απόδοση της μεθόδου SGD είναι περιορισμένη [43]. Σε αυτή την κατεύθυνση βρίσκει ευρεία εφαρμογή ο αλγόριθμος βελτιστοποίησης Adaptive Moment Estimation (Adam), ο οποίος προτάθηκε από τους Kingma και Ba (2014) [44]. Ο Adam εφαρμόζεται σε παραγωγίσιμες αντικειμενικές συναρτήσεις με θόρυβο και για την προσαρμογή των βαρών χρησιμοποιεί τόσο τη μέση τιμή όσο και τη μη κεντροποιημένη διακύμανση. Υπολογίζει δηλαδή τον εκθετικό μέσο όρο της κλίσης και της τετραγωνικής κλίσης, και μέσω των παραμέτρων β_1 , β_2 ενημερώνει τα βάρη των συνάψεων, όπως περιγράφεται στις εξισώσεις (3.16) – (3.20).

$$m_t = \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot \left[\frac{\partial L}{\partial w_t} \right] \quad (3.16)$$

$$u_t = \beta_2 \cdot u_{t-1} + (1 - \beta_2) \cdot \left[\frac{\partial L}{\partial w_t} \right]^2 \quad (3.17)$$

όπου m_t , m_{t-1} το άθροισμα των κλίσεων τη χρονική στιγμή t και $t - 1$ αντίστοιχα, w_t το βάρος σύναψης τη χρονική στιγμή t , β_1 , β_2 οι ρυθμοί αποσύνθεσης του μέσου όρου των κλίσεων (συνήθως 0,9 και 0,999 αντίστοιχα), u_t , u_{t-1} το άθροισμα τετραγώνων της κλίσης τη χρονική στιγμή t και $t-1$ αντίστοιχα και ∂L η μερική παράγωγος της συνάρτησης σφάλματος. Επειδή τα m_t , u_t αρχικοποιούνται ίσα με 0, εμφανίζουν μία τάση να πολώνονται προς την τιμή αυτή. Επομένως, σε κάθε επανάληψη τα m_t , u_t , w_t προσαρμόζονται με βάση τον ρυθμό εκμάθησης α και τη θετική σταθερά ε ως εξής:

$$\widehat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (3.18)$$

$$\widehat{u}_t = \frac{u_t}{1 - \beta_2^t} \quad (3.19)$$

$$w_{t+1} = w_t - \widehat{m}_t \cdot \left(\frac{\alpha}{\sqrt{\widehat{u}_t + \varepsilon}} \right) \quad (3.20)$$

Με βάση τα προηγούμενα, ο αλγόριθμος Adam προτιμάται τόσο από την απλή μέθοδο μείωσης της κλίσης όσο και από τον SGD, καθώς έχει τη δυνατότητα να μην απορροφά τον θόρυβο από το σύνολο δεδομένων εισόδου, είναι αποδοτικός τόσο σε μη στάσιμες αντικειμενικές συναρτήσεις όσο και σε αραιές κλίσεις και έχει χαμηλές απαιτήσεις σε μνήμη [45]. Σε πολλά προβλήματα του πραγματικού κόσμου, είναι πιθανό να απαιτείται η ταυτόχρονη βελτιστοποίηση δύο ή και παραπάνω αντικειμενικών συναρτήσεων (multi-objective optimization), επομένως δεν μπορούν να εφαρμοστούν οι προαναφερθέντες αλγόριθμοι, αλλά απαιτούνται αλγόριθμοι πολυκριτηριακής βελτιστοποίησης [46].

3.4 ΔΙΚΤΥΑ LSTM

Τα δίκτυα μακράς βραχύχρονης μνήμης (LSTM) αποτελούν μία υποκατηγορία – εξέλιξη των RNN, όπως αυτά παρουσιάστηκαν στην Ενότητα 3.3, και προτάθηκαν από τους Hochreiter και Schmidhuber (1997) [47]. Τα LSTM, όπως και τα RNN, απαρτίζονται από ανατροφοδοτούμενους νευρώνες, οι οποίοι συνήθως ονομάζονται κελιά (cells). Ο κυριότερος λόγος για τον οποίο τα LSTM έχουν κυριαρχήσει μεταξύ των RNN αφορά τη δυνατότητά τους να αναγνωρίζουν και να διαχειρίζονται μακροχρόνιες συσχετίσεις (long-term dependencies) μεταξύ των δεδομένων κατά τη διαδικασία της εκπαίδευσης [48].

3.4.1 Τρόπος λειτουργίας LSTM

Η αρχιτεκτονική ενός LSTM δεν διαφέρει σημαντικά από αυτή ενός RNN, διαθέτει όμως ορισμένα επιμέρους τμήματα που το καθιστούν πιο αποτελεσματικό και αποδοτικό. Ανάλογα με τη φύση του εξεταζόμενου προβλήματος, δύναται να χρησιμοποιηθεί κάποια από τις ακόλουθες τρεις κατηγορίες LSTM [49]:

- LSTM χωρίς επιλεκτική πύλη (forget gate): Η συγκεκριμένη αρχιτεκτονική φέρει για κάθε κελί μόνο δύο πύλες, τις πύλες εισόδου και εξόδου. Όπως είναι αναμενόμενο, τόσο στα RNN όσο και σε όλες τις δομές LSTM, το κελί (κόμβος) είναι ανατροφοδοτούμενο (recurrent cell). Οι μαθηματικές εκφράσεις του Σχήματος 3.9 αναπτύσσονται στη συνέχεια.

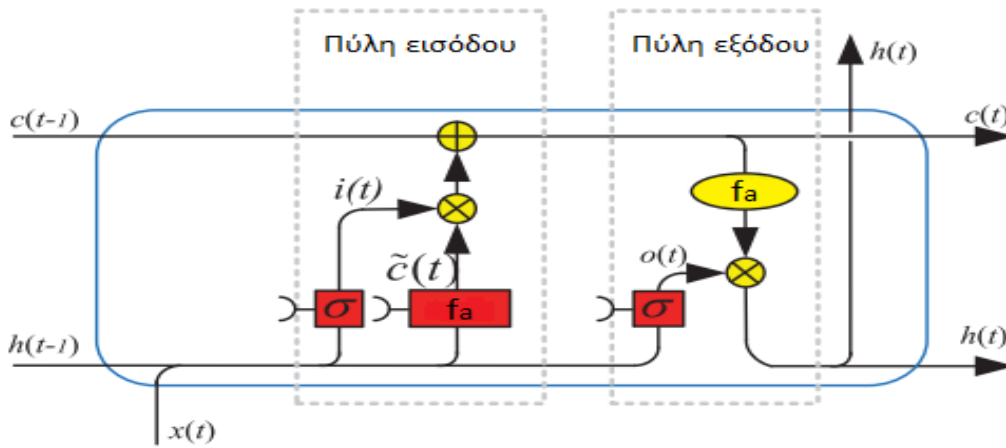
$$i_t = \sigma(W_{ih} \cdot h_{t-1} + W_{ix} \cdot x_t + b_i) \quad (3.21)$$

$$\tilde{c}_t = f_a(W_{\tilde{c}h} \cdot h_t + W_{\tilde{c}x} \cdot x_t + b_{\tilde{c}}) \quad (3.22)$$

$$c_t = c_{t-1} + i_t \cdot \tilde{c}_t \quad (3.23)$$

$$o_t = \sigma(W_{oh} \cdot h_{t-1} + W_{ox} \cdot x_t + b_o) \quad (3.24)$$

$$h_t = o_t \cdot f_a(c_t) \quad (3.25)$$



Σχήμα 3.9 : LSTM χωρίς επιλεκτική πύλη

Όπου i_t η τελική είσοδος του κελιού, x_t η είσοδος από το προηγούμενο επίπεδο, h_t, h_{t-1} η ανατροφοδοτούμενη πληροφορία τη χρονική στιγμή t και $t-1$ αντίστοιχα, W_{ih} το βάρος σύναψης μεταξύ εισόδου και ανατροφοδότησης, W_{ix} το βάρος σύναψης μεταξύ του τρέχοντος κελιού και του κελιού του προηγούμενου επιπέδου, c_t, c_{t-1} η εσωτερική κατάσταση του κελιού (cell state) τη χρονική στιγμή t και $t-1$ αντίστοιχα, o_t η έξοδος του κελιού, W_{ox} το βάρος σύναψης μεταξύ εξόδου και εισόδου προηγούμενου επιπέδου, W_{oh} το βάρος σύναψης μεταξύ εξόδου και ανατροφοδότησης, $b_i, b_{\tilde{c}}, b_o$, η πόλωση εισόδου, κατάστασης και εξόδου αντίστοιχα και f_a η συνάρτηση ενεργοποίησης.

- LSTM με επιλεκτική πύλη (forget gate): Το LSTM έχει τη δυνατότητα να συγκρατεί πληροφορία από προηγούμενες καταστάσεις, έτσι ώστε να εκπαιδευτεί πιο αποτελεσματικά. Ωστόσο, η παράμετρος αυτή ενέχει τον κίνδυνο το κελί να συγκρατεί την πληροφορία απεριόριστα, οδηγώντας σε ανεξέλεγκτη ανάπτυξή του. Για να αντιμετωπιστεί αυτός ο κίνδυνος, εισάχθηκε από τους Gers, Schmidhuber, και Cummins (2000) η επιλεκτική πύλη, η οποία συγκρατεί τις χρήσιμες πληροφορίες και απορρίπτει τις άχρηστες [50]. Οι εξισώσεις (3.26) έως και (3.31) και το Σχήμα 3.10 περιγράφουν ένα LSTM με επιλεκτική πύλη.

$$f_t = \sigma(W_{fh} \cdot h_{t-1} + W_{fx} \cdot x_t + b_f) \quad (3.26)$$

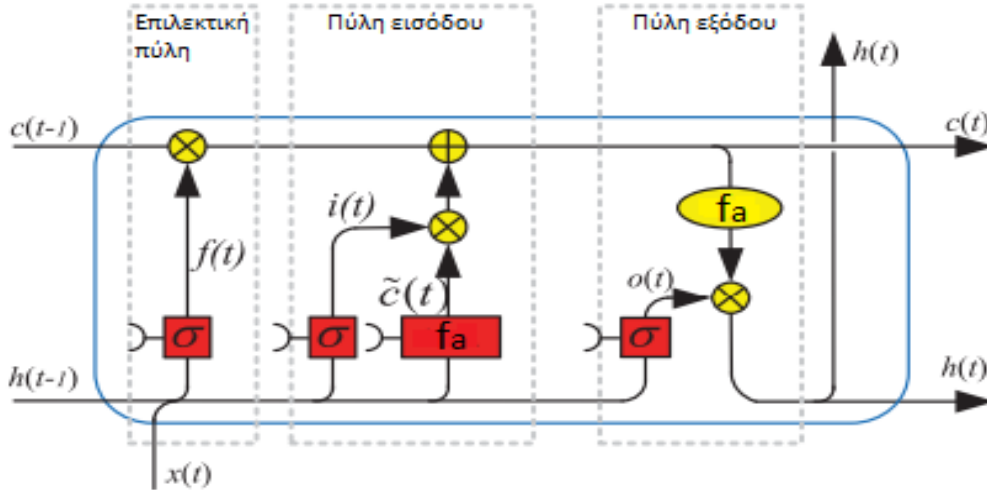
$$i_t = \sigma(W_{ih} \cdot h_{t-1} + W_{ix} \cdot x_t + b_i) \quad (3.27)$$

$$\tilde{c}_t = f_a(W_{\tilde{c}h} \cdot h_{t-1} + W_{\tilde{c}x} \cdot x_t + b_{\tilde{c}}) \quad (3.28)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (3.29)$$

$$o_t = \sigma(W_{oh} \cdot h_{t-1} + W_{ox} \cdot x_t + b_o) \quad (3.30)$$

$$h_t = o_t \cdot f_a(c_t) \quad (3.31)$$



Σχήμα 3.10 : LSTM με επιλεκτική πύλη

όπου f_t η τιμή της επιλεκτικής πύλης (αν $f_t = 1$ η πληροφορία συγκρατείται, αν $f_t = 0$ η πληροφορία απορρίπτεται) και b_f η πόλωση της επιλεκτικής πύλης. Αν η πόλωση b_f αρχικοποιηθεί με μια σχετικά μεγάλη τιμή μεταξύ 1 και 2, η γενικότερη απόδοση του LSTM βελτιώνεται, καθώς ανταποκρίνεται καλύτερα στη μέθοδο μείωσης της κλίσης [51].

- LSTM με επιλεκτική πύλη (forget gate) και «κρυφή» σύνδεση (peephole connection): Οι δύο προαναφερθέντες αρχιτεκτονικές LSTM δεν προσφέρουν άμεση σύνδεση της εσωτερικής κατάστασης του κελιού ούτε με την είσοδο ούτε με την έξοδο. Για αυτόν τον λόγο οι Gers και Schmidhuber (2000) πρότειναν μία «κρυφή» σύνδεση, ώστε να λαμβάνεται υπόψη και η εσωτερική κατάσταση του κελιού [52]. Οι ακόλουθες σχέσεις περιγράφουν ένα LSTM με επιλεκτική πύλη (forget gate) και «κρυφή» σύνδεση.

$$f_t = \sigma(W_{fh} \cdot h_{t-1} + W_{fx} \cdot x_t + P_f \cdot c_{t-1} + b_f) \quad (3.32)$$

$$i_t = \sigma(W_{ih} \cdot h_{t-1} + W_{ix} \cdot x_t + P_i \cdot c_{t-1} + b_i) \quad (3.33)$$

$$\tilde{c}_t = f_a(W_{\tilde{c}h} \cdot h_{t-1} + W_{\tilde{c}x} \cdot x_t + b_{\tilde{c}}) \quad (3.34)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (3.35)$$

$$o_t = \sigma(W_{oh} \cdot h_{t-1} + W_{ox} \cdot x_t + P_o \cdot c_t + b_o) \quad (3.36)$$

$$h_t = o_t \cdot f_a(c_t) \quad (3.37)$$

όπου P_f, P_i, P_o τα βάρη των «κρυφών» συνάψεων μεταξύ της εσωτερικής κατάστασης και της επιλεκτικής πύλης, της πύλης εισόδου και της πύλης εξόδου αντίστοιχα.

3.4.2 Πλεονεκτήματα LSTM

Τα RNN, εξαιτίας της ανατροφοδοτούμενης δομής τους, παρουσιάζουν ικανοποιητική αποτελεσματικότητα σε μία πληθώρα απαιτητικών και σύνθετων προβλημάτων. Στην Ενότητα 3.3 αναπτύχθηκε ο αλγόριθμος οπίσθιας διάδοσης σφάλματος, ο οποίος αποτελεί, με ορισμένες παραλλαγές, τη συνήθη διαδικασία εκπαίδευσης ενός RNN. Η παραγόμενη έξοδος δηλαδή, συγκρίνεται με την αναμενόμενη και μέσω της μεθόδου μείωσης της κλίσης, το σήμα σφάλματος διαδίδεται από την έξοδο προς την είσοδο ώστε να προσαρμοστούν ανάλογα τα βάρη συνάψεων και το σφάλμα αυτό να ελαχιστοποιηθεί. Ωστόσο, επειδή οι νευρώνες ενός RNN δεν διαθέτουν μνήμη, το σήμα σφάλματος μπορεί σταδιακά να εξαφανιστεί εντός του δικτύου (gradient vanishing problem), γεγονός που οδηγεί στην αδυναμία εκπαίδευσης του μοντέλου [53]. Ένα ακόμη συχνό πρόβλημα αποτελεί η «έκρηξη» (blow up) του σήματος σφάλματος, δηλαδή η συνεχής αλλαγή των βαρών και των πολώσεων χωρίς όμως να παρατηρείται βελτίωση του μοντέλου. Πέραν αυτών, η «έκρηξη» του σήματος σφάλματος και η εξαφάνιση της κλίσης μπορούν να οδηγήσουν σε ασταθή βάρη συνάψεων και σε απαγορευτικό χρόνο εκπαίδευσης, αντίστοιχα [48]. Κατά τη διαδικασία gradient descent στα RNN, διαισθητικά γίνεται αντιληπτό πως ο ανατροφοδοτούμενος νευρώνας «ξεδιπλώνεται» (unfold), όπως εμφανίζεται στο Σχήμα 3.11. Επομένως, η εσωτερική κατάσταση c_t και η έξοδος του κελιού y_t σε ένα RNN ισούνται με:


$$c_t = f_h(W_{xc} \cdot x_t + W_{cc} \cdot c_{t-1}) \quad (3.38)$$

$$y_t = \sigma(W_{co} \cdot c_t) \quad (3.39)$$

όπου f_h η συνάρτηση ενεργοποίησης της εσωτερικής κατάστασης, x_t η είσοδος από το προηγούμενο κελί, c_t, c_{t-1} η εσωτερική κατάσταση του κελιού τις χρονικές στιγμές t και $t - 1$, αντίστοιχα, και W_{xc}, W_{cc}, W_{co} τα βάρη συνάψεων μεταξύ προηγούμενου κελιού και εσωτερικής κατάστασης, ανατροφοδότησης, και εσωτερικής κατάστασης και εξόδου αντίστοιχα. Επομένως, αν $a_t = W_{co} \cdot c_t$ η κλίση για την αρχική εσωτερική κατάσταση c_0 της εξόδου y_t είναι [54]:

$$\frac{\partial y_t}{\partial c_0} = \frac{\partial \sigma}{\partial a_t} \times \frac{\partial a_t}{\partial c_0} \quad (3.40)$$

Καθίσταται λοιπόν εμφανές από τη σχέση (3.40) πως όσο το t αυξάνεται, δηλαδή η εξάρτηση αυξάνεται χρονικά στην οπίσθια διάδοση, τόσο ο παράγοντας $\frac{\partial a_t}{\partial c_0}$ μειώνεται καθώς η αρχική εσωτερική κατάσταση «απομακρύνεται» χρονικά. Αντίστοιχα λοιπόν, μειώνεται και ο παράγοντας $\frac{\partial y_t}{\partial c_0}$, προκαλώντας έτσι το πρόβλημα εξαφάνισης της κλίσης.



Σχήμα 3.11 : Διαδικασία «ξεδίπλωματος» νευρώνα RNN

Στον αντίποδα, όπως αναδείχθηκε στην Ενότητα 3.4, τα LSTM διαθέτουν κελιά μνήμης (memory cells), τα οποία σε συνδυασμό με την επιλεκτική πύλη μπορούν να συγκρατούν τη χρήσιμη πληροφορία ακόμη και για μακροχρόνιες συσχετίσεις, διευκολύνοντας έτσι την απρόσκοπτη εκπαίδευση του μοντέλου. Σε αντιστοιχία με τις σχέσεις (3.26) – (3.31), η κλίση για την αρχική κατάσταση μνήμης του κελιού ενός LSTM ισούται με:

$$\frac{\partial h_t}{\partial c_0} = \frac{\partial o_t}{\partial c_0} \cdot f_a(c_t) + o_t \frac{\partial f_a}{\partial c_t} \frac{\partial c_t}{\partial c_0} \quad (3.41)$$

Από τη σχέση (3.41) αποδεικνύεται πως η αύξηση του t δεν επιφέρει μείωση της κλίσης [54].

Πέρα από το πρόβλημα εξαφάνισης της κλίσης, το LSTM συνδυάζει όλα τα προαναφερθέντα πλεονεκτήματα των ANN και των RNN. Παράλληλα, ανταποκρίνεται αποτελεσματικά και με μεγάλη ακρίβεια σε απαιτητικά προβλήματα που φέρουν έντονη «καθυστερήση» μεταξύ εισόδου και μεταβλητών στόχων [55]. Ένα ακόμη σημαντικό θετικό χαρακτηριστικό των LSTM είναι πως η υπολογιστική τους πολυπλοκότητα ανά μονάδα χρόνου και βαρών ισούται με $O(1)$ [56], είναι δηλαδή τοπικά (local) σε χώρο και χρόνο. Επιπροσθέτως, τα LSTM φέρουν μεγαλύτερη ευελιξία από τα RNN κατά την λειτουργία τους. Δηλαδή, η επιλογή των υπέρ-παραμέτρων τους δεν είναι τόσο ευαίσθητη, καθώς αποδίδουν επαρκώς σε μία ευρεία περιοχή τιμών. Οι κυριότερες εμπλεκόμενες παράμετροι είναι ο ρυθμός εκμάθησης, οι πολώσεις των πυλών εισόδου – εξόδου, ο αριθμός των κρυφών στρωμάτων και ο αλγόριθμος βελτιστοποίησης.

Παρόλα αυτά, αν και τα LSTM έχουν πλέον κυριαρχήσει μεταξύ των RNN, είναι λογικό να παρουσιάζουν και ορισμένα μειονεκτήματα. Εξαιτίας της ιδιότητας ανατροφοδότησης του κελιού και της οπίσθιας διάδοσης σφάλματος, το σύνολο δεδομένων διαδίδεται πολλές φορές μέσα από το ίδιο δίκτυο κατά τη διαδικασία ελαχιστοποίησης του σφάλματος. Αυτό έχει ως αποτέλεσμα την αύξηση του χρόνου εκπαίδευσης ενός LSTM, χωρίς να είναι δεδομένο πως η αύξηση του αριθμού των επαναλήψεων (epochs) συνεπάγεται την αύξηση της συνολικής ακρίβειας [57]. Ειδικά για LSTM με πολλά κρυφά στρώματα και πολλούς εσωτερικούς νευρώνες, ο χρόνος εκπαίδευσης αυξάνεται πολλαπλασιαστικά. Λόγω της συνεχούς ροής σφάλματος στα κελιά μνήμης, είναι πιθανό σε απλά προβλήματα το LSTM να αντιλαμβάνεται ταυτόχρονα όλη τη χρονοσειρά εισόδου, αδυνατώντας να κατανοήσει ποια βάρη συνάψων και ποιες πολώσεις δημιουργούν το παρατηρούμενο σφάλμα [47]. Για τους ανωτέρω λόγους, τα LSTM συχνά συνδυάζονται με άλλες μεθόδους μηχανικής ή βαθιάς μάθησης, καθώς και με διαφορετικές τεχνικές βελτιστοποίησης και επεξεργασίας δεδομένων, ώστε να μειωθεί η επίδραση των μειονεκτημάτων των επιμέρους μεθόδων (υβριδικά μοντέλα).

3.5 ΥΒΡΙΔΙΚΑ ΜΟΝΤΕΛΑ


Προκειμένου ένα μοντέλο να χαρακτηριστεί υβριδικό πρέπει να συνδυάζει δύο ή περισσότερες μεθόδους ανάλυσης, επεξεργασίας ή πρόβλεψης, όπως αυτές αναλύθηκαν στην Ενότητα 2.5. Έχει καταστεί σαφές, πως κανένα μοντέλο δεν παρουσιάζει σε όλες τις κατηγορίες προβλημάτων βέλτιστη ακρίβεια. Επομένως, τα τελευταία χρόνια έχουν αναπτυχθεί σύνθετα υβριδικά μοντέλα, ώστε να συνδυάζονται διαφορετικές μέθοδοι με μοναδικά χαρακτηριστικά τα οποία έχουν τη ικανότητα να εξουδετερώνουν τα επιμέρους μειονεκτήματα [58]. Συχνά χρησιμοποιούμενα ζεύγη τα οποία συνθέτουν ένα υβριδικό μοντέλο αναφέρονται επιγραμματικά στη συνέχεια:

- Ασαφή συστήματα (fuzzy systems) και ANN [59].
- Bayesian μοντέλα και ANN [60].
- ANN και εξελικτικοί (evolutionary) αλγόριθμοι βελτιστοποίησης [61].
- ANN και μεταευρετικοί (metaheuristic) αλγόριθμοι βελτιστοποίησης [62].
- ANN, ασαφή συστήματα και ενισχυμένη μάθηση (reinforcement learning) [63].
- ANN και τεχνικές επεξεργασίας των δεδομένων [64].

Τα υβριδικά συστήματα, ανάλογα με τον τρόπο που συνδυάζονται οι τεχνικές επεξεργασίας, χωρίζονται σε τρεις βασικές κατηγορίες [65]:

- Ακολουθιακά (sequential): Ο ακολουθιακός τρόπος σύνδεσης υποδηλώνει πως οι μέθοδοι και οι τεχνικές του υβριδικού συστήματος συνδέονται γραμμικά (pipeline-like), δηλαδή η έξοδος του ενός μοντέλου αποτελεί είσοδο για το επόμενο, όπως εμφανίζεται στο Σχήμα 3.12. Αποτελεί τη συχνότερη και ευκολότερη αρχιτεκτονική ενός υβριδικού μοντέλου.
- Βοηθητικά (auxiliary): Στα βοηθητικά υβριδικά συστήματα οι μέθοδοι λειτουργούν παράλληλα. Το δεύτερο μοντέλο λαμβάνει πληροφορίες από το πρώτο, τις επεξεργάζεται και τις τροφοδοτεί ξανά πίσω σε αυτό, ώστε να παράγει την τελική έξοδο. Η δεύτερη μέθοδος καλείται υπο-ρουτίνα (subroutine), καθώς φέρει κυρίως υπολογιστικό χαρακτήρα.
- Ενσωματωμένα (embedded): Σε αυτή την κατηγορία, οι συνδυαζόμενες τεχνικές περιέχονται η μία μέσα στην άλλη και είναι μερικώς ή απόλυτα αλληλεξαρτώμενες. Οι μέθοδοι λειτουργούν ταυτόχρονα και είναι αλληλένδετες.

Ο λόγος δημιουργίας των υβριδικών μοντέλων έγκειται στην ανάγκη να συνδυαστούν τα πλεονεκτήματα και να αποφευχθούν τα μειονεκτήματα των επιμέρους τεχνολογιών. Ωστόσο, οι χρησιμοποιούμενες μέθοδοι και ο τρόπος σύνδεσής τους μπορεί να έχει τα αντίθετα αποτελέσματα, επομένως η αρχιτεκτονική ενός υβριδικού μοντέλου οφείλει να είναι προσεκτικά μελετημένη [66].



Σχήμα 3.12 : Τυπική δομή ακολουθιακού υβριδικού συστήματος

ΑΝΑΛΥΣΗ ΚΑΙ ΠΡΟΕΠΕΞΕΡΓΑΣΙΑ ΔΕΔΟΜΕΝΩΝ

4.1 ΓΕΝΙΚΑ

Η Φ/Β παραγωγή έχει τις τελευταίες δεκαετίες αναδειχθεί σε βασική πηγή ηλεκτρικής ενέργειας, τόσο για περιβαλλοντικούς όσο και για οικονομικούς λόγους. Ωστόσο, είναι δεδομένο πως η αναπόφευκτη στοχαστικότητα που φέρουν γενικά οι τεχνολογίες ΑΠΕ δυσχεραίνουν την ομαλή ένταξή τους στο δίκτυο, δίνοντας με αυτόν τον τρόπο όλο και μεγαλύτερη αξία στις μεθόδους πρόβλεψης, όπως αυτές αναπτύχθηκαν στην Ενότητα 2.5. Έχει καταστεί ήδη προφανές, πως η ποσότητα και η ποιότητα των δεδομένων εισόδου ενός μοντέλου ML είναι καθοριστικής σημασίας για τα παραγόμενα αποτελέσματα. Το γεγονός αυτό έρχεται σε αντιδιαστολή με τη «χαοτική» φύση ενός Φ/Β σταθμού, καθώς οι παράγοντες που επηρεάζουν την παραγωγή του είναι πολυπληθείς, μη αναμενόμενοι και δύσκολα μετρήσιμοι [67]. Πιο συγκεκριμένα, η παραγωγή ενός Φ/Β σταθμού μπορεί να επηρεαστεί είτε από μετεωρολογικούς είτε από κατασκευαστικούς παράγοντες. Στην πρώτη κατηγορία εντάσσονται η ηλιακή ακτινοβολία, η γωνία πρόσπτωσης των ηλιακών ακτίνων, η θερμοκρασία περιβάλλοντος και συλλέκτη, η ταχύτητα του ανέμου, οι νεφώσεις, η σχετική υγρασία, η σκίαση και η σκόνη. Στους κατασκευαστικούς παράγοντες, ανήκουν η γήρανση του εξοπλισμού, οι απώλειες του αντιστροφέα και του $M/\Sigma X/T - M/T$ και η αντίσταση των καλωδίων [68]. Οι μετεωρολογικοί παράγοντες μεταβάλλονται κατά τη διάρκεια του χρόνου, ενώ οι κατασκευαστικοί παραμένουν σταθεροί ή διαφοροποιούνται με πολύ αργό ρυθμό. Επομένως, για την πρόβλεψη της Φ/Β παραγωγής με χρήση ANN ή DNN γίνεται χρήση μόνο των χρονικά μεταβαλλόμενων παραγόντων, καθώς για αυτούς έχει νόημα η δημιουργία μίας ιστορικής χρονοσειράς και η αποτύπωση μοτίβων από το δίκτυο.

4.2 ΔΕΔΟΜΕΝΑ ΕΙΣΟΔΟΥ

4.2.1 Προέλευση δεδομένων

Τα δεδομένα που χρησιμοποιήθηκαν στην παρούσα διπλωματική εργασία για την εκπαίδευση, αξιολόγηση και παραγωγή όλων των αποτελεσμάτων μέσω του μοντέλου DL, προέρχονται από πραγματικό Φ/Β σταθμό εγκατεστημένης ισχύος 500 kW στην περιοχή της Ροδόπης. Πιο αναλυτικά, τα δεδομένα εισόδου συγκεντρώθηκαν τη χρονική περίοδο από 01/01/2022 έως 31/12/2022 με χρήση συγκεκριμένου μετρητικού εξοπλισμού (MOXA) και χρονική συχνότητα μέτρησης δεκαπέντε λεπτών. Τα εν λόγω δεδομένα μεταφέρονται και αποθηκεύονται σε πλατφόρμα παρακολούθησης (monitoring) Φ/Β σταθμών. Τα μετρούμενα μεγέθη τα οποία περιγράφονται στο σύνολο δεδομένων είναι η παραγόμενη ισχύς σε kW

(power), η θερμοκρασία περιβάλλοντος σε °C (ambient temperature), η θερμοκρασία του συλλέκτη σε °C (module temperature) και η μέση προσπίπτουσα ηλιακή ακτινοβολία ανά πάνελ σε kW/m² (average irradiance).

4.2.2 Επεξεργασία δεδομένων

Προκειμένου ένα μοντέλο ML ή DL να εκπαιδευθεί και να λειτουργήσει αποδοτικά, τα δεδομένα με τα οποία τροφοδοτείται πρέπει να είναι αντιπροσωπευτικά του προβλήματος, να μην περιέχουν ακραίες ή κενές τιμές και να υπάρχει ένα επαρκές δείγμα [69]. Για τον λόγο αυτό, τα δεδομένα που χρησιμοποιήθηκαν στην παρούσα διπλωματική εργασία υπέστησαν μία απαραίτητη διαδικασία εκκαθάρισης, ώστε να βελτιωθεί η ποιότητά τους. Πιο αναλυτικά, υλοποιήθηκαν τα ακόλουθα βήματα:

- Εκκαθάριση βλαβών δικτύου (grid faults): Αφαιρέθηκαν χρονικές στιγμές κατά τις οποίες ενώ υπήρχε επαρκής μετρούμενη ηλιοφάνεια, η παραγόμενη ισχύς του Φ/Β σταθμού ήταν μηδενική.
- Εκκαθάριση βλαβών εξοπλισμού (equipment faults): Από το σύνολο δεδομένων διαγράφηκαν οι χρονικές στιγμές κατά τις οποίες, λόγω πιθανού προβλήματος του εξοπλισμού, όλα τα μετρούμενα μεγέθη ήταν μηδενικά.
- Εκκαθάριση βλαβών πλατφόρμας (platform faults): Αφαιρέθηκαν χρονικές στιγμές του συνολου δεδομένων από τις οποίες «έλειπαν» μετρούμενα μεγέθη και υπήρχαν ορισμένα κενά κελιά εξαιτίας του συστήματος καταγραφής της σχετικής πλατφόρμας.

Μετά τη διαδικασία εκκαθάρισης των δεδομένων, πραγματοποιήθηκαν δύο ακόμη παρεμβάσεις:

- Προσθήκη διαγραμμένων δεδομένων: Για λόγους πληρότητας και ομοιομορφίας των δεδομένων εισόδου, προστέθηκαν όλες οι μετρήσεις που είχαν αφαιρεθεί κατά την διαδικασία εκκαθάρισης. Οπουδήποτε υπήρχε κενό κελί, αυτό συμπληρώθηκε με την αμέσως προηγούμενη μετρούμενη τιμή του αντίστοιχου μεγέθους. Με αυτόν τον τρόπο, στα δεδομένα υπάρχουν για όλα τα μεγέθη, όλες οι τιμές ανά δεκαπέντε λεπτά για όλη τη διάρκεια του έτους 2022.
- Δημιουργία νέας στήλης παραγόμενης ισχύος: Για την εύρυθμη λειτουργία του υβριδικού μοντέλου, το οποίο θα αναλυθεί στο Κεφάλαιο 5, η στήλη της παραγόμενης ισχύος υπέστη την ακόλουθη μετατροπή. Η αρχική στήλη μετονομάστηκε από power σε real-time power και δημιουργήθηκε μία νέα στήλη ισχύος με το όνομα actual power. Η στήλη αυτή προέρχεται από την αρχική στήλη ισχύος, με μία μετατόπιση (shift) τεσσάρων θέσεων προς τα πάνω ή αλλιώς με χρονική μετατόπιση μίας ώρας, ώστε να χρησιμοποιηθεί ως μεταβλητή στόχος για το υβριδικό μοντέλο.

4.3 ΤΕΧΝΙΚΕΣ ΕΠΕΞΕΡΓΑΣΙΑΣ ΔΕΔΟΜΕΝΩΝ

Τα δεδομένα με τα οποία τροφοδοτείται ένα μοντέλο ML είναι απαραίτητο να έχουν προηγουμένως υποστεί κατάλληλη επεξεργασία και πιθανώς κανονικοποίηση. Με τον όρο κανονικοποίηση στον τομέα της ML ορίζεται η διαδικασία επεξεργασίας των δεδομένων μέσω της οποίας αποκτούν ένα νέο εύρος τιμών, διατηρώντας παράλληλα τη μορφή της κατανομής τους. Η διαδικασία αυτή στοχεύει στη διασφάλιση ότι δεν θα υπάρχουν μεγάλες αποκλίσεις στην τάξη μεγέθους των δεδομένων, γεγονός το οποίο δυνητικά δυσχεραίνει την άρτια εκπαίδευση του μοντέλου [70]. Για την κατασκευή των μοντέλων και την παραγωγή των αποτελεσμάτων της παρούσας διπλωματικής εργασίας, χρησιμοποιήθηκαν οι ακόλουθες τεχνικές επεξεργασίας:

- «Στιβαρή» κλιμάκωση (robust scaling): Η συγκεκριμένη μέθοδος αγνοεί τις ακραίες τιμές (outliers) και προσαρμόζει τα δεδομένα σύμφωνα με το εύρος των τεταρτημορίων (Inter-Quartile Range / IQR). Το IQR είναι το εύρος μεταξύ του πρώτου και του τρίτου τεταρτημορίου. Ως πρώτο τεταρτημορίο στη στατιστική (Q_1), θεωρείται το διάστημα όπου 25% των τιμών είναι μικρότερες από την συγκεκριμένη τιμή. Αντίστοιχα, στο τρίτο τεταρτημόριο το 75% των τιμών είναι μικρότερες από την εξεταζόμενη τιμή [71]. Η κεντροποίηση (centering) και η κλιμάκωση συμβαίνουν ανεξάρτητα σε κάθε χαρακτηριστικό με τον υπολογισμό των σχετικών στατιστικών στοιχείων στα δείγματα του συνόλου εκπαίδευσης. Η διάμεσος και το ενδοτεταρτημοριακό εύρος αποθηκεύονται για να χρησιμοποιηθούν στη συνέχεια σε μεταγενέστερα δεδομένα με τη μέθοδο μετασχηματισμού [72]. Ο τρόπος υπολογισμού του robust scaling είναι:

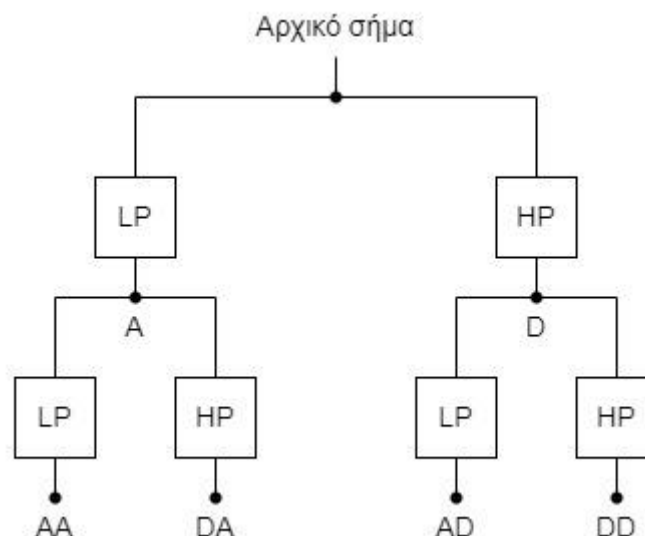
$$x_{scaled} = \frac{x_{original} - Q_2}{IQR} \quad (4.1)$$

όπου x_{scaled} , $x_{original}$ η κλιμακούμενη και η αρχική τιμή αντίστοιχα και Q_2 το δεύτερο τεταρτημόριο (η διάμεσος).

- Αναδιαμόρφωση δεδομένων εισόδου (reshape [-1, 1]): Μετά την κλιμάκωση, τα δεδομένα ανασχηματίζονται από μονοδιάστατες τιμές σε δισδιάστατους πίνακες μίας στήλης. Ο όρος -1 σημαίνει πως ο αριθμός των γραμμών του δημιουργούμενου πίνακα καθορίζεται από το πλήθος των δεδομένων εισόδου, ενώ ο όρος 1 πως ο πίνακας έχει μόνο μία στήλη.
- Συνένωση δεδομένων (concatenate): Οι πίνακες μίας στήλης ενώνονται οριζόντια, ώστε οι επιμέρους μεταβλητές να αντικατασταθούν από μία. Η νέα μεταβλητή απεικονίζεται από έναν πίνακα, με αριθμό γραμμών ίσο με αυτόν των επιμέρους πινάκων και αριθμό στηλών ίσο με το άθροισμα των στηλών όλων των πινάκων.
- Αντίστροφος μετασχηματισμός (inverse transform): Τα παραγόμενα αποτελέσματα υπόκεινται σε αντίστροφο μετασχηματισμό μορφής και τιμών, ώστε να είναι κατανοητά και ερμηνεύσιμα. Με αυτόν τον τρόπο γίνεται η επιστροφή στις φυσικές τιμές των μεγεθών.

4.4 ΑΠΟΣΥΝΘΕΣΗ ΧΡΟΝΟΣΕΙΡΑΣ

Πέραν των προαναφερθέντων τεχνικών επεξεργασίας, μία ακόμη μέθοδος που χρησιμοποιείται στην παρούσα διπλωματική εργασία αφορά την αποσύνθεση της ιστορικής χρονοσειράς παραγωγής ισχύος ενός Φ/Β σταθμού. Όπως είναι λογικό, οι μεταβλητοί παράγοντες που αναλύθηκαν στην Ενότητα 4.1 δεν επηρεάζουν ισοβαρώς την παραγωγή ενός Φ/Β. Ωστόσο, είναι σχεδόν αδύνατο να είναι εκ των προτέρων γνωστό με ποιον τρόπο και σε τι βαθμό δημιουργείται συσχέτιση μεταξύ εισόδου και εξόδου. Ακόμη και αν τα μετεωρολογικά δεδομένα έχουν εκκαθαρισθεί από σφάλματα, ο αναπόφευκτος θόρυβός τους μπορεί να καταστήσει την διαδικασία εκπαίδευσης δυσκολότερη ή πιο χρονοβόρα. Για τον λόγο αυτό, σε μία προσπάθεια βελτίωσης της ποιότητας των παρεχόμενων δεδομένων και κατά επέκταση τη διευκόλυνση της εκπαίδευσης και της αξιολόγησής ενός μοντέλου ML χρησιμοποιείται συχνά η τεχνική αποσύνθεσης πακέτων κυματιδίων (WPD) [73]. Η WPD είναι μία τεχνική επεξεργασίας σήματος στο πεδίο της συχνότητας. Η χρονοσειρά ισχύος ενός Φ/Β αποτελείται από συνιστώσες διαφορετικής συχνότητας, οι οποίες αποσυντίθενται μέσω της WPD, ώστε οι συνιστώσες χαμηλής συχνότητας να αντιπροσωπεύουν την τάση της ισχύος, ενώ οι συνιστώσες υψηλής συχνότητας την ταχεία μεταβολή της [1]. Η μέθοδος WPD διαχωρίζει την αρχική χρονοσειρά σε επιμέρους σειρές (sub-series) με διαφορετικές ιδιότητες. Το αρχικό σήμα φιλτράρεται τόσο με βαθυπερατά (Low-Pass / LP) όσο και με υψιπερατά (High-Pass / HP) φίλτρα, τα οποία ονομάζονται τετραγωνικά φίλτρα καθρέφτη [74]. Η συχνότητα αποκοπής αυτών των φίλτρων ισούται με το ένα τέταρτο της συχνότητας δειγματοληψίας του σήματος. Τα φιλτραρισμένα βαθυπερατά και υψιπερατά σήματα αφορούν την προσέγγιση (Approximation / A) και τη λεπτομέρεια (Detail / D) του αρχικού σήματος αντίστοιχα. Τα A, D διαθέτουν εξίσου το μισό μέγεθος του αρχικού σήματος και φέρουν το περιεχόμενο χαμηλής και υψηλής συχνότητας αντίστοιχα. Με τον ίδιο τρόπο, η διαδικασία αποσύνθεσης μπορεί να εφαρμοστεί ξεχωριστά στα σήματα A, D όπου προκύπτουν τέσσερα νέα σήματα: η προσέγγιση της προσέγγισης (AA), η λεπτομέρεια της προσέγγισης (AD), η προσέγγιση της λεπτομέρειας (DA) και η λεπτομέρεια της λεπτομέρειας (DD). Μία WPD δευτέρου επιπέδου απεικονίζεται στο Σχήμα 4.1.



Σχήμα 4.1 : Αποσύνθεση πακέτων κυματιδίων δευτέρου επιπέδου

Γενικότερα, ο μετασχηματισμός κυματιδίων (WT), υποκατηγορία του οποίου είναι η μέθοδος WPD, αποτελεί μέθοδο ανάλυσης στο πεδίο της συχνότητας και διαχωρίζεται σε διακριτό (Discrete Wavelet Transform / DWT) και συνεχή (Continuous Wavelet Transform / CWT) μετασχηματισμό κυματιδίων. Στην πληθώρα των εφαρμογών πρόβλεψης χρησιμοποιείται ο συνεχής μετασχηματισμός εξαιτίας της ύπαρξης ιστορικής χρονοσειράς δεδομένων. Αν $\psi(t) \in L^2(\mathbb{R})$ είναι μία τετραγωνική ολοκληρώσιμη συνάρτηση, της οποίας η συνάρτηση μετασχηματισμού Fourier είναι $\psi(\omega)$ και για την οποία ισχύει:

$$C_\psi = \int_{\mathbb{R}} \frac{|\psi(\omega)|^2}{|\omega|} d\omega < \infty \quad (4.2)$$

τότε η $\psi(t)$ ονομάζεται μητρική συνάρτηση κυματιδίων (mother wavelet function) [75]. Η συνάρτηση βάσης κυματιδίων (wavelet basis function) συνεχούς μετασχηματισμού ισούται με:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \cdot \psi\left(\frac{t-b}{a}\right) \quad (4.3)$$

όπου a παράμετρος κλιμάκωσης και b παράμετρος μετάφρασης. Αντίστοιχα, για διακριτό μετασχηματισμό ισχύει $a = a_0^u$ και $b = va_0^u b_0$, άρα η συνάρτηση αυτή είναι:

$$\psi_{u,v}(t) = \frac{1}{\sqrt{a_0^u}} \cdot \psi\left(\frac{t - va_0^u b_0}{a_0^u}\right) \quad (4.4)$$

Επομένως, οι συναρτήσεις CWT, DWT ενός σήματος $x(t)$ ορίζονται στις εξισώσεις (4.5) και (4.6):

$$CWT_x(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \cdot \psi\left(\frac{t-b}{a}\right) dt \quad (4.5)$$

$$DWT_x(u, v) = \frac{1}{\sqrt{a_0^u}} \sum_v x(v) \cdot \psi\left(\frac{t - va_0^u b_0}{a_0^u}\right) \quad (4.6)$$

Μια εναλλακτική διατύπωση της εξίσωσης (4.5) για την μέθοδο WPD είναι η εξής:

$$CWT_f(a, b) = \langle f(t), \psi_{a,b}(t) \rangle = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \cdot \psi\left(\frac{t-b}{a}\right) dt \quad (4.7)$$

όπου το σήμα συμβολίζεται με $f(t)$. Η διαδικασία αποσύνθεσης WPD μπορεί να περιγραφεί με τις ακόλουθες εξισώσεις:

$$P_j^{2i-1}(t) = HP_{j-1}^i(t) \quad (4.8)$$

$$P_j^{2i}(t) = GP_{j-1}^i(t) \quad (4.9)$$

όπου P_j^i το i -οστό πακέτο κυματιδίων του επιπέδου j και H, G το βαθυπερατό και το υψιπερατό φίλτρο αντίστοιχα. Κάθε πακέτο κυματιδίων μετά την αποσύνθεση τελικού επιπέδου ακολουθεί αντίστροφη πορεία αποσύνθεσης και ανακατασκευάζεται στο αρχικό επίπεδο. Η τιμή των υπόλοιπων πακέτων ίδιου επιπέδου θεωρείται μηδενική κατά την συγκεκριμένη διαδικασία [1]. Η μέθοδος ανακατασκευής περιγράφεται από την εξίσωση (4.10):

$$P_j^i(t) = H * P_{j+1}^{2i-1}(t) + G * P_{j+1}^{2i}(t) \quad (4.10)$$

όπου το σύμβολο $*$ αναφέρεται στους δυαδικούς τελεστές των H, G .

Η επιλογή της κατάλληλης μητρικής συνάρτησης κυματιδίων, εξαρτάται από τα σήματα εισόδου, τις υπολογιστικές απαιτήσεις και τη φύση του προβλήματος. Οι βασικές παράμετροι οι οποίες οφείλουν να ληφθούν υπόψη πριν τον καθορισμό της μητρικής συνάρτησης, είναι οι εξής [76]:

- Οπτική ομοιότητα (visual similarity): Τα κυματίδια βασίζονται στην εύρεση της συσχέτισης μεταξύ της αρχικής κυματομορφής και της μετατοπισμένης και κλιμακούμενης εκδοχής ενός κύματος μικρής διάρκειας που ονομάζεται κυματίδιο. Επομένως, η οπτική ομοιότητα μεταξύ της συνάρτησης του σήματος και της μητρικής συνάρτησης μπορεί να είναι ένα πρώτο κριτήριο επιλογής. Ωστόσο, δεν πρέπει να αποτελεί μοναδικό παράγοντα για την επιλογή, καθώς είναι πιθανό η τελική ακρίβεια της επεξεργασίας να είναι μικρή.
- Στιγμές εξαφάνισης κυματιδίων (vanishing wavelet moments): Ένα κυματίδιο έχει K στιγμές εξαφάνισης αν για κάθε $k < K$ ισχύει:

$$\int t^k f(t) dt = 0 \quad (4.11)$$

Οι στιγμές εξαφάνισης αφορούν την τάξη της συνάρτησης που μπορεί να προσεγγιστεί από το αντίστοιχο κυματίδιο και το επίπεδο συμπίεσης που επιτυγχάνεται μέσω της αποσύνθεσης κυματιδίων. Για παράδειγμα, στις συχνά χρησιμοποιούμενες οικογένειες μητρικών συναρτήσεων Daubechies (DBN) ο αριθμός N αναφέρεται στον αριθμό των στιγμών εξαφάνισης [77]. Στην παρούσα διπλωματική εργασία, στο υβριδικό μοντέλο του Κεφαλαίου 5, χρησιμοποιείται η μητρική συνάρτηση DB4. Γενικότερα, όσο αυξάνεται ο αριθμός N βελτιώνεται η ικανότητα της μεθόδου να διαχειρίζεται σύνθετα σήματα, με ταυτόχρονη αύξηση, ωστόσο, της πολυπλοκότητάς της [78].

- Υλοποίηση και υπολογιστική ένταση (implementation and computational intensity): Ένας ακόμη σημαντικός παράγοντας για την επιλογή μιας μητρικής συνάρτησης, αποτελεί η εφαρμογή και η υπολογιστική πολυπλοκότητα της προσέγγισης. Συναρτήσεις με φίλτρα υψηλότερης τάξης φέρουν μεγαλύτερη υπολογιστική πολυπλοκότητα, αλλά τείνουν να είναι λιγότερο ευνοϊκές για εφαρμογές του πραγματικού κόσμου.

ΥΒΡΙΔΙΚΟ ΜΟΝΤΕΛΟ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ

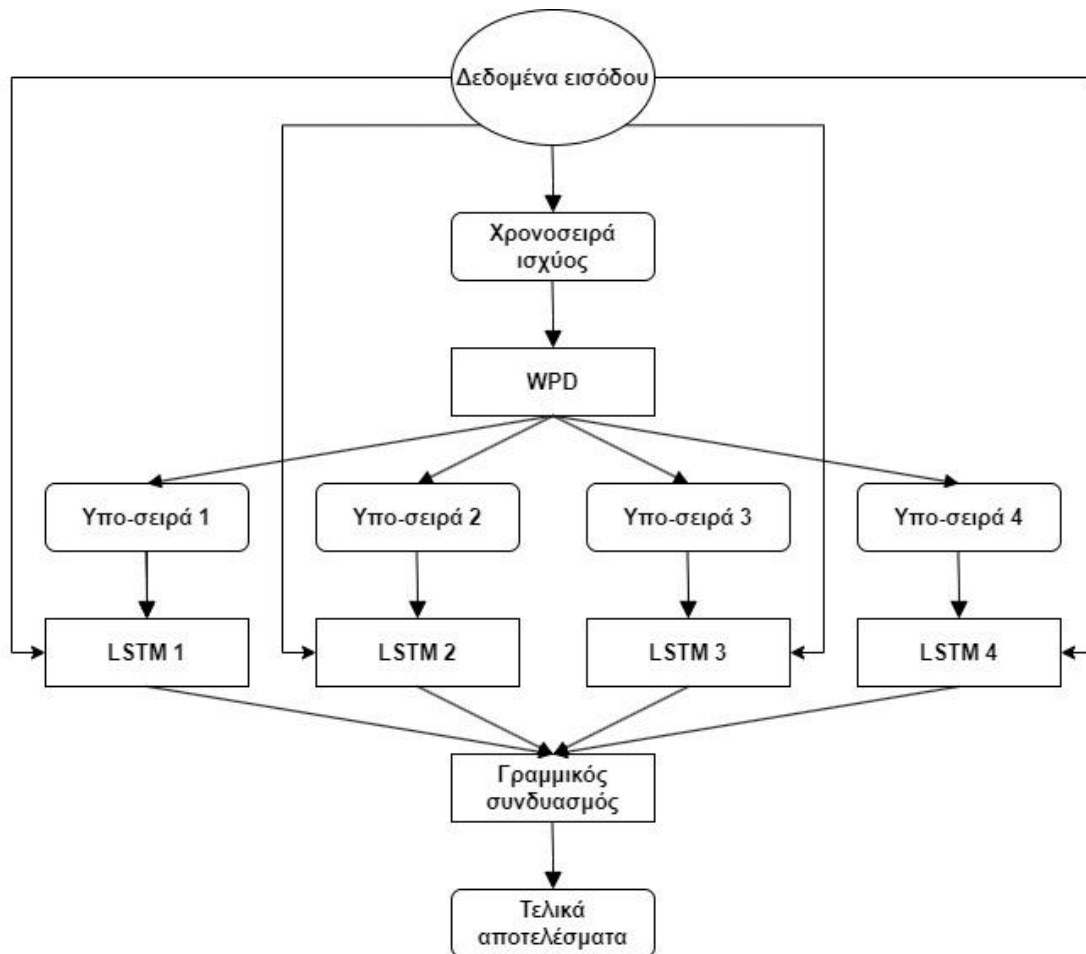
5.1 ΓΕΝΙΚΑ

Τα υβριδικά μοντέλα βρίσκουν όλο και πιο ευρεία εφαρμογή τα τελευταία χρόνια λόγω της δυνατότητάς τους να συνδυάζουν αποτελεσματικά διαφορετικές μεθόδους, με αποτέλεσμα τη μείωση της επίδρασης των επιμέρους μειονεκτημάτων. Το φαινόμενο αυτό εντείνεται όσο αυξάνονται οι απαιτήσεις ακρίβειας από τις χρησιμοποιούμενες μεθόδους, ειδικά όταν αφορούν νευραλγικούς τομείς, όπως η πρόβλεψη παραγωγής ηλεκτρικής ενέργειας. Ένα υβριδικό μοντέλο μπορεί να αποτελείται τόσο από διαφορετικές επιμέρους μεθόδους και τεχνικές επεξεργασίας όσο και από διαφορετικές αρχιτεκτονικές σύνθεσης της δομής του [79]. Σε αυτό το σημείο πρέπει να ληφθεί υπόψη, πως στην πλειονότητα των προβλημάτων του πραγματικού κόσμου δεν επικρατούν ιδανικές συνθήκες, καθώς τα διαθέσιμα δεδομένα για την παραγωγή μίας πρόβλεψης μπορεί να είναι ανεπαρκή, ασαφή ή να ποσοτικοποιούνται δύσκολα. Επομένως, η ορθή επιλογή των μεθόδων και των παραμέτρων ενός υβριδικού μοντέλου αποκτά ακόμη μεγαλύτερη σημασία, ειδικά από τη στιγμή που η άνθηση της τεχνητής νοημοσύνης απαιτεί όλο και περισσότερο τη διαχείριση δεδομένων εξαιρετικά μεγάλου όγκου (big data) [80].

5.2 ΜΕΘΟΔΟΛΟΓΙΑ ΥΒΡΙΔΙΚΟΥ ΜΟΝΤΕΛΟΥ

Στην παρούσα διπλωματική εργασία αναπτύχθηκε ένα υβριδικό μοντέλο βαθιάς μάθησης με στόχο την πρόβλεψη Φ/Β παραγωγής σε χρονικό ορίζοντα μίας ώρας (one-hour-ahead). Βάση του εν λόγω μοντέλου αποτελεί το υβριδικό μοντέλο που προτάθηκε από τους Li, Zhou, Lu και Yang (2020) [1], το οποίο υπέστη ορισμένο αριθμό αλλαγών και τροποποιήσεων στη δομή, στην αξιολόγηση και στην εφαρμογή του. Τα δεδομένα εισόδου και εξόδου που χρησιμοποιούνται για την εκπαίδευση και την αξιολόγηση του μοντέλου, καθώς και η απαραίτητη προεπεξεργασία αυτών, αναλύθηκαν στις Ενότητες 4.2 και 4.3. Η δημιουργία του μοντέλου, η εκπαίδευσή του, ο καθορισμός των υπερ-παραμέτρων καθώς και η εξαγωγή των αποτελεσμάτων υλοποιήθηκαν με χρήση της γλώσσας προγραμματισμού Python. Τα δομικά στοιχεία του συγκεκριμένου υβριδικού μοντέλου είναι επιγραμματικά τα εξής:

- Αποσύνθεση πακέτου κυματιδίων χρονοσειράς (WPD)
- Δίκτυα μακράς βραχύχρονης μνήμης (LSTM)
- Γραμμικός συνδυασμός (linear combination) των επιμέρους εξόδων



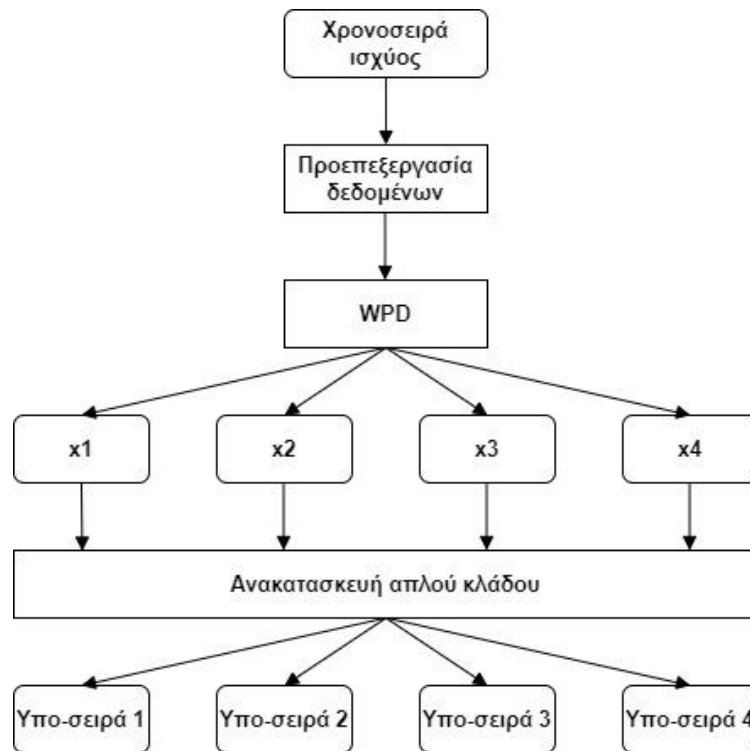
Σχήμα 5.1 : Διάγραμμα ροής κατασκευασμένου υβριδικού μοντέλου

Όπως παρουσιάζεται στο Σχήμα 5.1, τα επιμέρους στοιχεία του υβριδικού μοντέλου συνδέονται ακολουθιακά, καθώς τα αποτελέσματα της κάθε μεθόδου αποτελούν στη συνέχεια δεδομένα εισόδου για την επόμενη. Οι τεχνικές επεξεργασίας απεικονίζονται σε ορθογώνιο πλαίσιο, ενώ η μορφή των δεδομένων σε στρογγυλεμένο ορθογώνιο. Το εν λόγω υβριδικό μοντέλο ακολουθεί επιτηρούμενη εκπαίδευση και για αυτόν τον λόγο εκτελείται ένας διαχωρισμός μεταξύ δεδομένων εκπαίδευσης (train data) και δεδομένων αξιολόγησης (test data). Η συγκεκριμένη διαφοροποίηση πραγματοποιείται τόσο για τις μεταβλητές εκπαίδευσης του μοντέλου (real-time power, θερμοκρασία περιβάλλοντος, θερμοκρασία συλλέκτη, μέση ηλιακή ακτινοβολία), όσο και για τη μεταβλητή στόχο (actual power). Στην παρούσα μεθοδολογία το σύνολο δεδομένων εισόδου επιλέχθηκε να χωριστεί ισομερώς σε train και test, με κάθε υποσύνολο να κατέχει το 50% των συνολικών δεδομένων. Η επιλογή αυτή είναι αρκετά δημοφιλής μεταξύ των μοντέλων ML, καθώς εξασφαλίζει ένα επαρκές δείγμα για την εκπαίδευση και την αξιολόγηση. Επιπλέον, εφόσον υπάρχουν διαθέσιμα δεδομένα μόλις ενός έτους, διασφαλίζεται πως και τα δύο υποσύνολα θα έχουν ομοιόμορφο δείγμα μετεωρολογικών συνθηκών, καθώς το σύνολο εκπαίδευσης αποτελείται από μετρήσεις που διεξήχθησαν τους μήνες Ιανουάριο – Ιούνιο και το σύνολο αξιολόγησης από μετρήσεις των μηνών Ιούλιο – Δεκέμβριο. Με αυτόν τον τρόπο, αυξάνεται η αξιοπιστία των αποτελεσμάτων, μιας και το μοντέλο εκπαιδεύεται και αξιολογείται για εποχές του έτους με κοινά μετεωρολογικά χαρακτηριστικά. Ενδεικτικά, τα μετρούμενα μεγέθη των μηνών Ιανουαρίου και Φεβρουαρίου της εκπαίδευσης, είναι παρόμοια με αυτά των μηνών Νοεμβρίου και Δεκεμβρίου της

αξιολόγησης, όπως αντίστοιχα συμβαίνει και με τους μήνες Μάρτιο, Απρίλιο και Σεπτέμβριο, Οκτώβριο, πέραν φυσικά των μηνών του καλοκαιριού.


Στην Ενότητα 4.2 περιγράφηκε η δημιουργία της στήλης δεδομένων actual power, μέσω μετατόπισης μίας ώρας της ιστορικής χρονοσειράς ισχύος. Το προτεινόμενο μοντέλο των Li, Zhou, Lu και Yang [1] αν και χρησιμοποιεί επίσης πραγματικά ιστορικά δεδομένα, δεν πραγματοποιεί αυτόν τον διαχωρισμό στην παραγόμενη ισχύ, παράμετρος που βελτιώνει πλασματικά την αποτελεσματικότητα των μεθόδων. Πιο αναλυτικά, όλη η εκπαίδευση και η αξιολόγηση του μοντέλου πραγματοποιείται με την ακόλουθη μεθοδολογία: Χρησιμοποιούνται οι μετεωρολογικές μετρήσεις της ώρας $t + N$ (όπου N ο χρονικός ορίζοντας), ώστε να προβλεφθεί η ενεργός ισχύς την ώρα $t + N$ και στη συνέχεια – για την αναπροσαρμογή των συνάψεων των LSTMs – η προβλεπόμενη παραγωγή της ώρας $t + N$ συγκρίνεται με την πραγματική παραγωγή της ώρας $t + N$. Πρακτικά όμως, με αυτόν τον τρόπο θεωρείται δεδομένο πως είναι γνωστά εκ των προτέρων τα μετεωρολογικά μεγέθη της ώρας $t + N$, λαμβάνοντας υπόψη μία εξιδανικευμένη κατάσταση όπου υπάρχει γνώση εκ των προτέρων των μελλοντικών μετεωρολογικών συνθηκών. Ωστόσο, γίνεται αντιληπτό πως η μεθοδολογία αυτή είναι αδύνατο να εφαρμοστεί σε ένα πρόβλημα υπό πραγματικές συνθήκες, διότι τα μοντέλα πρόβλεψης στον πραγματικό κόσμο καλούνται να προβλέψουν τη Φ/Β παραγωγή της ώρας $t + N$, βασισμένα στα μετεωρολογικά δεδομένα της ώρας t . Για τον λόγο αυτόν, η δημιουργία της στήλης actual power επιτρέπει στο τροποποιημένο υβριδικό μοντέλο της παρούσας διπλωματικής εργασίας, να συγκρίνει την τιμή της προβλεπόμενης ισχύος την ώρα $t + N$ με την πραγματική ιστορική παραγωγή την ίδια ώρα $t + N$. Είναι εμφανές, πως η συγκεκριμένη διαφοροποίηση στη μεθοδολογία, συνεπάγεται αναπόφευκτη αύξηση των υπολογιζόμενων σφαλμάτων που θα αναλυθούν στη συνέχεια, καθιστά ωστόσο την προσέγγιση του προβλήματος πρόβλεψης πολύ πιο ρεαλιστική.

Στο Σχήμα 5.1 απεικονίζεται η ροή που ακολουθούν τα δεδομένα από την είσοδο έως την έξοδο του υβριδικού μοντέλου. Αρχικά, από το σύνολο δεδομένων εισόδου απομονώνεται η στήλη real-time power, η οποία αποτελεί την ιστορική χρονοσειρά ισχύος του Φ/Β σταθμού. Η χρονοσειρά ισχύος υπόκειται σε WPD, η οποία την αποσυνθέτει σε τέσσερις επιμέρους συνιστώσες διαφορετικής συχνότητας. Η μέθοδος αποσύνθεσης WPD παρουσιάζεται αναλυτικά στο Σχήμα 5.2. Στη συνέχεια, κάθε δημιουργούμενη υπο-σειρά εισάγεται ως είσοδος – μαζί με τα υπόλοιπα μεγέθη του αρχικού συνόλου δεδομένων – σε ένα δίκτυο LSTM, το οποίο είναι υπεύθυνο να συσχετίσει τις εισόδους με την επιθυμητή έξοδο μέσω της διαδικασίας αναπροσαρμογής των βαρών των συνάψεων. Η αναλυτική αρχιτεκτονική των παρεμβαλλόμενων δικτύων LSTM απεικονίζεται στο Σχήμα 5.3. Στην πορεία, οι έξοδοι των τεσσάρων διακριτών LSTMs συνδυάζονται γραμμικά με διαφορετικούς συντελεστές βαρών ανάλογα με το κατά πόσο η έξοδος κάθε LSTM συνεισφέρει στο τελικό αποτέλεσμα. Τέλος, τα παραγόμενα αποτελέσματα υπόκεινται σε αντίστροφο μετασχηματισμό μορφής και τιμών, ώστε να είναι εφικτή η συνολική αξιολόγηση του υβριδικού μοντέλου και η ερμηνεία των αποτελεσμάτων. Όπως θα αναπτυχθεί και στη συνέχεια, η προσθήκη της μεθόδου WPD και του γραμμικού συνδυασμού καθιστά το μοντέλο υβριδικό και αξιοποιείται ώστε να αυξηθεί η ακρίβεια πρόβλεψης και να περιοριστούν τα πιθανά μειονεκτήματα που συνεπάγεται η αποκλειστική χρήση του δικτύου LSTM.



Σχήμα 5.2 : Μέθοδος αποσύνθεσης πακέτου κυματιδίων υβριδικού μοντέλου

Η μέθοδος WPD χρησιμοποιείται για να αναλύσει τις ιδιότητες του σήματος (χρονοσειρά ισχύος), παρέχοντας ορθογόνιες βάσεις πακέτων κυματιδίων μέσω μίας συνάρτησης χρονικού εντοπισμού συχνότητας [81]. Κάθε ιστορική χρονοσειρά Φ/Β παραγωγής ισχύος αποτελείται από ζώνες συνιστωσών διαφορετικής συχνότητας, παράγοντας ο οποίος δυσχεραίνει την άρτια εκπαίδευση του νευρωνικού δικτύου και κατά επέκταση τη συνολική ακρίβεια της πρόβλεψης. Σε αντίθεση με την απλή αποσύνθεση κυματιδίων (Wavelet Decomposition / WD) που εφαρμόζει μονόπλευρη αποσύνθεση και περιλαμβάνει μόνο βαθυπερατό φίλτρο, η WPD διαθέτει τόσο βαθυπερατό όσο και υψιπερατό φίλτρο καθιστώντας έτσι την αποσύνθεση πιο στοχευμένη και ακριβέστερη [82]. Η μέθοδος WPD αποσυνθέτει τη χρονοσειρά ισχύος σε συνιστώσες υψηλής και χαμηλής συχνότητας, σε μια προσπάθεια να διαχωριστεί η ταχεία μεταβολή και η τάση της χρονοσειράς, αντίστοιχα, και να βελτιωθεί η ποιότητα των δεδομένων. Η διαδικασία αυτή εκτελείται προκειμένου να απομονωθεί ο θόρυβος των δεδομένων εισόδου των τεσσάρων LSTM, διευκολύνοντας έτσι την αποτύπωση του μοτίβου μεταξύ των μεταβλητών εισόδου και της Φ/Β παραγωγής. Οι συνιστώσες χαμηλής συχνότητας συνήθως αντιπροσωπεύουν τα γεωγραφικά χαρακτηριστικά των δεδομένων (π.χ. θέση του ήλιου στον ορίζοντα, ηλιακή ακτινοβολία), ενώ οι συνιστώσες υψηλής συχνότητας τα μετεωρολογικά χαρακτηριστικά (π.χ. νεφώσεις, θερμοκρασία). Στην παρούσα διπλωματική εργασία επιλέχθηκε η συνάρτηση κυματιδίων της οικογένειας Daubechies τάξης 4 (db4), ενώ χρησιμοποιείται WPD δευτέρου επιπέδου, άρα ο αριθμός των επιμέρους υπο-σειρών ισούται με τέσσερα. Στην ίδια κατεύθυνση, η χρονοσειρά ισχύος υπόκειται σε μία αναγκαία προεπεξεργασία πριν την αποσύνθεσή της, η οποία περιλαμβάνει τις τεχνικές *robust scaling* και *reshape*, ώστε τα δεδομένα να αποκτήσουν την απαραίτητη μορφή. Προκειμένου να καταστεί εφικτό οι διαφορετικές συνιστώσες να εισαχθούν στα LSTMs, πρέπει να παρεμβληθεί η ανακατασκευή απλού κλάδου, ώστε να αποκτηθεί το σήμα συνιστώσας, το οποίο φέρει την ίδια δομή με το αρχικό σήμα, για να δημιουργηθούν στη συνέχεια οι υπο-σειρές [83].

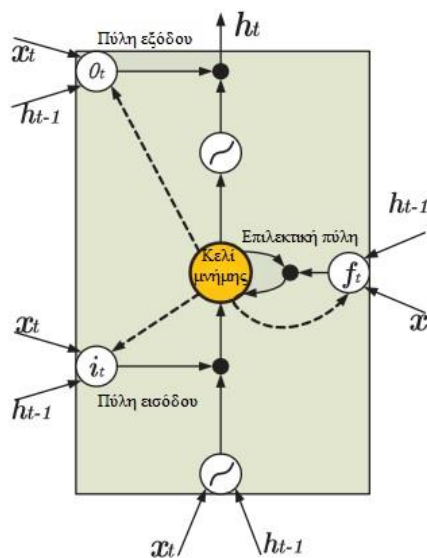


Σχήμα 5.3 : Δομή i -οστού LSTM υβριδικού μοντέλου

Τα δίκτυα LSTM αποτελούν μία υποκατηγορία των RNN, τα οποία έχουν κυριαρχήσει σε προβλήματα πρόβλεψης εξαιτίας της ικανότητάς τους να περιορίζουν γνωστές παθογένειες των υπολοίπων ANN. Αν και οι υπόλοιπες δομές RNN ανταποκρίνονται ικανοποιητικά σε σύνθετα προβλήματα συσχέτισης μη γραμμικών δεδομένων, το βασικό πλεονέκτημα των LSTM αφορά τη δυνατότητά τους να αποφεύγουν το πρόβλημα εξαφάνισης της κλίσης, όπως αναπτύχθηκε και στην Ενότητα 3.4. Ο ευρύτερα χρησιμοποιούμενος αλγόριθμος βελτιστοποίησης των ANN, η οπίσθια διάδοση σφάλματος, περιλαμβάνει τη διάδοση ενός σήματος σφάλματος από την έξοδο προς την είσοδο, ούτως ώστε η παραγόμενη έξοδος να συγκριθεί με την αναμενόμενη και να πραγματοποιηθεί η απαραίτητη αναπροσαρμογή των βαρών των συνάψεων. Ο αναδρομικός νευρώνας ενός LSTM – σε αντίθεση με τα υπόλοιπα RNN – διαθέτει μία επιλεκτική πύλη, η οποία του επιτρέπει να συγκρατεί μόνο τη χρήσιμη πληροφορία. Με αυτόν τον τρόπο, ελαχιστοποιείται τόσο η πιθανότητα εξαφάνισης του σήματος σφάλματος, όσο και της «έκρηξης» αυτού. Ωστόσο, ένα συχνό πρόβλημα των LSTMs και γενικά των μοντέλων ML αφορά το γεγονός πως όσο αυξάνονται οι απαιτήσεις ακρίβειας της τελικής πρόβλεψης, τόσο αυξάνεται και η ανάγκη για ποιοτικά δεδομένα εισόδου. Επομένως, γίνεται αντιληπτό πως τυχόν παρεμβαλλόμενος θόρυβος των μεταβλητών εισόδου μπορεί να μειώσει δραματικά την αξιοπιστία των LSTMs [84]. Για τον λόγο αυτόν στο παρόν υβριδικό μοντέλο προηγείται η μέθοδος WPD, ώστε να μειωθεί η επίδραση του θορύβου και να αυξηθεί η ποιότητα των δεδομένων με τα οποία τροφοδοτούνται τα τέσσερα επιμέρους δίκτυα LSTM. Όπως παρουσιάζεται στο Σχήμα 5.1, μετά τον διαχωρισμό της χρονοσειράς ισχύος σε τέσσερις επιμέρους υπο-σειρές, κάθε μία από αυτές συνενώνεται με τις υπόλοιπες μεταβλητές εισόδου, ώστε τα LSTMs να λάβουν στην είσοδο τόσο την αποσυντιθέμενη χρονοσειρά όσο και τα υπόλοιπα μετεωρολογικά δεδομένα. Επιπλέον, στο Σχήμα 5.3 απεικονίζεται η δομή καθενός εκ των τεσσάρων πανομοιότυπων LSTM που χρησιμοποιούνται

στην παρούσα διπλωματική εργασία. Με κόκκινο χρώμα σημειώνονται οι κόμβοι εισόδου, με μαύρο χρώμα οι κόμβοι των τριών κρυφών στρωμάτων, ενώ με πράσινο χρώμα ο μοναδικός κόμβος εξόδου. Είναι εμφανές πως οι κόμβοι εισόδου είναι τέσσερις, ένας για κάθε μεταβλητή του συνόλου δεδομένων και ο κόμβος εξόδου είναι μοναδικός, καθώς απαιτείται μόνο ένα ζητούμενο μέγεθος πρόβλεψης, η παραγωγή ενεργού ισχύος σε χρονικό ορίζοντα μίας ώρας. Ο αριθμός νευρώνων των τριών εσωτερικών στρωμάτων δεν είναι δεδομένος, διότι αποτελεί μία υπερ-παραμέτρο προς βελτιστοποίηση, η οποία θα αναλυθεί στην Ενότητα 5.3. Στο Σχήμα 5.3 οι νευρώνες του δικτύου LSTM παρουσιάζονται για σχεδιαστικούς λόγους με απλό κυκλικό σχήμα, σε αντιστοιχία με τους κόμβους ενός FFNN. Σημειώνεται σε αυτό το σημείο, πως τα LSTMs του υβριδικού μοντέλου αποτελούνται, προφανώς, από αναδρομικούς κόμβους ή ισοδύναμα κελιά μνήμης. Μία εναλλακτική αρχιτεκτονική για τα κελιά μνήμης των τεσσάρων LSTM δικτύων, πέραν του Σχήματος 3.10, παρουσιάζεται στο Σχήμα 5.4. Συνοψίζοντας, η βασική μεθοδολογία του κατασκευασμένου υβριδικού μοντέλου είναι η ακόλουθη:

- 1) Η αρχική χρονοσειρά ισχύος του Φ/Β σταθμού $X = (P_{t-N+1}, P_{t-N+2}, \dots, P_t)^T$, όπου P_t η παραγωγή του σταθμού τη χρονική στιγμή t και N ο χρονικός ορίζοντας, αποσυντίθεται μέσω της μεθόδου WPD σε τέσσερις συνιστώσες διαφορετικής συχνότητας x_1, x_2, x_3, x_4 και στη συνέχεια μέσω ανακατασκευής απλού κλάδου δημιουργούνται τέσσερις επιμέρους υπο-σειρές $S_i = (p_{i,t-N+1}, p_{i,t-N+2}, \dots, p_{i,t})^T, i = 1, 2, 3, 4$.
- 2) Κάθε υπο-σειρά S_i μαζί με το σύνολο των υπόλοιπων μετεωρολογικών δεδομένων $H_t = \{a_{1,t}, a_{2,t}, \dots, a_{k,t}\}$, όπου $a_{k,t}$ η τιμή της μεταβλητής k τη χρονική στιγμή t , τροφοδοτείται ως είσοδος σε ένα δίκτυο LSTM τριών κρυφών στρωμάτων, το οποίο προβλέπει την παραγωγή ισχύος P τη χρονική στιγμή $t + N$ καθώς πρόκειται για μοντέλο με ορίζοντα πρόβλεψης μίας ώρας με μετρήσεις μεταβλητών εισόδου ανά δεκαπέντε λεπτά.
- 3) Οι χρονοσειρές εξόδου των τεσσάρων LSTMs υπόκεινται στη μέθοδο γραμμικού συνδυασμού, ώστε να προκύψει για κάθε μία ο συντελεστής βάρους βάσει του οποίου βελτιστοποιείται η ακρίβεια της πρόβλεψης. Τελικά, προκύπτει η χρονοσειρά πρόβλεψης του υβριδικού μοντέλου, η οποία έχει μέγεθος ίσο με αυτό του συνόλου δεδομένων αξιολόγησης.



Σχήμα 5.4 : Αναδρομικός κόμβος LSTM του υβριδικού μοντέλου

5.3 ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΠΑΡΑΜΕΤΡΩΝ ΥΒΡΙΔΙΚΟΥ ΜΟΝΤΕΛΟΥ

Ο προσδιορισμός των βέλτιστων παραμέτρων ενός δικτύου LSTM αποτελεί καίρια διαδικασία για την ορθή και αποτελεσματική λειτουργία του. Με τον όρο «βέλτιστος» εννοείται ο συνδυασμός συγκεκριμένων τιμών των παραμέτρων, βάσει των οποίων ελαχιστοποιείται μία συγκεκριμένη συνάρτηση σφάλματος. Ο συνδυασμός των παραμέτρων ενός μοντέλου ML ανάγεται σε αναπόσπαστο κομμάτι κατά την κατασκευή του, καθώς είναι αδύνατο οι τιμές των παραμέτρων να είναι γνωστές ή να μπορούν να προσεγγιστούν εκ των προτέρων [85]. Το φαινόμενο αυτό συμβαίνει διότι η συμπεριφορά ενός μοντέλου ML στις απαιτήσεις και στα χαρακτηριστικά του εκάστοτε προβλήματος πρέπει να μελετάται ανά περίπτωση. Οι βέλτιστες τιμές των παραμέτρων επηρεάζονται από πληθώρα μοναδικών παραγόντων του προβλήματος, όπως το πλήθος των μεταβλητών εισόδου, η ποσότητα των διαθέσιμων δεδομένων, η συσχέτιση εισόδου – εξόδου και ευρύτερα η φύση της εφαρμογής. Επομένως, η βελτιστοποίηση των παραμέτρων ενός μοντέλου ML είναι μία ιδιαίτερα επίπονη και καθοριστική διαδικασία και για τον λόγο αυτόν έχουν αναπτυχθεί αρκετές τεχνικές εύρεσης των κατάλληλων τιμών των παραμέτρων. Οι κυριότερες κατηγορίες αυτών παρουσιάζονται στη συνέχεια [86]:

- Χειροκίνητη αναζήτηση (manual search): Στη μέθοδο manual search οι διαφορετικοί συνδυασμοί τιμών των παραμέτρων επιλέγονται από τον κατασκευαστή του μοντέλου και προσαρμόζονται ανάλογα με το αν βελτιώνεται η επιλεγμένη αντικειμενική συνάρτηση. Η συγκεκριμένη αναζήτηση είναι η κυρίαρχη τεχνική βελτιστοποίησης μοντέλων ML εξαιτίας της απλότητάς της και της εξοικείωσης των ανθρώπων με τη μέθοδο δοκιμή – σφάλμα (trial and error). Ωστόσο, δεν θεωρείται δεδομένο πως θα βρεθεί ο βέλτιστος συνδυασμός τιμών, καθώς η μέθοδος δεν είναι συνεπής και προϋποθέτει την αυξημένη γνώση και εμπειρία του κατασκευαστή. Στην παρούσα διπλωματική εργασία, επιλέχθηκε χειροκίνητη αναζήτηση για τη βελτιστοποίηση των παραμέτρων του υβριδικού μοντέλου. Για ορισμένες παραμέτρους, η χειροκίνητη αναζήτηση επιτελέστηκε με χρήση επαναληπτικών βρόχων. Οι συνθήκες των επαναληπτικών βρόχων ορίστηκαν έτσι ώστε να εξασφαλιστεί η εύρεση ενός συνδυασμού παραμέτρων όσο πιο κοντά γίνεται στον βέλτιστο συνδυασμό, κρατώντας παράλληλα το συνολικό υπολογιστικό κόστος σε χαμηλά επίπεδα.
- Αναζήτηση πλέγματος (grid search): Κατά τη βελτιστοποίηση παραμέτρων με τη μέθοδο grid search, το συνολικό πεδίο ορισμού των παραμέτρων διαιρείται σε ένα διακριτό πλέγμα και ο αλγόριθμος δοκιμάζει όλους τους πιθανούς συνδυασμούς τιμών προσπαθώντας να εντοπίσει το ολικό ελάχιστο της συνάρτησης σφάλματος. Αν και η συγκεκριμένη μέθοδος είναι η ακριβέστερη, καθώς ελέγχει όλες τις δυνατές τιμές για κάθε παράμετρο, πρόκειται για μια εξαντλητική διαδικασία η οποία απαιτεί εξαιρετικά μεγάλο υπολογιστικό χρόνο, ειδικά για σύνθετα μοντέλα με πολλές παραμέτρους και πολυάριθμους νευρώνες.
- Μεταερευρητικοί (metaheuristic) αλγόριθμοι: Οι μεταερευρητικές μέθοδοι έχουν αναδειχθεί τελευταία σε μία δημοφιλή επιλογή για την επίλυση απαιτητικών προβλημάτων βελτιστοποίησης. Έχουν τη δυνατότητα να παρέχουν μία ικανοποιητική λύση δίχως να χρειάζονται εκτεταμένη υπολογιστική και χρονική πολυπλοκότητα. Οι συγκεκριμένοι αλγόριθμοι είναι στοχαστικοί και λειτουργούν προσομοιάζοντας κάποια φυσική συμπεριφορά, με το μεγαλύτερο πλεονέκτημά τους να οφείλεται στο γεγονός ότι

παρουσιάζουν αυξημένη ταχύτητα, καθώς αναζητούν «επαρκείς» και όχι απόλυτα βέλτιστες τιμές παραμέτρων [87].

- Bayesian αλγόριθμοι: Η βελτιστοποίηση υπερ-παραμέτρων με χρήση τέτοιων αλγορίθμων προϋποθέτει μία συνάρτηση με παρουσία θορύβου, η οποία φέρει την προσέγγιση «μαύρου κουτιού» (black-box) και απεικονίζει τις παραμέτρους σε έναν συγκεκριμένο στόχο (π.χ. βελτίωση της ακρίβειας πρόβλεψης). Οι εν λόγω αλγόριθμοι συγκεντρώνουν τις υπερ-παραμέτρους ως εισόδους και την απόδοση του μοντέλου ως παρατηρήσεις της συγκεκριμένης συνάρτησης και προσπαθούν να αντλήσουν πληροφορίες για τον προσδιορισμό της. Ο όρος απόδοση μπορεί να περιλαμβάνει είτε κάποια συνάρτηση σφάλματος, είτε κάποιον άλλον τρόπο μέτρησης της αποτελεσματικότητας του μοντέλου ML [88].

5.3.1 Υπολογιζόμενα σφάλματα

Όπως έχει αναπτυχθεί αναλυτικά στην Ενότητα 3.2, κατά την επιτηρούμενη εκπαίδευση ενός ANN, αυτό τροφοδοτείται με ένα σύνολο δεδομένων εισόδου, το οποίο περιέχει τόσο τις μεταβλητές εισόδου όσο και την επιθυμητή έξοδο ή αλλιώς μεταβλητή στόχο. Στην παρούσα διπλωματική εργασία, κάθε LSTM εκπαιδεύεται με σκοπό να προσεγγίσει τη μεταβλητή στόχο actual power μέσω ελαχιστοποίησης του μέσου τετραγωνικού σφάλματος (MSE):

$$MSE = \frac{1}{N} \cdot \sum_{i=1}^N [OUT_{forecast,i} - OUT_{actual,i}]^2 \quad (5.1)$$

όπου N ο αριθμός επαναλήψεων, $OUT_{forecast,i}$ και $OUT_{actual,i}$ η προβλεπόμενη και η αναμενόμενη έξοδος από το LSTM στην i -οστή επανάληψη, αντίστοιχα. Επίσης, στην Ενότητα 5.2 αναλύθηκε ο ρόλος της μεθόδου γραμμικού συνδυασμού, η οποία εφαρμόζεται στα τέσσερα επιμέρους αποτελέσματα των δικτύων LSTM. Προκειμένου να υπολογιστεί ο συντελεστής βάρους για κάθε ένα από τα τέσσερα αποτελέσματα, επιλέχθηκε ο συνδυασμός των τιμών που ελαχιστοποιεί την τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος (Root Mean Squared Error / RMSE):

$$RMSE = \sqrt{\frac{\sum_{i=1}^N [OUT_{forecast,i} - OUT_{actual,i}]^2}{N}} \quad (5.2)$$

5.3.2 Μεθοδολογία βελτιστοποίησης

Το υβριδικό μοντέλο της παρούσας διπλωματικής εργασίας, αποτελείται από τρεις βασικές επιμέρους μεθόδους – όπως επεξηγήθηκε στην Ενότητα 5.2 – επομένως κατά την κατασκευή του παρεμβάλλεται πληθώρα υπερ-παραμέτρων, οι οποίες επηρεάζουν την ακρίβεια και την απόδοση του μοντέλου. Για το σύνολο των παραμέτρων του παρόντος μοντέλου επιλέχθηκε η μέθοδος manual search, με χρήση επαναληπτικών βρόχων ανά

περιπτώσεις. Αρχικά, στη μέθοδο WPD επιλέχθηκε η συνάρτηση κυματιδίων της οικογένειας Daubechies τάξης 4 (db4), σε αντίθεση με το άρθρο των Li, Zhou, Lu και Yang (2020) [1] στο οποίο προτείνεται η χρήση της τάξης 3 (db3). Όσο η τάξη της συνάρτησης κυματιδίων αυξάνεται, τόσο η ικανότητα αποσύνθεσης της μεθόδου βελτιώνεται, γεγονός, βέβαια, που την καθιστά πιο σύνθετη υπολογιστικά και αυξάνει την χρονική πολυπλοκότητα [89].

Αδιαμφισβήτητα, η πλειονότητα των υπερ-παραμέτρων του υβριδικού μοντέλου εντοπίζεται στη δομή των LSTMs και για αυτόν τον λόγο ο προσδιορισμός του βέλτιστου συνδυασμού τιμών είναι αρκετά χρονοβόρος. Στην παρούσα διπλωματική εργασία, όλα τα επιμέρους δίκτυα LSTM είναι πανομοιότυπα, τόσο σε αρχιτεκτονική όσο και στις τιμές των υπερ-παραμέτρων τους, ώστε να μειωθεί η συνολική υπολογιστική πολυπλοκότητα της βελτιστοποίησης παραμέτρων. Οι παράμετροι του υβριδικού μοντέλου που βελτιστοποιήθηκαν μέσω επαναληπτικών βρόχων, καθώς και η σημασία τους, περιγράφονται στη συνέχεια [90]:

- Αριθμός επαναλήψεων (epochs): Προσδιορίζει τον αριθμό των φορών που ο αλγόριθμος βελτιστοποίησης θα επεξεργαστεί ολόκληρο το σύνολο δεδομένων εκπαίδευσης. Κάθε μία επανάληψη συνεπάγεται πως κάθε δείγμα στο σύνολο δεδομένων εκπαίδευσης έχει την ευκαιρία να ενημερώσει τις εσωτερικές παραμέτρους του μοντέλου μία φορά.
- Αριθμός νευρώνων κρυφών στρωμάτων LSTM (units): Καθορίζει τον αριθμό των αναδρομικών κόμβων καθενός από τα τρία κρυφά στρώματα των LSTMs. Στην παρούσα εργασία, και τα τρία κρυφά στρώματα όλων των δικτύων LSTM διαθέτουν τον ίδιο αριθμό νευρώνων. Όσο οι κόμβοι των κρυφών στρωμάτων αυξάνονται, το μοντέλο καθίσταται συνολικά πιο πολύπλοκο και απαιτεί περισσότερο υπολογιστικό χρόνο.
- Συνάρτηση ενεργοποίησης (activation function): Χρησιμοποιείται για να υπολογίσει την έξοδο των κόμβων του LSTM, πραγματοποιώντας την κατάλληλη τροποποίηση στις τιμές των σημάτων εισόδου κάθε κόμβου. Συνήθεις συναρτήσεις ενεργοποίησης περιγράφονται στην Ενότητα 3.2. Στο κατασκευασμένο υβριδικό μοντέλο συνάρτηση ενεργοποίησης εφαρμόζεται μόνο στον κόμβο εξόδου και όχι στους κόμβους των κρυφών στρωμάτων.
- Μέγεθος παρτίδας (batch size): Ελέγχει τον αριθμό δειγμάτων εκπαίδευσης που υπόκεινται σε επεξεργασία από το δίκτυο, πριν ενημερωθούν οι εσωτερικές παράμετροί του. Όσο το μέγεθος παρτίδας αυξάνεται, τόσο περισσότερα δεδομένα λαμβάνονται υπόψη ανά επανάληψη για την αναπροσαρμογή των βαρών των συνάψεων του LSTM. Το μέγεθος παρτίδας μπορεί, θεωρητικά, να λάβει τιμές από 1 έως και τον αριθμό των δειγμάτων του συνόλου εκπαίδευσης.

Πέραν των προαναφερθέντων παραμέτρων, υπάρχουν ορισμένες ακόμα οι οποίες δεν βελτιστοποιήθηκαν συστηματικά με χρήση επαναληπτικών βρόχων, αλλά με τη μέθοδο trial and error. Οι συγκεκριμένες παράμετροι αναφέρονται ακολούθως:

- Εγκατάλειψη (dropout): Το dropout είναι μία πιθανοτική παράμετρος, η οποία προσδίδει στους κόμβους των LSTMs τη δυνατότητα να αγνοούν ορισμένα από τα δεδομένα με τα οποία τροφοδοτούνται. Διαθέτει εύρος τιμών από 0, όπου λαμβάνονται υπόψη όλα τα δεδομένα, έως 1, όπου δεν λαμβάνεται υπόψη καμία είσοδος για τον συγκεκριμένο κόμβο. Στην πράξη, καθορίζει την πιθανότητα ένα σήμα εισόδου ενός κόμβου να εξαιρεθεί από τη

διαδικασία αναπροσαρμογής των βαρών. Χρησιμοποιείται για να αποφευχθεί το φαινόμενο υπερπροσαρμογής, το οποίο αναλύεται στην Ενότητα 5.3. Στην τρέχουσα διπλωματική εργασία, το dropout εφαρμόζεται αποκλειστικά στους κόμβους των κρυφών στρωμάτων και όχι σε αυτούς των στρωμάτων εισόδου ή εξόδου.

- Αλγόριθμος βελτιστοποίησης (optimizer): Αναφέρεται στη μέθοδο με την οποία εκπαιδεύεται το υβριδικό μοντέλο και στην προσπάθεια σε κάθε επανάληψη να ελαχιστοποιηθεί η συνάρτηση σφάλματος. Περισσότερα για τους αλγόριθμους βελτιστοποίησης αναπτύσσονται στην Ενότητα 3.3.
- Υπομονή (patience): Προσδιορίζει τον αριθμό των επαναλήψεων, κατά την εκπαίδευση του μοντέλου, για τις οποίες αν δεν παρατηρείται βελτίωση της ακρίβειας (μείωση της συνάρτησης σφάλματος) πραγματοποιείται διακοπή της διαδικασίας εκπαίδευσης.

Από το Σχήμα 5.1 είναι εμφανές πως μετά τη μέθοδο αποσύνθεσης WPD και τα τέσσερα δίκτυα LSTM, ακολουθεί η μέθοδος γραμμικού συνδυασμού. Με τη συγκεκριμένη διαδικασία υπολογίζεται κατά πόσο συνεισφέρει κάθε μία από τις τέσσερις επιμέρους παραγόμενες από τα LSTM χρονοσειρές, στα τελικά αποτελέσματα. Το κριτήριο επιλογής αφορά το ποιος βέλτιστος συνδυασμός βαρών w_1, w_2, w_3, w_4 , ελαχιστοποιεί το υπολογιζόμενο RMSE. Προφανώς, μιας και πρόκειται για συντελεστές βάρους, η διαδικασία εύρεσης των βέλτιστων τιμών διεξάγεται υπό τη συνθήκη:

$$w_1 + w_2 + w_3 + w_4 = 1 \quad (5.3)$$

5.3.3 Αποτελέσματα βελτιστοποίησης

Στον Πίνακα 5.1 παρουσιάζονται οι παράμετροι του υβριδικού μοντέλου που βελτιστοποιήθηκαν με χρήση επαναληπτικών βρόχων, ενώ στον Πίνακα 5.2 καταγράφονται οι παράμετροι οι οποίες βελτιστοποιήθηκαν μέσω trial and error των υπολογιζόμενων σφαλμάτων, καθώς και οι ελεγχόμενες τιμές. Μέσω των Πινάκων 5.1 και 5.2 καθίσταται σαφές πως η αύξηση του αριθμού επαναλήψεων και των νευρώνων των κρυφών στρωμάτων δεν συνεπάγεται πάντα βελτίωση της ακρίβειας των παραγόμενων προβλέψεων. Διαισθητικά, όσο το LSTM γίνεται πιο σύνθετο αρχιτεκτονικά και οι επαναλήψεις αυξάνονται, αναμένεται η απόδοσή του να παρουσιάζει αντίστοιχη βελτίωση. Στην πραγματικότητα όμως, αυτό σπανίως παρατηρείται στα ANN εξαιτίας του φαινομένου της υπερπροσαρμογής (overfitting). Όπως έχει ήδη αναφερθεί, ένα ANN εκπαιδεύεται και αξιολογείται με διαφορετικά δεδομένα, ώστε να διασφαλίζεται η αξιοπιστία του. Ωστόσο, είναι συχνό τα ANN να εκπαιδεύονται «δογματικά» και να απομνημονεύουν τα δεδομένα εκπαίδευσης συμπεριλαμβανομένου του θορύβου, αντί να αποτυπώνουν ανεξάρτητα τη συσχέτιση μεταξύ εισόδου – εξόδου [91]. Σε αυτή την περίπτωση, όταν το μοντέλο τροφοδοτείται με νέα δεδομένα εισόδου πέραν αυτών της εκπαίδευσης, αδυνατεί να αναγνωρίσει τα σύνθετα μοτίβα και να προσεγγίσει την αναμενόμενη έξοδο, παρουσιάζοντας μειωμένη αποτελεσματικότητα. Συχνά χρησιμοποιούμενες τεχνικές για την αποφυγή του overfitting αποτελούν η πρόωμη διακοπή εκπαίδευσης όταν ο αλγόριθμος βελτιστοποίησης δεν ελαχιστοποιεί την αντικειμενική συνάρτηση, η απλοποίηση της δομής του ANN, και η επέκταση του συνόλου εκπαίδευσης.

Πίνακας 5.1 : Αποτελέσματα βελτιστοποίησης παραμέτρων υβριδικού μοντέλου με χρήση επαναληπτικού βρόχου

| Παράμετρος | Εύρος τιμών | Βήμα | Βέλτιστη τιμή |
|---------------------|--|------|---------------|
| epochs | [10, 300] | 10 | 50 |
| units | [10, 100] | 10 | 10 |
| activation function | [sigmoid, tanh, softmax, relu, leaky relu] | - | relu |
| batch size | [16, 2048] | 16 | 32 |
| w_1 | [0,1, 1] | 0,1 | 0,7 |
| w_2 | [0,1, 1] | 0,1 | 0,1 |
| w_3 | [0,1, 1] | 0,1 | 0,1 |
| w_4 | [0,1, 1] | 0,1 | 0,1 |

Πίνακας 5.2 : Αποτελέσματα βελτιστοποίησης παραμέτρων υβριδικού μοντέλου με trial and error

| Παράμετρος | Δοκιμαζόμενες τιμές | Βέλτιστη τιμή |
|------------|---------------------|---------------|
| dropout | 0,1, 0,2, 0,3 | 0,3 |
| optimizer | SGD, Adam, Adamax | Adam |
| patience | 10, 20, 30 | 20 |

5.4 ΑΡΙΘΜΗΤΙΚΗ ΑΝΑΠΑΡΑΣΤΑΣΗ ΩΡΑΣ ΣΤΑ ΔΕΔΟΜΕΝΑ ΕΙΣΟΔΟΥ

Καθώς τα ANN δεν διαθέτουν πρότερη γνώση ή εκπαίδευση, οποιαδήποτε συσχέτιση μεταξύ εισόδου και εξόδου βασίζεται εξ ολοκλήρου στα δεδομένα, στις εμπλεκόμενες υπερ-παραμέτρους και ευρύτερα στη φύση του εκάστοτε προβλήματος. Επί της ουσίας, όπως αναλύθηκε και στην Ενότητα 2.5, ο συγκεκριμένος παράγοντας μπορεί να αποτελέσει ένα από τα σημαντικότερα πλεονεκτήματα των μοντέλων ML, καθώς στην παραγωγή των αποτελεσμάτων δεν υπεισέρχεται η ανθρώπινη προκατάληψη. Ωστόσο, το γεγονός αυτό είναι πιθανό να λάβει αρνητική τροπή, καθώς οποιοδήποτε φαινόμενο όσο προφανές και να είναι για τον άνθρωπο, πρέπει να έχει ποσοτικοποιηθεί προκειμένου να αποτυπωθεί από κάποιο ANN. Για παράδειγμα, είναι ευρέως γνωστό πως η παραγωγή ενός Φ/Β σταθμού είναι μηδενική τις βραδινές ώρες, αυξάνεται σταδιακά από το πρωί έως το μεσημέρι και στη συνέχεια μειώνεται. Παρόλα αυτά, η συγκεκριμένη μεταβολή της Φ/Β παραγωγής δεν είναι γνωστή εκ των προτέρων σε κάποιο ANN και η μόνη συσχέτιση που μπορεί να εντοπιστεί αφορά την προσπίπτουσα ηλιακή ακτινοβολία στους ηλιακούς συλλέκτες. Επιπλέον, διφορούμενες μεταβλητές, όπως η θερμοκρασία, είναι πιθανό να δυσχεραίνουν ακόμη περισσότερο την αποτύπωση των μοτίβων από το ANN, καθώς, όπως αναφέρεται στην Ενότητα 2.4, η ιδανική θερμοκρασία λειτουργίας ενός ηλιακού συλλέκτη ανέρχεται στους 25°C. Υπό πραγματικές συνθήκες όμως, είναι πολύ πιθανό η θερμοκρασία αυτή να ξεπεραστεί εντός της ημέρας πριν μεγιστοποιηθεί η προσπίπτουσα ηλιακή ακτινοβολία, δημιουργώντας με αυτόν τον τρόπο δύο αντικρουόμενες μεταβλητές. Αν και τα δίκτυα LSTM προορίζονται για σύνθετα και μη γραμμικά προβλήματα, γίνεται εμφανές πως η ποιότητα, η ποσότητα, και το είδος των μεταβλητών εισόδου ενός μοντέλου ML αποτελούν σε κάθε περίπτωση παράγοντα καίριας σημασίας για την παραγωγή αξιόπιστων αποτελεσμάτων.

5.4.1 Μεθοδολογία αριθμητικής αναπαράστασης

Το υβριδικό μοντέλο των Li, Zhou, Lu και Yang [1] χρησιμοποιεί ως δεδομένα εισόδου για τα δίκτυα LSTM, πέρα από την ιστορική χρονοσειρά ισχύος της Φ/Β παραγωγής, την παγκόσμια οριζόντια ακτινοβολία, τη διάχυτη οριζόντια ακτινοβολία, τη θερμοκρασία περιβάλλοντος, την ταχύτητα ανέμου και τη σχετική υγρασία. Αντιθέτως, το υβριδικό μοντέλο αυτής της διπλωματικής εργασίας βασίζεται για την πρόβλεψη της Φ/Β παραγωγής στην ιστορική χρονοσειρά ισχύος, στη θερμοκρασία περιβάλλοντος, στη θερμοκρασία του συλλέκτη και στην προσπίπτουσα ηλιακή ακτινοβολία. Είναι σαφές πως όσο πιο ποικίλα, ποιοτικά και σχετικά είναι τα δεδομένα εισόδου ενός ANN, τόσο διευκολύνεται η εκπαίδευση και η αξιολόγησή του αυξάνοντας την ακρίβεια των προβλέψεων. Σε αυτή την κατεύθυνση, σε μία προσπάθεια βελτίωσης της συμπεριφοράς των δικτύων LSTM προστίθεται μία επιπλέον μεταβλητή εισόδου, η οποία αφορά την αριθμητική αναπαράσταση της ώρας των αρχικών δεδομένων. Η Φ/Β παραγωγή παρουσιάζει έντονη ημερήσια περιοδικότητα και τα χαρακτηριστικά της εξαρτώνται σε μεγάλο βαθμό από τη χρονική στιγμή μέσα στην ημέρα, αν πρόκειται δηλαδή για στιγμή έναρξης, μεγιστοποίησης ή διακοπής της ημερήσιας παραγωγής. Ουσιαστικά, η ιδανική καμπύλη της Φ/Β παραγωγής ακολουθεί ένα παρόμοιο μοτίβο καθημερινά και φέρει τη χαρακτηριστική γραφική παράσταση «καμπάνας», σε αντίθεση π.χ. με την αιολική παραγωγή, που είναι σε πολύ μεγαλύτερο βαθμό στοχαστική. Λόγω αυτής της περιοδικότητας, είναι επιθυμητή η υποβοήθηση του νευρωνικού δικτύου με την εισαγωγή της ώρας ως μεταβλητή εισόδου, ώστε να μπορεί ευκολότερα να εντοπίσει τη συσχέτιση αυτή. Στο υβριδικό μοντέλο των Li, Zhou, Lu και Yang δεν χρησιμοποιείται η ώρα ως δεδομένο εισόδου, διότι υποκαθίσταται με την τέλεια πρότερη γνώση της ηλιακής ακτινοβολίας. Οι μετρήσεις του χρησιμοποιούμενου συνόλου δεδομένων έχουν πραγματοποιηθεί για όλη τη διάρκεια της ημέρας ανά δεκαπέντε λεπτά και για αυτόν τον λόγο φέρουν χρονική σήμανση (timestamp) της μορφής XX:00, XX:15, XX:30, XX:45, όπου XX η αντίστοιχη ώρα της ημέρας, η οποία λαμβάνει τιμές από 00 έως 23. Κάθε timestamp αντικαθίσταται από μία ποσοτικοποιημένη τιμή αντιστοιχίζοντας την ώρα 00:00 με την τιμή 0, αυξάνοντας την με βήμα 0,25 ανά μέτρηση των μεταβλητών (δεκαπέντε λεπτά). Η νέα μεταβλητή με το όνομα Time, λαμβάνει τη μέγιστη τιμή που ισούται με 12 στις 12:00 κάθε ημέρας και στη συνέχεια μειώνεται με βήμα 0,25 μέχρι να λάβει ξανά την τιμή 0 (Πίνακας 5.3). Η μεταβλητή της αριθμητικής αναπαράστασης ακολουθεί περιοδική μεταβολή με περίοδο 24 ωρών, ελάχιστη τιμή ίση με 0 και μέγιστη ίση με 12. Ο λόγος που επιλέχθηκε η συγκεκριμένη ποσοτικοποίηση της ώρας, αφορά στην προσομοίωση της με την πορεία του ήλιου στον ορίζοντα και τη γωνία απόκλισης δ , όπως αυτή περιεγράφηκε στην Ενότητα 2.5. Ποιοτικά, πρόκειται για μία προσπάθεια το LSTM να κατανοήσει την ανατολή και τη δύση του ήλιου κατά τη διάρκεια της ημέρας, ώστε να αναγνωρίσει το μοτίβο μηδενικής Φ/Β παραγωγής τις βραδινές ώρες, αυξανόμενης έως τις μεσημβρινές και ξανά μειούμενης έως τις βραδινές. Παρατηρήθηκε πως τα υπολογιζόμενα σφάλματα του μοντέλου ήταν μικρότερα με χρήση αυτής της επιπλέον μεταβλητής, καθώς προσεγγίζεται ακριβέστερα η καμπύλη της πραγματικής παραγωγής. Επομένως, όλα τα παραγόμενα αποτελέσματα του Κεφαλαίου 6 βασίζονται στο συγκεκριμένο βελτιωμένο υβριδικό μοντέλο, με κάθε LSTM να χρησιμοποιεί πλέον πέντε χαρακτηριστικά εισόδου αντί για τέσσερα. Η μοναδική μεταβολή στη δομή του τροποποιημένου υβριδικού μοντέλου είναι πως στο Σχήμα 5.3 το στρώμα εισόδου αποτελείται από πέντε νευρώνες (υπο-σειρά παραγωγής, θερμοκρασία περιβάλλοντος, θερμοκρασία συλλέκτη, προσπίπτουσα ηλιακή ακτινοβολία, αριθμητική αναπαράσταση ώρας).

Πίνακας 5.3 : Αριθμητική αναπαράσταση ώρας στα δεδομένα εισόδου

| | | | | | | | | | | | | |
|-------------|-------|-------|-------|-------|-------|-----|-------|-------|-------|-----|-------|-------|
| Ωρα | 00:00 | 00:15 | 00:30 | 00:45 | 01:00 | ... | 11:45 | 12:00 | 12:15 | ... | 23:45 | 00:00 |
| Τιμή | 0 | 0,25 | 0,5 | 0,75 | 1 | ... | 11,75 | 12 | 11,75 | ... | 0,25 | 0 |

5.4.2 Αποτελέσματα βελτιστοποίησης

Εφόσον μεταβλήθηκαν τα χαρακτηριστικά των τεσσάρων επιμέρους LSTM ήταν απαραίτητο να επαναληφθεί η διαδικασία βελτιστοποίησης των εμπλεκόμενων υπερ-παραμέτρων τους. Η συγκεκριμένη διαδικασία πραγματοποιήθηκε με πανομοιότυπο τρόπο και τα αποτελέσματά της παρουσιάζονται στους Πίνακες 5.4 και 5.5. Όλα τα αποτελέσματα, τα διαγράμματα και οι εφαρμογές της συγκεκριμένης διπλωματικής εργασίας έχουν προκύψει από το βελτιωμένο υβριδικό μοντέλο με χρήση της αριθμητικής αναπαράστασης της ώρας και τις υπερ-παραμέτρους των Πινάκων 5.4 και 5.5. Σημειώνεται πως το βελτιωμένο υβριδικό μοντέλο εκπαιδεύεται ομοίως με το 50% του συνολικού συνόλου δεδομένων και αξιολογείται με το υπόλοιπο 50%. Επομένως, οι παραγόμενες προβλέψεις Φ/Β παραγωγής αφορούν τους μήνες Ιούλιο – Δεκέμβριο.

Πίνακας 5.4 : Αποτελέσματα βελτιστοποίησης παραμέτρων βελτιωμένου υβριδικού μοντέλου με χρήση επαναληπτικού βρόχου

| Παράμετρος | Εύρος τιμών | Βήμα | Βέλτιστη τιμή |
|---------------------|--|------|---------------|
| epochs | [10, 300] | 10 | 100 |
| units | [10, 100] | 10 | 40 |
| activation function | [sigmoid, tanh, softmax, relu, leaky relu] | - | relu |
| batch size | [16, 2048] | 16 | 32 |
| w_1 | [0,1, 1] | 0,1 | 0,7 |
| w_2 | [0,1, 1] | 0,1 | 0,1 |
| w_3 | [0,1, 1] | 0,1 | 0,1 |
| w_4 | [0,1, 1] | 0,1 | 0,1 |

Πίνακας 5.5 : Αποτελέσματα βελτιστοποίησης παραμέτρων βελτιωμένου υβριδικού μοντέλου με trial and error

| Παράμετρος | Δοκιμαζόμενες τιμές | Βέλτιστη τιμή |
|------------|---------------------|---------------|
| dropout | 0,1, 0,2, 0,3 | 0,2 |
| optimizer | SGD, Adam, Adamax | Adam |
| patience | 10, 20, 30 | 20 |

ΑΠΟΤΕΛΕΣΜΑΤΑ

6.1 ΑΝΑΛΥΣΗ ΥΠΟΛΟΓΙΖΟΜΕΝΩΝ ΣΦΑΛΜΑΤΩΝ

Η ερμηνεία και η ανάλυση των αποτελεσμάτων ενός προβλήματος πρόβλεψης είναι μία διαδικασία η οποία δεν υπολείπεται σε αξία συγκριτικά με την επεξεργασία των δεδομένων και την κατασκευή του χρησιμοποιούμενου μοντέλου. Προκειμένου να αξιολογηθεί η ακρίβεια των προβλεπόμενων τιμών, είναι απαραίτητο να υπολογιστούν τα μετρητικά σφάλματος (error metrics), ώστε να διασφαλιστεί η αντικειμενικότητα της αξιολόγησης. Τα error metrics είναι ένας τρόπος ποσοτικοποίησης της απόδοσης ενός μοντέλου και παρέχουν τη δυνατότητα σύγκρισης διαφορετικών μεθόδων και μοντέλων. Ωστόσο, κάθε εξεταζόμενο μετρητικό ποσοτικοποιεί διαφορετικά την απόδοση της πρόβλεψης. Επομένως, η επιλογή του κατάλληλου error metric χρήζει ιδιαίτερης προσοχής και διαφέρει ανάλογα των χαρακτηριστικών και των απαιτήσεων του προβλήματος [92].

Στην Ενότητα 5.3 αναπτύχθηκε τόσο η συνάρτηση σφάλματος για τη βελτιστοποίηση των παραμέτρων των τεσσάρων LSTM του υβριδικού μοντέλου (MSE), όσο και το σφάλμα προς ελαχιστοποίηση για τον υπολογισμό των συντελεστών βάρους της μεθόδου γραμμικού συνδυασμού (RMSE). Για την αξιολόγηση των αποτελεσμάτων του βελτιωμένου υβριδικού μοντέλου της παρούσας διπλωματικής εργασίας χρησιμοποιούνται τα τρία ακόλουθα μετρητικά σφάλματος:

- RMSE (εξίσωση (5.2))
- Μέσο απόλυτο σφάλμα (Mean Absolute Error / MAE):

$$MAE = \frac{1}{N} \cdot \sum_{i=1}^N |OUT_{forecast,i} - OUT_{actual,i}| \quad (6.1)$$

- Κανονικοποιημένο μέσο απόλυτο σφάλμα (Normalized Mean Absolute Error / NMAE):

$$NMAE (\%) = \frac{\frac{1}{N} \cdot \sum_{i=1}^N |OUT_{forecast,i} - OUT_{actual,i}|}{P_{nom}} \cdot 100\% \quad (6.2)$$

όπου P_{nom} η ονομαστική εγκατεστημένη ισχύς του Φ/Β σταθμού, η οποία ισούται με 500 kW για τα δεδομένα του εξεταζόμενου Φ/Β σταθμού της παρούσας διπλωματικής εργασίας.

Σε ορισμένα προβλήματα πρόβλεψης είναι πιθανό η αξιολόγηση του χρησιμοποιούμενου μοντέλου να είναι πιο αποτελεσματικό να πραγματοποιηθεί βάσει του σχετικού και όχι του απόλυτου σφάλματος. Μετρητικά σφάλματος όπως το RMSE και το MAE υπολογίζουν την απόλυτη ακρίβεια πρόβλεψης, ωστόσο επηρεάζονται σημαντικά από την τάξη μεγέθους των αντίστοιχων μεταβλητών. Αντίθετα, μετρητικά σφάλματος όπως το μέσο απόλυτο ποσοστιαίο σφάλμα (Mean Absolute Percentage Error / MAPE), υπολογίζουν το σχετικό σφάλμα, απαλείφοντας την τάξη μεγέθους των δεδομένων. Ο τρόπος υπολογισμού του MAPE περιγράφεται από την εξίσωση (6.3).

$$MAPE (\%) = \frac{1}{N} \cdot \sum_{i=1}^N \frac{|OUT_{forecast,i} - OUT_{actual,i}|}{OUT_{actual,i}} \cdot 100\% \quad (6.3)$$

Το MAPE αποτελεί μία αρκετά δημοφιλή επιλογή για τη σύγκριση της απόδοσης διαφορετικών μοντέλων, λόγω της αξιολόγησης υπό κοινή βάση, αλλά και της απλότητάς του. Ωστόσο, στην περίπτωση της Φ/Β πρόβλεψης συναντά ένα πολύ σημαντικό μειονέκτημα, τη διαίρεση με μηδενικές τιμές. Όπως φαίνεται στην εξίσωση (6.3), η απόλυτη διαφορά μεταξύ προβλεπόμενης και πραγματικής τιμής διαιρείται με την πραγματική τιμή και στη συνέχεια υπολογίζεται η μέση τιμή αυτής της παράστασης για όλες τις προβλέψεις. Σε προβλήματα πρόβλεψης Φ/Β παραγωγής είναι αναμενόμενο το σύνολο δεδομένων να περιέχει πολλές μηδενικές τιμές, εξαιτίας της μηδενικής παραγωγής σε μεγάλο χρονικό διάστημα της ημέρας, καθώς επίσης και τιμές που προσεγγίζουν το μηδέν, τις πρώτες πρωινές και τις τελευταίες απογευματινές ώρες. Επομένως, το MAPE δεν αποτελεί ιδανική επιλογή μετρητικού σφάλματος στην παρούσα διπλωματική εργασία.

Στον αντίποδα, η χρήση του NMAE δεν παρουσιάζει το συγκεκριμένο μειονέκτημα και έχει τη δυνατότητα να αξιολογεί την απόδοση των μοντέλων διαιρώντας την απόκλιση της πρόβλεψης με το κοινό μέγεθος της ονομαστικής εγκατεστημένης ισχύος του Φ/Β σταθμού. Η μέθοδος αυτή αξιολογεί αντικειμενικά τα παραγόμενα αποτελέσματα, καθώς λαμβάνει υπόψη πως όσο αυξάνεται η ισχύς του σταθμού, τόσο δυσκολότερο είναι να προσεγγιστεί με ακρίβεια η πραγματική τιμή. Για παράδειγμα, σε ένα υποθετικό σενάριο ενός Φ/Β σταθμού εγκατεστημένης ισχύος 100 kW σε μία χρονική στιγμή με πραγματική παραγωγή 80 kW και πρόβλεψη 40 kW, το MAE ισούται με 40 kW και το NMAE με 40%. Σε ένα δεύτερο υποθετικό σενάριο για έναν Φ/Β σταθμό ισχύος 600 kW, με πραγματική παραγωγή 500 kW και πρόβλεψη 400kW, το MAE ισούται με 100 kW και το NMAE με 17%. Είναι σαφές πως η πρόβλεψη στο πρώτο σενάριο είναι στην πραγματικότητα χειρότερη από την πρόβλεψη στο δεύτερο σενάριο, ωστόσο αυτό δεν είναι εμφανές μέσω του MAE, το οποίο οδηγεί σε στρεβλή ερμηνεία των δύο περιπτώσεων. Αντιθέτως, το μετρητικό NMAE αποδίδει με ακρίβεια την αποτελεσματικότητα των μοντέλων κάθε σεναρίου, καθώς αν και η πρόβλεψη του δεύτερου σεναρίου είναι σε απόλυτο αριθμό χειρότερη, ποιοτικά είναι ακριβέστερη. Για αυτούς τους λόγους, από το σύνολο των υπολογιζόμενων μετρητικών σφάλματος που παρουσιάζονται στο παρόν κεφάλαιο, ως μέτρο σύγκρισης των εξεταζόμενων μοντέλων πρόβλεψης λαμβάνεται το NMAE, όπου θεωρείται ακριβέστερο εκείνο το μοντέλο που εμφανίζει μικρότερη τιμή του συγκεκριμένου σφάλματος. Ωστόσο, για λόγους πληρότητας της ανάλυσης των παραγόμενων αποτελεσμάτων, για τα διακριτά μοντέλα έχουν υπολογιστεί και παρουσιάζονται, πέραν του NMAE, τα MAE και RMSE.

6.2 ΑΠΟΤΕΛΕΣΜΑΤΑ ΑΡΧΙΚΩΝ ΜΟΝΤΕΛΩΝ, ΥΒΡΙΔΙΚΟΥ ΚΑΙ ΒΕΛΤΙΩΜΕΝΟΥ ΥΒΡΙΔΙΚΟΥ

Προκειμένου να αξιολογηθεί πλήρως το βελτιωμένο υβριδικό μοντέλο της παρούσας εργασίας, προηγείται η δημιουργία τριών διαφορετικών μοντέλων, αρχιτεκτονικά απλούστερων από το υβριδικό. Όλα τα μοντέλα αξιολογήθηκαν με το ίδιο σύνολο ιστορικών δεδομένων του Φ/Β σταθμού στη Ροδόπη (εγκατεστημένης ισχύος 500 kW) και με το ίδιο ζητούμενο, την πρόβλεψη της Φ/Β παραγωγής σε χρονικό ορίζοντα μίας ώρας. Τα ακόλουθα μοντέλα τροφοδοτήθηκαν με μεταβλητές εισόδου την ιστορική χρονοσειρά παραγωγής, τη θερμοκρασία περιβάλλοντος, τη θερμοκρασία συλλέκτη και τη μέση προσπίπτουσα ηλιακή ακτινοβολία. Μοναδική διαφοροποίηση παρατηρείται στο βελτιωμένο υβριδικό μοντέλο της παρούσας διπλωματικής εργασίας, το οποίο λαμβάνει στην είσοδό του, πέραν των ανωτέρω, και την αριθμητική αναπαράσταση της ώρας, όπως αυτή αναλύθηκε στην Ενότητα 5.4. Τα μοντέλα, τα αποτελέσματα των οποίων παρουσιάζονται στον Πίνακα 6.1, είναι τα ακόλουθα:

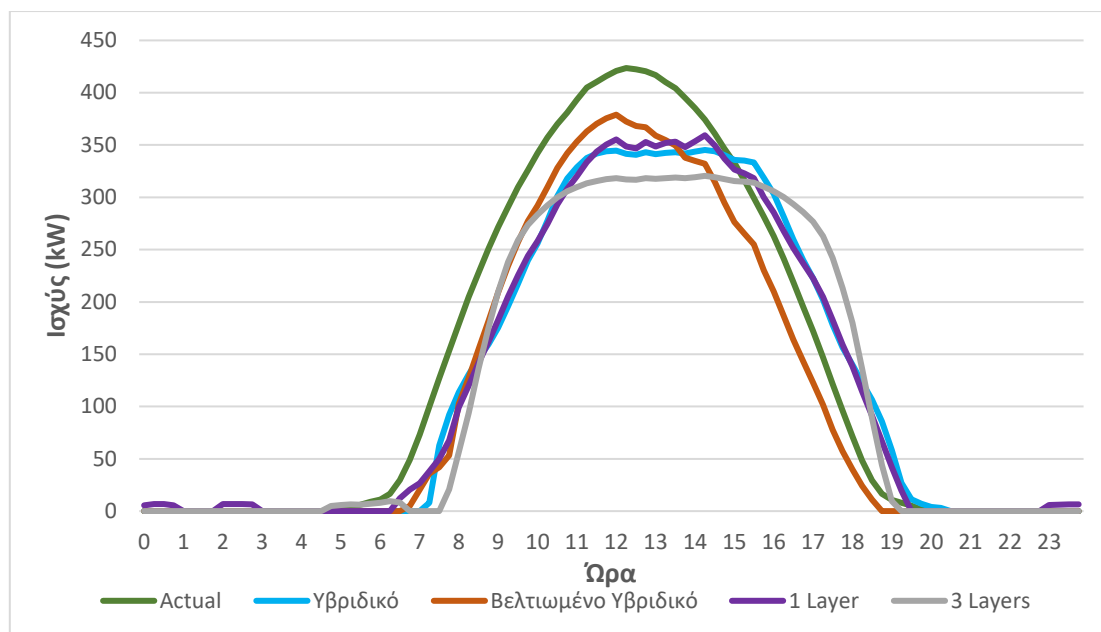
- Μοντέλο επιμονής (persistence): Η μέθοδος persistence είναι η απλούστερη διαδικασία πρόβλεψης, καθώς θεωρεί πως η προβλεπόμενη τιμή θα ισούται με την τελευταία πραγματική παρατήρηση [93]. Στη συγκεκριμένη περίπτωση, η μέθοδος persistence χρησιμοποιείται ως μοντέλο αναφοράς, και το υπολογιζόμενο σφάλμα της ως η χειρότερη επίδοση την οποία πρέπει να υπερκεράσουν όλα τα υπόλοιπα μοντέλα. Η εν λόγω μεθοδολογία πρόβλεψης θεωρεί πως δεν θα μεταβληθούν οι μετεωρολογικές συνθήκες μεταξύ της χρονικής στιγμής t και της χρονικής στιγμής $t + 1$, επομένως η πρόβλεψη Φ/Β παραγωγής θεωρείται πάντα ίση με την μετρούμενη Φ/Β παραγωγή της τρέχουσας χρονικής στιγμής.
- 1 Layer LSTM: Αφορά την απλούστερη δομή ενός δικτύου LSTM με μόνο ένα κρυφό στρώμα, χωρίς άλλες τεχνικές επεξεργασίας δεδομένων. Το χρησιμοποιούμενο LSTM αποτελείται από τέσσερις κόμβους εισόδου, έναν για κάθε μεταβλητή εισόδου, και έναν κόμβο εξόδου. Ο αριθμός των νευρώνων του μοναδικού κρυφού στρώματος αποτελεί παράμετρο προς βελτιστοποίηση. Η βελτιστοποίηση επιτελέστηκε με την μέθοδο trial and error.
- 3 Layers LSTM: Πρόκειται για ένα μοντέλο με πανομοιότυπη δομή με τα τέσσερα επιμέρους δίκτυα του υβριδικού μοντέλου, χωρίς τις υπόλοιπες μεθόδους επεξεργασίας του υβριδικού μοντέλου (αποσύνθεση, γραμμικός συνδυασμός). Διαθέτει τρία κρυφά στρώματα, τέσσερις κόμβους εισόδου και έναν κόμβο εξόδου. Όπως και στην περίπτωση του 1 Layer LSTM, ακολουθείται η διαδικασία βελτιστοποίησης των εμπλεκόμενων υπερ-παραμέτρων με την μέθοδο trial and error.
- Υβριδικό μοντέλο: Αφορά το υβριδικό μοντέλο του Κεφαλαίου 5, με τέσσερις μεταβλητές εισόδου, χωρίς την αριθμητική αναπαράσταση της ώρας της Ενότητας 5.4.
- Βελτιωμένο υβριδικό μοντέλο: Αποτελεί τροποποίηση του υβριδικού μοντέλου του Κεφαλαίου 5, το οποίο τροφοδοτείται με πέντε μεταβλητές εισόδου, αξιοποιώντας και την αριθμητική αναπαράσταση της ώρας.

Πίνακας 6.1 : Απόδοση αρχικών μοντέλων, υβριδικού και βελτιωμένου υβριδικού

| Μοντέλο | RMSE (kW) | MAE (kW) | NMAE | Βελτίωση NMAE |
|-----------------------------|--------------|--------------|--------------|---------------|
| Persistence | 54,82 | 30,67 | 6,13% | - |
| 1 Layer LSTM | 50,47 | 28,90 | 5,78% | 5,71% |
| 3 Layers LSTM | 50,79 | 28,77 | 5,75% | 6,20% |
| Υβριδικό μοντέλο | 51,19 | 28,32 | 5,66% | 7,67% |
| Βελτιωμένο υβριδικό μοντέλο | 42,97 | 21,51 | 4,30% | 29,85% |

Όπως φαίνεται στον Πίνακα 6.1, παρόλο που το μοντέλο persistence αναμενόμενα παρουσιάζει τη μικρότερη ακρίβεια πρόβλεψης μεταξύ των εξεταζόμενων μοντέλων, δεν είναι αξιοσημείωτα αναποτελεσματικό. Το γεγονός αυτό οφείλεται στη φύση του παρόντος προβλήματος και κυρίως στον βραχυπρόθεσμο χαρακτήρα των παραγόμενων προβλέψεων. Στην μέθοδο persistence η πρόβλεψη της Φ/Β παραγωγής την επόμενη ώρα ισούται με την πραγματική παραγωγή την τρέχουσα ώρα. Επειδή μεσολαβεί μικρό χρονικό διάστημα μεταξύ παρατήρησης και πρόβλεψης, η παραγωγή εντός μίας ώρας συνήθως δεν εμφανίζει σημαντική διαφοροποίηση και για αυτόν τον λόγο το NMAE ισούται μόλις με 6,13%. Εκτός αυτού, από τη φύση της η Φ/Β παραγωγή δεν φέρει έντονη μεταβλητότητα από ώρα σε ώρα σε μία μέρα με ηλιοφάνεια, εξαιτίας της γνωστής περιοδικότητάς της κατά τη διάρκεια της ημέρας. Η παραγωγή ενός Φ/Β σταθμού αυξάνεται σταδιακά όσο αυξάνεται η προσπίπτουσα ηλιακή ακτινοβολία οδεύοντας προς τις μεσημβρινές ώρες, ενώ στη συνέχεια μειώνεται τις απογευματινές ώρες. Η συγκεκριμένη διαδικασία δεν περιέχει βίαιες αυξομειώσεις, η προσπίπτουσα ηλιακή ακτινοβολία – η κυριότερη μετεωρολογική μεταβλητή που καθορίζει την παραγωγή ενός Φ/Β σταθμού – μεταβάλλεται επίσης με σταθερό ρυθμό. Ωστόσο, το μοντέλο persistence δεν είναι εφικτό να προβλέψει δυναμικά μετεωρολογικά φαινόμενα, όπως ραγδαίες αλλαγές της ηλιοφάνειας λόγω ύπαρξης τοπικών νεφώσεων, επομένως δεν συνίσταται για προβλήματα με αυξημένες απαιτήσεις ακρίβειας.

Από τον Πίνακα 6.1, είναι εμφανές πως το βελτιωμένο υβριδικό μοντέλο το οποίο κατασκευάστηκε στην παρούσα διπλωματική εργασία αποδίδει σημαντικά καλύτερα σε όρους NMAE (4,30%) τόσο από το υβριδικό μοντέλο των Li, Zhou, Lu και Yang [1] (5,66%), όσο και από τα απλούστερα μοντέλα persistence, 1 layer LSTM και 3 layers LSTM. Η τεχνική της αριθμητικής αναπαράστασης της ώρας βελτιώνει εντυπωσιακά την απόδοση του υβριδικού μοντέλου (βελτίωση NMAE 29,85% σε σχέση με το persistence), καθώς το διευκολύνει να αντιληφθεί την ημερήσια περιοδικότητα της Φ/Β παραγωγής. Επίσης, με αυτόν τον τρόπο έχει τη δυνατότητα να συσχετίσει ευκολότερα την αύξηση και την μείωση της παραγωγής με τις ώρες ανατολής και δύσης του ηλίου, αντίστοιχα. Όσο προφανές και να είναι πως η Φ/Β παραγωγή ξεκινάει τις πρωινές ώρες και σταματάει τις βραδινές, αυτό δεν είναι εκ των προτέρων γνωστό σε κανένα μοντέλο ML αν δεν έχει ποσοτικοποιηθεί. Επιπλέον, ένα ακόμη απαιτητικό ζήτημα για τα μοντέλα Φ/Β πρόβλεψης αφορά τις ώρες μέγιστης παραγωγής, δηλαδή κατά πόσο οξεία ή αμβλεία θα είναι η «καμπάνα» της παραγωγής. Η αριθμητική αναπαράσταση της ώρας διευκολύνει σημαντικά το υβριδικό μοντέλο να αντιληφθεί τα συγκεκριμένα ποιοτικά χαρακτηριστικά της Φ/Β παραγωγής, ειδικά σε περιπτώσεις όπως της παρούσας διπλωματικής εργασίας, όπου δεν υπάρχουν μετεωρολογικές προβλέψεις της επόμενης ώρας. Η αριθμητική αναπαράσταση αποτρέπει ενδεχόμενη αύξηση της πολυπλοκότητας των δικτύων LSTM, καθώς η αξιοποίηση της ανθρώπινης γνώσης καθιστά μη αναγκαία την προσθήκη περισσότερων κρυφών στρωμάτων.



Σχήμα 6.1 : Καμπύλες πραγματικής παραγωγής και πρόβλεψης για όλα τα μοντέλα την πρώτη ημέρα παραγωγής προβλέψεων

Στο Σχήμα 6.1 απεικονίζονται οι καμπύλες πρόβλεψης για όλα τα μοντέλα του Πίνακα 6.1, καθώς και η πραγματική παραγωγή (actual) ενδεικτικά για την πρώτη διαθέσιμη ημέρα των παραγόμενων αποτελεσμάτων (03/07/2022). Γίνεται αντιληπτό πως το βελτιωμένο υβριδικό μοντέλο προσεγγίζει την πραγματική παραγωγή ακριβέστερα από όλα τα υπόλοιπα μοντέλα κατά τη διάρκεια της ημέρας. Προφανώς το Σχήμα 6.1 είναι ενδεικτικό, καθώς περιγράφει μόλις μία μεμονωμένη ημέρα και ασφαλέστερα συμπεράσματα μπορούν να εξαχθούν μέσω των σφαλμάτων του Πίνακα 6.1, τα οποία υπολογίζονται λαμβάνοντας υπόψη το σύνολο του συνόλου αξιολόγησης. Ωστόσο, γίνεται εμφανές πως η αριθμητική αναπαράσταση της ώρας βοηθά το βελτιωμένο υβριδικό μοντέλο να προσεγγίσει καλύτερα τόσο τη χρονική στιγμή έναρξης της ημερήσιας παραγωγής, όσο κυρίως τη χρονική στιγμή τερματισμού της. Επιπλέον, η σημαντικά μεγαλύτερη ακρίβεια του μοντέλου της παρούσας εργασίας έγκειται στο γεγονός πως προσεγγίζει καλύτερα την πραγματική παραγωγή κατά τη διάρκεια μεγιστοποίησης της ημερήσιας παραγωγής. Η συγκεκριμένη συμπεριφορά είναι καθοριστικής σημασίας για τα υπολογιζόμενα σφάλματα όλων των μοντέλων του Πίνακα 6.1, καθώς όταν η πρόβλεψη αφορά ώρες υψηλής παραγωγής, αυξάνονται αντίστοιχα τα μετρητικά σφάλματος απόλυτης ακρίβειας.

6.3 ΑΠΟΤΕΛΕΣΜΑΤΑ ΕΠΟΧΙΚΗΣ ΑΝΑΛΥΣΗΣ


Η εποχική ανάλυση της Ενότητας 6.3 και η μετεωρολογική ανάλυση της Ενότητας 6.4 έχουν διεξαχθεί για το βελτιωμένο υβριδικό μοντέλο της παρούσας διπλωματικής εργασίας, το οποίο εμφανίζει την καλύτερη απόδοση μεταξύ όλων των υπολοίπων μοντέλων του Πίνακα 6.1. Εφεξής, το βελτιωμένο υβριδικό μοντέλο το οποίο περιλαμβάνει αποσύνθεση της ιστορικής χρονοσειράς ισχύος μέσω της μεθόδου WPD, τέσσερα επιμέρους LSTM δίκτυα, μέθοδο γραμμικού συνδυασμού και αξιοποιεί την αριθμητική αναπαράσταση της ώρας ως επιπλέον πέμπτη μεταβλητή εισόδου θα αναφέρεται με τον όρο υβριδικό μοντέλο.

Πίνακας 6.2 : Εποχική απόδοση υβριδικού μοντέλου

| Εποχή | RMSE (kW) | MAE (kW) | NMAE |
|-----------|--------------|--------------|--------------|
| Καλοκαίρι | 39,55 | 21,88 | 4,38% |
| Φθινόπωρο | 42,11 | 20,22 | 4,04% |
| Χειμώνας | 51,12 | 24,59 | 4,92% |

Στον Πίνακα 6.2 παρουσιάζεται η εποχική απόδοση του υβριδικού μοντέλου, η οποία αποτυπώνεται με τα μετρητικά σφάλματος RMSE, MAE, και NMAE. Όπως αναφέρεται και στο Κεφάλαιο 5, το υβριδικό μοντέλο της παρούσας εργασίας χρησιμοποιεί το 50% του συνόλου δεδομένων για την εκπαίδευση και το υπόλοιπο 50% για την αξιολόγησή του. Για αυτόν τον λόγο, παραγόμενες προβλέψεις υπάρχουν για τους μήνες Ιούλιο – Δεκέμβριο. Επομένως, στον Πίνακα 6.2 ως καλοκαίρι ορίζονται οι μήνες Ιούλιος, Αύγουστος, ως φθινόπωρο οι μήνες Σεπτέμβριος, Οκτώβριος, Νοέμβριος και ως χειμώνας ο μήνας Δεκέμβριος. Σε μία συγκριτική ανάγνωση των Πινάκων 6.1 και 6.2, εξάγεται το συμπέρασμα πως, σε όρους NMAE, το υβριδικό μοντέλο αποδίδει ελάχιστα χειρότερα το καλοκαίρι, αρκετά καλύτερα το φθινόπωρο και εμφανώς χειρότερα τον χειμώνα, σε σχέση με τον ετήσιο μέσο όρο του (4,30%). Το γεγονός αυτό οφείλεται στην ύπαρξη περισσότερων δυναμικών και απρόβλεπτων φαινομένων τους χειμερινούς μήνες, συγκριτικά με τους καλοκαιρινούς και τους φθινοπωρινούς μήνες. Όταν οι μετεωρολογικές συνθήκες μεταβάλλονται απρόσμενα, είναι δύσκολο για το μοντέλο να προβλέψει την αντίστοιχη αυξομείωση της παραγωγής και είναι πιθανό να χρειάζεται κάποια ώρα για να αντιληφθεί αυτή τη μεταβολή.

Εκτός των άλλων, βασική παράμετρο αποτελεί ο τρόπος υπολογισμού κάθε μετρητικού σφάλματος και το πως αυτό αντανακλά στα χαρακτηριστικά του προβλήματος πρόβλεψης Φ/Β παραγωγής. Στα εποχικά αποτελέσματα του Πίνακα 6.2 φαίνεται πως το υβριδικό μοντέλο έχει μικρότερο RMSE το καλοκαίρι και μεγαλύτερο το φθινόπωρο, αλλά μεγαλύτερο MAE το καλοκαίρι και μικρότερο το φθινόπωρο. Το φαινόμενο αυτό υποδηλώνει πως το μοντέλο αποτυπώνει επιτυχώς τα μέγιστα επίπεδα παραγωγής το καλοκαίρι, ενώ οι προβλέψεις του έχουν μικρές διακυμάνσεις άρα και μικρά τετραγωνικά σφάλματα. Αντίθετα, το βελτιωμένο MAE το φθινόπωρο δείχνει πως αν και οι μέσες προβλέψεις του μοντέλου μπορεί να απέχουν ελαφρώς περισσότερο από τις πραγματικές τιμές σε σύγκριση με το καλοκαίρι, η μεταβλητότητα των σφαλμάτων (τόσο των θετικών όσο και των αρνητικών) είναι μικρότερη. Γενικά, το MAE είναι μία γραμμική επίδοση σφάλματος, όπου όλες οι διαφορές των δειγμάτων σταθμίζονται ισοβαρώς, ενώ το RMSE είναι μία τετραγωνική επίδοση, η οποία μετρά το μέσο μέγεθος του σφάλματος. Η συγκεκριμένη διαφορά είναι πιθανό να οφείλεται στις ανόμοιες μετεωρολογικές συνθήκες μεταξύ καλοκαιριού και φθινοπώρου, όπως η διάρκεια της ημέρας, η γωνία πρόσπτωσης της ηλιακής ακτινοβολίας, και η θερμοκρασία. Στην παρούσα διπλωματική εργασία, ως μέτρο σύγκρισης θεωρείται το σφάλμα NMAE, καθώς λαμβάνει υπόψη την εγκατεστημένη ισχύ του Φ/Β σταθμού και το γεγονός πως είναι δυσκολότερη η ακριβής πρόβλεψη παραγωγής για σταθμούς μεγάλης ισχύος. Τους φθινοπωρινούς μήνες το υβριδικό μοντέλο παρουσιάζει τη βέλτιστη απόδοσή του, με το χαμηλότερο NMAE σε σχέση με όλες τις εποχές του εξεταζόμενου έτους. Οι εύκρατες συνθήκες ακόμη και το φθινόπωρο σε χώρες όπως η Ελλάδα, ευνοούν τη σταθερή Φ/Β παραγωγή, εξαιτίας της απουσίας έντονων απρόβλεπτων βροχοπτώσεων και νεφώσεων. Επίσης, το γεγονός πως λόγω εποχής η παραγωγή είναι μικρότερη συγκριτικά με το καλοκαίρι μειώνει το σχετικό υπολογιζόμενο NMAE, σε αντίθεση με άλλα μετρητικά όπως το MAPE, το οποίο θα ήταν πιθανώς αυξημένο.




Σχήμα 6.2 : Καμπύλες πραγματικής παραγωγής και πρόβλεψης υβριδικού μοντέλου για την ημέρα μέγιστης μέσης παραγωγής του καλοκαιριού

Αναμφίβολα, τα ημερήσια διαγράμματα μέσω των οποίων συγκρίνεται η πραγματική και η προβλεπόμενη καμπύλη παραγωγής του Φ/Β σταθμού είναι ενδεικτικά, καθώς είναι ανέφικτο η μία επιλεγμένη ημέρα να αντιπροσωπεύει απόλυτα την καθολική συμπεριφορά του υβριδικού μοντέλου. Συνεπώς, προκειμένου η εποχική ανάλυση της παρούσας εργασίας να είναι όσο το δυνατόν πιο αξιόπιστη, στα εμφανιζόμενα διαγράμματα επιλέχθηκε να απεικονίζονται οι ημέρες κάθε εποχής με τη μέγιστη και την ελάχιστη μέση παραγωγή. Στο Σχήμα 6.2 παρουσιάζεται η ημέρα του καλοκαιριού (19/07/2022), η οποία κατέγραψε τη μέγιστη μέση πραγματική ημερήσια παραγωγή (132,55 kW/15 λεπτά). Είναι ευδιάκριτο πως το υβριδικό μοντέλο εντοπίζει επαρκώς τις ώρες έναρξης και διακοπής της παραγωγής, χωρίς να παρουσιάζει κάποια μεγάλη χρονική καθυστέρηση ή προπόρευση (NMAE = 3,72%). Επιπλέον, ακολουθεί ικανοποιητικά την καμπύλη της πραγματικής παραγωγής σε όλη τη διάρκεια της ημέρας, παρουσιάζοντας ωστόσο μία σταθερή απαισιόδοξη συμπεριφορά σε όλες τις χρονικές στιγμές. Το μοναδικό ίσως αρνητικό χαρακτηριστικό της συγκεκριμένης ημέρας, αποτελεί η αδυναμία του μοντέλου να προσεγγίσει απόλυτα την παραγωγή τις ώρες που αυτή λαμβάνει τις μέγιστες τιμές της. Όπως φαίνεται και στον Πίνακα 6.3, τις μεσημβρινές ώρες όπου η παραγωγή μεγιστοποιείται, η ακρίβεια πρόβλεψης μειώνεται, σε σύγκριση με τις υπόλοιπες ώρες της ημέρας στις οποίες υπάρχει παραγωγή ενεργού ισχύος. Προφανώς, όταν η απόκλιση αφορά ώρες υψηλής παραγωγής, τα απόλυτα μεγέθη άρα και τα υπολογιζόμενα μετρητικά σφάλματος αυξάνονται.


Πίνακας 6.3 : Αναλογική απόδοση υβριδικού μοντέλου βάσει παραγωγής την ημέρα μέγιστης μέσης παραγωγής του καλοκαιριού

| Παραγωγή (Actual) | Ώρες | NMAE |
|---------------------|------------------------------|--------------|
| Actual > 350 kW | 10:30 – 14:30 | 6,38% |
| 0 < Actual < 350 kW | 05:15 – 10:15, 14:45 – 19:45 | 5,92% |



Σχήμα 6.3 : Καμπύλες πραγματικής παραγωγής και πρόβλεψης υβριδικού μοντέλου για την ημέρα ελάχιστης μέσης παραγωγής του καλοκαιριού

Στο Σχήμα 6.3 απεικονίζεται η ημέρα του καλοκαιριού (25/07/2022) με τη μικρότερη μέση παραγωγή ενεργού ισχύος (76,57 kW/15 λεπτά). Τη συγκεκριμένη ημέρα ήταν εμφανώς έντονη η παρουσία δυναμικών φαινομένων, καθώς το διάγραμμα της παραγωγής δεν είναι περιοδικό και ομοιόμορφο. Το υβριδικό μοντέλο αντιλαμβάνεται την πιθανή ύπαρξη τοπικών νεφώσεων και προσπαθεί να προβλέψει τη μελλοντική τάση της παραγωγής, αλλά εμφανίζει κάποια δυσκολία στο να αποτυπώσει τις αυξομειώσεις αυτής. Όπως φαίνεται από το Σχήμα 6.3, δεν πρόκειται για μία ημέρα με έντονες συνεχείς νεφώσεις, αλλά με παροδικές μετεωρολογικές μεταβολές, οι οποίες δυσχεραίνουν τη Φ/Β πρόβλεψη. Διευκρινιστικά, η παραγωγή διαφοροποιείται ραγδαία σε πολύ μικρό χρονικό διάστημα, καθώς από 152,04 kW στις 13:00 αυξάνεται στα 410,27 kW στις 13:45. Συνολικά, το υβριδικό μοντέλο συσχετίζει με επάρκεια τις εμφανιζόμενες νεφώσεις με τη μείωση της παραγωγής, ακόμη και αν αυτό συμβαίνει με μία μικρή χρονική καθυστέρηση. Σε κάθε περίπτωση, το μοντέλο αντιλαμβάνεται επιτυχώς τόσο τα χρονικά διαστήματα με αυξητική τάση της παραγωγής (10:45 – 11:45) όσο και αυτά με τάση μείωσής της (15:00 – 19:00). Ωστόσο, ο συνδυασμός δυναμικών φαινομένων με παροδικά ηλιόλουστη ημέρα, αποτελεί τη χειρότερη δυνατή συνθήκη για το υβριδικό μοντέλο και σε αυτό οφείλεται το αυξημένο NMAE, το οποίο για την εν λόγω ημέρα ισούται με 5,25%. Στην ημέρα ελάχιστης μέσης παραγωγής καλοκαιριού (Σχήμα 6.3) το σφάλμα NMAE υπολογίζεται για όλη τη διάρκεια της ημέρας, σε αντίθεση με την ημέρα μέγιστης μέσης παραγωγής καλοκαιριού (Σχήμα 6.2 και Πίνακας 6.3) όπου υπολογίζεται μόνο για τις ώρες παραγωγής. Αδιαμφισβήτητα, στη δεύτερη περίπτωση η απόκλιση της πρόβλεψης «τιμωρείται» αυστηρότερα, διότι στην πρώτη περίπτωση τα σφάλματα εξομαλύνονται τις βραδινές ώρες όπου πραγματικές και προβλεπόμενες τιμές ταυτίζονται και ισούνται με μηδέν. Αυτός ο διαφορετικός τρόπος υπολογισμού επιλέγεται ώστε να γίνει καλύτερα αντιληπτή – μέσω του Πίνακα 6.3 – η διαφοροποιημένη απόδοση του υβριδικού μοντέλου σε ώρες μεγάλης και μικρής παραγωγής την καλοκαιρινή ημέρα με τη μέγιστη μέση παρατηρούμενη παραγωγή.



Σχήμα 6.4 : Καμπύλες πραγματικής παραγωγής και πρόβλεψης υβριδικού μοντέλου για την ημέρα μέγιστης μέσης παραγωγής του φθινοπώρου

Στο Σχήμα 6.4 παρουσιάζεται η ημέρα του φθινοπώρου (07/09/2022) με τη μεγαλύτερη μέση παραγωγή ενεργού ισχύος (128,09 kW/15 λεπτά). Όπως και στην περίπτωση μέγιστης καλοκαιρινής παραγωγής (Σχήμα 6.2), η καμπύλη πρόβλεψης ακολουθεί ικανοποιητικά την παραγωγή, τόσο στην μορφή όσο και στην περιοδικότητά της. Επιπλέον, όπως και στις υπόλοιπες περιπτώσεις, προσδιορίζει πολύ ικανοποιητικά την ανατολή και τη δύση του ηλίου, συσχετίζοντας την με την έναρξη και διακοπή της παραγωγής, αντίστοιχα. Τόσο στην ημέρα μέγιστης μέσης παραγωγής του καλοκαιριού όσο και του φθινοπώρου, παρατηρείται μία σταθερή υπό-πρόβλεψη σε όλη τη διάρκεια της ημέρας. Αυτό πιθανώς οφείλεται είτε στα χαρακτηριστικά του συγκεκριμένου προβλήματος πρόβλεψης, είτε στον συνδυασμό των υπερ-παραμέτρων του υβριδικού μοντέλου.

Αξίζει να σημειωθεί, πως αν και η ημέρα μέγιστης μέσης παραγωγής του καλοκαιριού έχει μεγαλύτερη μέση παραγωγή και μέση ηλιοφάνεια από αυτή του φθινοπώρου, η μέγιστη στιγμιαία παραγωγή παρατηρείται στη φθινοπωρινή ημέρα, όπως παρουσιάζεται και στον Πίνακα 6.4. Το γεγονός αυτό πιθανό να οφείλεται στη θερμοκρασία συλλέκτη πέραν των 25 °C για περισσότερες ώρες της ημέρας το καλοκαίρι έναντι του φθινοπώρου, παράγοντας ο οποίος – όπως αναπτύσσεται στην Ενότητα 2.4 – προκαλεί μείωση της Φ/Β παραγωγής. Η μεγαλύτερη μέση παραγωγή στις 19/07/2022 πιθανώς εξηγείται από τη μεγαλύτερη διάρκεια ηλιοφάνειας της συγκεκριμένης ημέρας σε σύγκριση με τις 07/09/2022 (14,5 ώρες παραγωγής την καλοκαιρινή ημέρα, 12,15 ώρες τη φθινοπωρινή). Στον Πίνακα 6.4 παρουσιάζεται το «παράδοξο» μεταξύ μέσης ηλιοφάνειας και μέγιστης στιγμιαίας παραγωγής για τις ημέρες μέγιστης μέσης παραγωγής καλοκαιριού και φθινοπώρου.

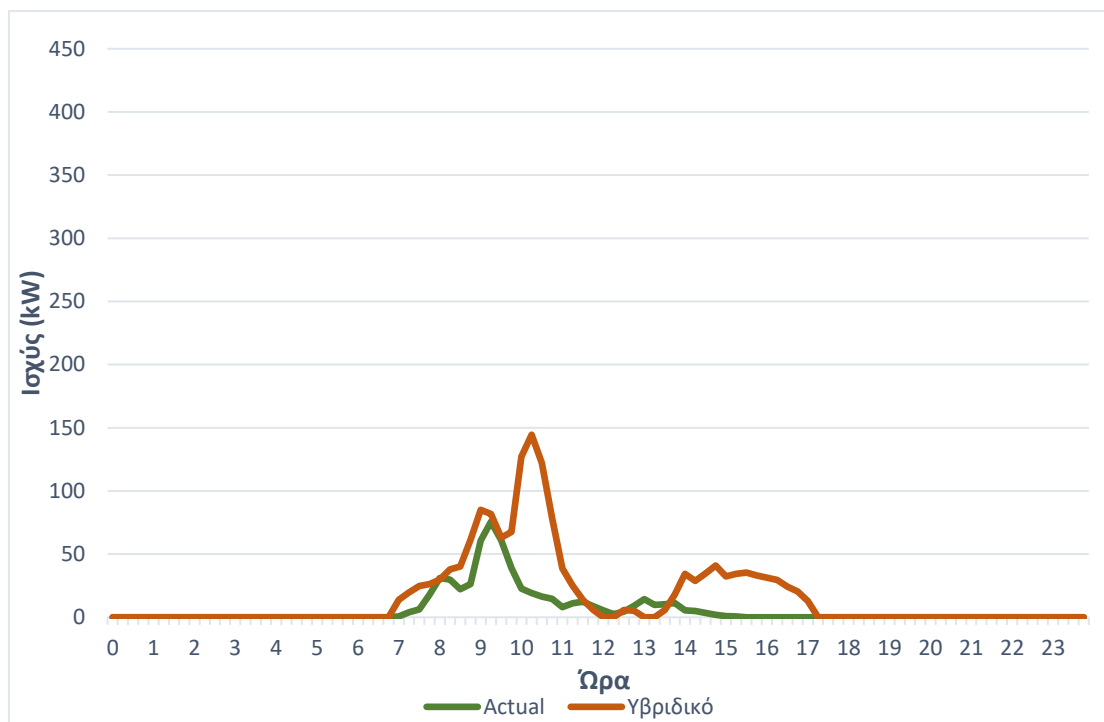
Πίνακας 6.4 : Παραγωγή και μετεωρολογικά δεδομένα για τις ημέρες μέγιστης μέσης παραγωγής του καλοκαιριού και του φθινοπώρου

| Ημερομηνία | Μέγιστη στιγμιαία παραγωγή (kW) | Μέση παραγωγή (kW/15 λεπτά) | Μέση ηλιακή ακτινοβολία (kW/m ² /15 λεπτά) | Μέση θερμοκρασία συλλέκτη (°C) | Θερμοκρασία συλλέκτη >25 °C |
|------------|---------------------------------|-----------------------------|---|--------------------------------|-----------------------------|
| 19/07/2022 | 405,88 | 132,55 | 332,34 | 24,77 | 13,5 ώρες |
| 07/09/2022 | 416,75 | 128,09 | 313,49 | 21,97 | 8,75 ώρες |

Στο Σχήμα 6.5 απεικονίζονται οι καμπύλες παραγωγής και πρόβλεψης για την ημέρα του φθινοπώρου (30/11/2022) με τη μικρότερη μέση παραγωγή (5,96 kW/15 λεπτά). Αν και η μέση παραγωγή είναι εξαιρετικά χαμηλή για ένα ΦΒ πάρκο εγκατεστημένης ισχύος 500 kW, δεν πρέπει να συγκρίεται η σταθερά χαμηλή προσπίπτουσα ακτινοβολία με την ύπαρξη δυναμικών απρόβλεπτων φαινομένων. Στο Σχήμα 6.3 παρουσιάζεται μία ημέρα πιθανότατα με τοπικές σποραδικές νεφώσεις, κατά την οποία η παραγωγή λαμβάνει μεγάλες τιμές (308,09 kW, 410,27 kW), αλλά πραγματοποιεί μεγάλα «βυθίσματα» (152,04 kW στις 13:00). Στον αντίποδα, το Σχήμα 6.5 πρόκειται πιθανότατα για μία ημέρα με ελάχιστη ηλιοφάνεια, στην οποία κυριάρχησαν για όλη τη διάρκειά της οι επίμονες νεφώσεις. Ενδεικτικά, στις 25/07/2022 καταγράφηκε μέση προσπίπτουσα ηλιακή ακτινοβολία στους συλλέκτες 191,05 kW/m²/15 λεπτά, ενώ στις 30/11/2022 ήταν ίση με μόλις 14,91 kW/m²/15 λεπτά. Τη φθινοπωρινή ημέρα με τη χαμηλότερη μέση παραγωγή το υβριδικό μοντέλο αντιλαμβάνεται τις νεφώσεις και οι προβλέψεις του κινούνται σε ένα ικανοποιητικό, σε γενικές γραμμές, επίπεδο. Ωστόσο, η προσωρινή αυξητική τάση της παραγωγής στο διάστημα 08:30 – 09:30 παραπλανά το μοντέλο να δώσει μία αρκετά εσφαλμένη πρόβλεψη στις 10:15 (144,49 kW). Εντούτοις, αν και εποπτικά από το Σχήμα 6.5 ήταν αναμενόμενη μία μεγάλη τιμή σφάλματος NMAE, αυτό ισούται ημερήσια με το αξιοπρόσεκτο 2,19%, ενώ στην αντίστοιχη ημέρα ελάχιστης μέσης παραγωγής του καλοκαιριού (Σχήμα 6.3), όπως αναφέρεται και προηγουμένως, ισούται με 5,25%. Το φαινόμενο αυτό οφείλεται στο ότι, τα σφάλματα της φθινοπωρινής ημέρας αφορούν πολύ μικρότερα επίπεδα παραγωγής, το οποίο ευνοεί τον τρόπο υπολογισμού του NMAE, καθώς όλα τα σφάλματα κανονικοποιούνται υπό την ίδια τιμή της εγκατεστημένης ισχύος. Με αυτόν τον τρόπο, έχει μεγαλύτερη σημασία η απόλυτη τιμή της απόκλισης και όχι η σχετική ακρίβεια της πρόβλεψης. Όπως φαίνεται και στον Πίνακα 6.5, η κατάλληλη επιλογή μετρητικού σφάλματος αξιολογεί διαφορετικά την πρόβλεψη, καθώς αν και η φθινοπωρινή πρόβλεψη έχει χειρότερη σχετική ακρίβεια, εμφανίζει χαμηλότερο NMAE λόγω των μικρότερων απόλυτων τιμών των μεγεθών.

Πίνακας 6.5 : Παραγωγή και μετεωρολογικά δεδομένα για τις ημέρες ελάχιστης μέσης παραγωγής καλοκαιριού και φθινοπώρου

| Ημερομηνία | Ωρα μέγιστης απόκλισης | Πραγματική παραγωγή (kW) | Προβλεπόμενη παραγωγή (kW) | MAE (kW) | NMAE | MAPE |
|------------|------------------------|--------------------------|----------------------------|----------|--------|---------|
| 25/07/2022 | 13:45 | 410,27 | 249,72 | 160,55 | 32,11% | 39,13% |
| 30/11/2022 | 10:15 | 19,09 | 144,49 | 125,40 | 25,08% | 656,89% |




Σχήμα 6.5 : Καμπύλες πραγματικής παραγωγής και πρόβλεψης υβριδικού μοντέλου για την ημέρα ελάχιστης μέσης παραγωγής του φθινοπώρου

Το Σχήμα 6.6 αναπαριστά τις καμπύλες πρόβλεψης και παραγωγής για την ημέρα του χειμώνα (21/12/2022) με τη μεγαλύτερη μέση παραγωγή ενεργού ισχύος (81,39 kW/15 λεπτά). Σε αντίθεση με τις αντίστοιχες ημέρες των υπόλοιπων εποχών (Σχήμα 6.2 και 6.4), η καμπύλη πρόβλεψης, αν και μέχρι τις 12:15 ακολουθεί με μεγάλη ακρίβεια την παραγωγή, τις υπόλοιπες ώρες τις ημέρας παρουσιάζει μία ορατή χρονική μετατόπιση περίπου δύο ωρών. Πιο αναλυτικά, το υβριδικό μοντέλο, από τις μεσημβρινές ώρες και μετά, παράγει υπέρ-αισιόδοξες προβλέψεις, ενώ η πραγματική καμπύλη μειώνεται αρκετά γρηγορότερα και μηδενίζεται πολύ νωρίτερα (15:45). Το φαινόμενο αυτό οφείλεται στην περιστροφή της γης γύρω από τον άξονά της υπό γωνία 23,4°, γεγονός το οποίο προκαλεί την διαφοροποιημένη διάρκεια ημέρας ανά εποχή. Όπως φαίνεται και στον Πίνακα 6.6, η διάρκεια της ημέρας μέγιστης μέσης παραγωγής κάθε εποχής ποικίλει σημαντικά, παράγοντας ο οποίος επηρεάζει καθοριστικά τη μέση παραγωγή, ακόμη και αν δεν υπάρχει μεγάλη μεταβολή της προσπίπτουσας ηλιακής ακτινοβολίας. Η μέση ηλιακή ακτινοβολία τις ώρες παραγωγής δεν διαφέρει δραματικά ανά εποχή σε μία ημέρα με ευνοϊκές μετεωρολογικές συνθήκες, γεγονός αντικρουόμενο με την αδιαμφισβήτητη εποχική διακύμανση της παραγωγής σε επίπεδο παραγόμενης ενέργειας.

Πίνακας 6.6 : Χαρακτηριστικά ηλιακής ακτινοβολίας τις ημέρες μέγιστης μέσης παραγωγής καλοκαιριού, φθινοπώρου και χειμώνα


| Ημερομηνία | Μέση ημερήσια ηλιακή ακτινοβολία (kW/m ² /15 λεπτά) | Μέση ηλιακή ακτινοβολία τις ώρες παραγωγής (kW/m ² /15 λεπτά) | Χρονικό διάστημα παραγωγής | Μέση ημερήσια παραγωγή (kW/15 λεπτά) |
|------------|--|--|----------------------------|--------------------------------------|
| 19/07/2022 | 332,34 | 540,76 | 06:15 – 20:45 | 132,55 |
| 07/09/2022 | 313,49 | 590,03 | 07:00 – 19:45 | 128,09 |
| 21/12/2022 | 195,75 | 507,86 | 08:00 – 17:00 | 81,39 |



Σχήμα 6.6 : Καμπύλες πραγματικής παραγωγής και πρόβλεψης υβριδικού μοντέλου για την ημέρα μέγιστης μέσης παραγωγής του χειμώνα

Χαρακτηριστικά, την ημέρα μέγιστης μέσης παραγωγής του φθινοπώρου παρατηρείται μεγαλύτερη μέση ακτινοβολία τις ώρες παραγωγής συγκριτικά με αυτή του καλοκαιριού. Ωστόσο, η καλοκαιρινή ημέρα διαθέτει περισσότερες ώρες παραγωγής, επομένως σε ημερήσιο επίπεδο παρατηρείται μεγαλύτερη μέση ηλιακή ακτινοβολία. Ομοίως, την ημέρα μέγιστης μέσης παραγωγής του χειμώνα, αν και καταγράφεται δεδομένη μείωση τόσο της μέσης παραγωγής όσο και της μέσης ημερήσιας ακτινοβολίας, μεμονωμένα τις ώρες παραγωγής η μέση ακτινοβολία δεν είναι εξαιρετικά μειωμένη. Συνεπώς, εξάγεται το συμπέρασμα πως η προσπίπτουσα ηλιακή ακτινοβολία στους ηλιακούς συλλέκτες δεν εμφανίζει κάποια αξιοσημείωτη εποχική αυξομείωση, ο παράγοντας, ωστόσο, ο οποίος διαδραματίζει καθοριστικό ρόλο για τη συνολική ημερήσια παραγωγή είναι η διάρκεια της ημέρας. Σε αυτό το σημείο, πρέπει να αναφερθεί πως το φαινόμενο της ραγδαίας μεταβολής της διάρκειας ημέρας ανά εποχή, δυσχεραίνει σημαντικά την πρόβλεψη μέσω του υβριδικού μοντέλου, καθώς πρέπει να συσχετίσει τις διαφορετικές παραγωγικές ώρες της ημέρας, την ηλιοφάνεια και την παραγωγή ενεργού ισχύος. Ενδεικτικά για τις τρεις προαναφερθείσες ημέρες καλοκαιριού, φθινοπώρου και χειμώνα καταγράφονται 14,5 ώρες, 12,75 και 9 ώρες παραγωγής, αντίστοιχα. Η εν λόγω παράμετρος αιτιολογεί μερικώς την αδυναμία του υβριδικού μοντέλου να ακολουθήσει την πραγματική καμπύλη στις ώρες έναρξης και διακοπής της παραγωγής, όπως γίνεται σαφές και στο Σχήμα 6.6.

Στο Σχήμα 6.7 παρουσιάζεται η ημέρα του χειμώνα (01/12/2022) με την μικρότερη μέση παραγωγή ενεργού ισχύος (2.32 kW/15 λεπτά). Είναι εμφανές τόσο από τη μορφή της γραφικής παράστασης όσο και από τις τιμές ισχύος στον κατακόρυφο άξονα, πως πρόκειται για μία ημέρα με έντονες νεφώσεις για όλη τη διάρκειά της και ελάχιστη ηλιοφάνεια. Στην πλειονότητά τους, ισχύουν τα ίδια συμπεράσματα με την ημέρα ελάχιστης μέσης παραγωγής του φθινοπώρου (Σχήμα 6.5), καθώς καταγράφεται, ομοίως, εξαιρετικά χαμηλή παραγωγή.



Σχήμα 6.7 : Καμπύλες πραγματικής παραγωγής και πρόβλεψης υβριδικού μοντέλου για την ημέρα ελάχιστης μέσης παραγωγής του χειμώνα

Στην ίδια κατεύθυνση, αν και δημιουργείται η εντύπωση πως υπάρχει μεγάλη απόκλιση μεταξύ παραγωγής και πρόβλεψης, στην πραγματικότητα αυτό οφείλεται, όπως αναφέρθηκε και προηγουμένως, σε εποπτικούς λόγους. Επιπλέον, η ακρίβεια της συνολικής ημερήσιας πρόβλεψης κρίνεται εξαιρετική με το μετρητικό σφάλματος NMAE να ανέρχεται σε 1,94%. Συνολικά, μέσω των Σχημάτων 6.5 και 6.7 καθίσταται σαφές το πως η τιμή της παραγωγής και της πρόβλεψης επηρεάζουν το NMAE, το οποίο είναι ένα κανονικοποιημένο σφάλμα αξιολόγησης της απόλυτης και όχι της σχετικής ακρίβειας. Στον Πίνακα 6.7 παρουσιάζεται η συγκεντρωτική απόδοση του υβριδικού μοντέλου για τις ημέρες μέγιστης και ελάχιστης μέσης παραγωγής ανά εποχή. Είναι προφανές πως το υβριδικό μοντέλο αποδίδει αποτελεσματικότερα τις ημέρες ελάχιστης παραγωγής, καθώς σε περίπτωση μικρής παραγωγής ενεργού ισχύος, τα υπολογιζόμενα σφάλματα είναι μικρότερα, ακόμη και αν οι προβλέψεις φέρουν μικρότερη σχετική ακρίβεια, όπως παρουσιάζεται και στον Πίνακα 6.5. Αντίθετα, εξαίρεση αποτελεί η ημέρα ελάχιστης παραγωγής του καλοκαιριού, στην οποία καταγράφονται δυναμικά μετεωρολογικά φαινόμενα και επομένως το μοντέλο δυσκολεύεται να προβλέψει τη μη αναμενόμενη μεταβολή της ηλιακής ακτινοβολίας (Σχήμα 6.3). Αναφορικά με τις ημέρες μέγιστης παραγωγής, αν και οι απόλυτες τιμές παραγωγής είναι μεγάλες, η σταθερότητα των καιρικών φαινομένων ευνοεί το υβριδικό μοντέλο να ακολουθεί την παραγωγή με μεγάλη ακρίβεια και συνέπεια. Για αυτόν τον λόγο, η απόδοση του μοντέλου στις συγκεκριμένες ημέρες είναι υψηλότερη από τον αντίστοιχο μέσο όρο της εποχής, καθώς σε κάθε εποχή συνδυάζονται ημέρες υψηλής, χαμηλής και μεταβλητής ηλιοφάνειας. «Μελανό» σημείο αποτελεί η ημέρα μέγιστης μέσης παραγωγής του χειμώνα, κατά την οποία όπως φαίνεται και από το Σχήμα 6.6 υπάρχει χρονική μετατόπιση των δύο παραστάσεων με υπέρ-αισιόδοξη πρόβλεψη από τις μεσημβρινές ώρες και μετά. Η συγκεκριμένη παράμετρος, σε συνάρτηση με τις υψηλές τιμές παραγωγής, προκαλεί το μεγαλύτερο NMAE συγκριτικά με όλες τις υπόλοιπες εξεταζόμενες ημέρες.

Πίνακας 6.7 : Συγκεντρωτική εποχική απόδοση υβριδικού μοντέλου για τις ημέρες μέγιστης και ελάχιστης μέσης παραγωγής

| Ημέρα | Μέση παραγωγή (kW/15 λεπτά) | RMSE (kW) | MAE (kW) | NMAE |
|----------------------|-----------------------------|--------------|-------------|--------------|
| Μέγιστη καλοκαιριού | 132,55 | 26,74 | 18,60 | 3,72% |
| Ελάχιστη καλοκαιριού | 76,57 | 52,00 | 26,27 | 5,25% |
| Μέγιστη φθινοπώρου | 128,09 | 28,53 | 17,93 | 3,59% |
| Ελάχιστη φθινοπώρου | 5,96 | 24,73 | 10,94 | 2,19% |
| Μέγιστη χειμώνα | 81,39 | 67,12 | 32,92 | 6,58% |
| Ελάχιστη χειμώνα | 2,32 | 18,01 | 9,72 | 1,94% |

Συνοψίζοντας, τα ημερήσια αποτελέσματα της παρούσας ενότητας είναι ενδεικτικά και αξιολογούνται ώστε να γίνει κατανοητή η συμπεριφορά του υβριδικού μοντέλου σε συγκεκριμένες ημέρες ενδιαφέροντος κάθε εποχής. Ως κριτήριο επιλέχθηκε η μέση παραγωγή, σε μία προσπάθεια να αξιολογηθούν οι προβλέψεις του προτεινόμενου μοντέλου σε ημέρες με όσο το δυνατόν διαφορετικά μετεωρολογικά χαρακτηριστικά. Το μετρητικό σφάλματος NMAE θεωρείται το πλέον ενδεδειγμένο για την παρούσα διπλωματική εργασία, διότι λαμβάνει υπόψη την εγκατεστημένη ισχύ του Φ/Β σταθμού και προσφέρει μία ευρύτερη ποσοτικοποίηση της ακρίβειας των προβλέψεων. Διαφορετικά μετρητικά σφάλματος, όπως το MAPE, χρησιμοποιούνται αποκλειστικά για μεμονωμένες χρονικές στιγμές, καθώς σε ένα πρόβλημα πρόβλεψης, όπως αυτό της Φ/Β παραγωγής, το οποίο περιέχει πολλές πραγματικές μηδενικές τιμές ή πολύ μικρές τιμές δεν διαθέτει μεγάλη αξία. Πιο ασφαλή συμπεράσματα για την εποχική απόδοση του υβριδικού μοντέλου παρουσιάζονται στον Πίνακα 6.2, τα μετρητικά σφάλματος του οποίου έχουν υπολογιστεί για όλες τις ημέρες κάθε εποχής, ανεξαρτήτου παραγωγής και μετεωρολογικών συνθηκών. Συνολικά, προκειμένου να επιτευχθεί η μέγιστη ακρίβεια πρόβλεψης μέσω του υβριδικού μοντέλου και να είναι σε θέση να αντιλαμβάνεται ικανοποιητικά τόσο την απόλυτη τιμή της ηλιακής ακτινοβολίας όσο και τη σημαντική εποχική μεταβολή των παραγωγικών ωρών κάθε ημέρας, κρίνεται ευνοϊκή η επιμέρους εκπαίδευση του μοντέλου ανά εποχή ή ακόμη και ανά μήνα. Με αυτόν τον τρόπο, θα μετριάζονταν οι επιπτώσεις της μεγάλης διακύμανσης της διάρκειας της ημέρας, καθώς με την τρέχουσα εκπαίδευση για ένα σύνολο έξι μηνών, δυσχεραίνεται το έργο του υβριδικού μοντέλου. Χαρακτηριστικά, την ημέρα μέγιστης μέσης παραγωγής του καλοκαιριού (Σχήμα 6.2) στις 16:00 υπάρχει παραγωγή 255,91 kW, ενώ την ίδια ώρα (16:00) της ημέρας μέγιστης μέσης παραγωγής του χειμώνα (Σχήμα 6.6) η παραγωγή έχει μηδενιστεί. Ωστόσο, η ξεχωριστή μηνιαία εκπαίδευση του μοντέλου απαιτεί πολυετή ιστορικά δεδομένα και δεν συμπεριλαμβάνεται στις επιδιώξεις της παρούσας διπλωματικής εργασίας.


6.4 ΑΠΟΤΕΛΕΣΜΑΤΑ ΜΕΤΕΩΡΟΛΟΓΙΚΗΣ ΑΝΑΛΥΣΗΣ

Η μετεωρολογική ανάλυση της παρούσας διπλωματικής εργασίας, υλοποιείται με σκοπό την αξιολόγηση του προτεινόμενου υβριδικού μοντέλου στις διαφορετικές μετεωρολογικές συνθήκες κατά τις οποίες καλείται να λειτουργήσει ένας Φ/Β σταθμός. Η παραγωγή ενός Φ/Β σταθμού εξαρτάται από ποικίλους παράγοντες, η μεταβολή των οποίων είναι πιθανό να προκαλέσει σημαντική αύξηση της διακύμανσης της παραγωγής κατά τη διάρκεια της ημέρας. Όπως είναι λογικό, η μεταβολή των μετεωρολογικών συνθηκών αποτελεί


κρίσιμη παράμετρο για την ακρίβεια της Φ/Β πρόβλεψης, καθώς όταν τα φαινόμενα είναι δυναμικά και μεταβάλλονται ραγδαία σε μικρό χρονικό διάστημα, δυσχεραίνεται το έργο του υβριδικού μοντέλου. Αδιαμφισβήτητα, η μεταβλητή η οποία επηρεάζει σε μεγαλύτερο βαθμό τη Φ/Β παραγωγή είναι η προσπίπτουσα ηλιακή ακτινοβολία, διότι οποιαδήποτε μεταβολή της έχει άμεσο αντίκτυπο στην παραγωγή ενεργού ισχύος. Για αυτόν τον λόγο, προκειμένου να ερευνηθεί η αποτελεσματικότητα του υβριδικού μοντέλου στις διαφορετικές μετεωρολογικές συνθήκες, έχει πραγματοποιηθεί διαχωρισμός των ημερών κάθε μήνα σε τρεις βασικές κατηγορίες: Ηλιόλουστη, συννεφιασμένη, και δυναμική ημέρα. Ως ηλιόλουστη θεωρείται μία ημέρα κατά την οποία η ηλιακή ακτινοβολία λαμβάνει μεγάλες, για την εποχή, τιμές και ακολουθεί την αναμενόμενη κατανομή με μορφή «καμπάνας», χωρίς αξιόλογες αποκλίσεις. Αντίθετα, ως συννεφιασμένη χαρακτηρίζεται μία ημέρα με πολύ μικρή μετρούμενη προσπίπτουσα ηλιακή ακτινοβολία, κατά την οποία δεν υπάρχουν καθόλου χρονικά διαστήματα ηλιοφάνειας. Τέλος, με τον όρο «δυναμική» περιγράφεται η ημέρα εκείνη, κατά την οποία η ηλιακή ακτινοβολία εμφανίζει έντονες αυξομειώσεις, συνοδευόμενες από εμφανείς κορυφές και «βυθίσεις». Είναι εξίσου πιθανό, μία ημέρα να θεωρηθεί δυναμική τόσο αν διαθέτει σποραδικές νεφώσεις ακόμη και για λίγες ώρες, όσο και αν παρατηρούνται επίμονες νεφώσεις, οι οποίες όμως παροδικά υποχωρούν.

Αναμφίβολα, η παραπάνω κατηγοριοποίηση περιλαμβάνει ποιοτικά κριτήρια, τα οποία είναι αδύνατο να ποσοτικοποιηθούν αποτελεσματικά. Για παράδειγμα, είναι πιθανό σε μία ημέρα να καταγράφεται υψηλός μέσος όρος ακτινοβολίας, αλλά σε κάποιες στιγμές αυτή να μειώνεται σημαντικά, όπως επίσης σε μία φαινομενικά συννεφιασμένη ημέρα η ακτινοβολία να εκτοξεύεται τις μεσημβρινές ώρες. Επομένως, γίνεται αντιληπτό πως η ταξινόμηση των ημερών με κριτήριο την μετρούμενη προσπίπτουσα ηλιακή ακτινοβολία αποτελεί μία επίπονη διαδικασία, για την οποία είναι δύσκολο να βρεθεί μία γρήγορη, συστηματική και ακριβής, ταυτόχρονα, μέθοδος. Για αυτόν τον λόγο, στην παρούσα διπλωματική εργασία επιλέχθηκε για λόγους πληρότητας και αξιοπιστίας ο διαχωρισμός στις τρεις προαναφερθείσες κατηγορίες να πραγματοποιηθεί εποπτικά, ξεχωριστά για κάθε ημέρα. Αρχικά, υπολογίστηκε τόσο ο ημερήσιος όσο και ο μηνιαίος μέσος όρος ηλιακής ακτινοβολίας, ώστε να είναι γνωστό σε τι επίπεδα κυμαίνεται η ακτινοβολία κάθε ημέρας. Στη συνέχεια, δημιουργήθηκαν οι γραφικές παραστάσεις της ηλιακής ακτινοβολίας για κάθε ημέρα, ώστε να είναι ευδιάκριτη η μεταβολή της και τα ποιοτικά χαρακτηριστικά της. Είναι προφανές, πως η ηλιακή ακτινοβολία που καταγράφεται από ένα μετρητικό όργανο υπό πραγματικές συνθήκες, είναι σπάνιο να ακολουθεί τέλεια την κατανομή «καμπάνας». Στο Σχήμα 6.8(α) παρουσιάζεται ενδεικτικά η ηλιακή ακτινοβολία μίας ημέρας η οποία θεωρείται στο πλαίσιο της παρούσας διπλωματικής εργασίας πως έχει την ιδανική καμπύλη και, προφανώς, αποτελεί ένα πρότυπο ηλιόλουστης ημέρας. Στον αντίποδα, στο Σχήμα 6.8(β) φαίνεται η καμπύλη της ηλιακής ακτινοβολίας μίας ημέρας, η οποία τις μεσημβρινές ώρες εμφανίζει κάποιες ανεπαίσθητες αυξομειώσεις. Ωστόσο, τόσο οι μεγάλες τιμές της ακτινοβολίας όσο και η μικρή χρονική διάρκεια των μεταπτώσεων οδηγούν στο να ταξινομηθεί και η συγκεκριμένη ημέρα ως ηλιόλουστη. Κατά τη διαδικασία του εποπτικού διαχωρισμού των ημερών, η μεγαλύτερη δυσκολία έγκειται στην κατηγοριοποίηση των δυναμικών ημερών. Γενικότερα, επειδή τα κριτήρια δεν είναι απόλυτα αντικειμενικά, πρέπει να λαμβάνονται υπόψη τόσο τα ποιοτικά χαρακτηριστικά της καμπύλης ακτινοβολίας, όσο και οι απόλυτες τιμές της. Στην παρούσα διπλωματική εργασία θεωρείται ως αξιοπρόσεκτη μία μεταβολή της τάξης του 30% για μία μέτρηση ή και μικρότερο ποσοστό για διαδοχικές χρονικές στιγμές. Στο Σχήμα 6.9(α) παρουσιάζεται μία ημέρα με μεγάλη ηλιακή ακτινοβολία τις περισσότερες ώρες, αλλά με σημαντική βύθιση για κάποιο διάστημα. Αν και

στην ημέρα του Σχήματος 6.9(α) η ηλιακή ακτινοβολία μειώνεται μόνο για μικρό χρονικό διάστημα, η συγκεκριμένη πτώση είναι αξιοσημείωτη, καθώς πρόκειται για μείωση της τάξης του 50%. Επομένως, εξάγεται το συμπέρασμα πως κατά τις εν λόγω ώρες παρουσιάστηκαν κάποιες παροδικές νεφώσεις, οι οποίες όμως υποχώρησαν γρήγορα.

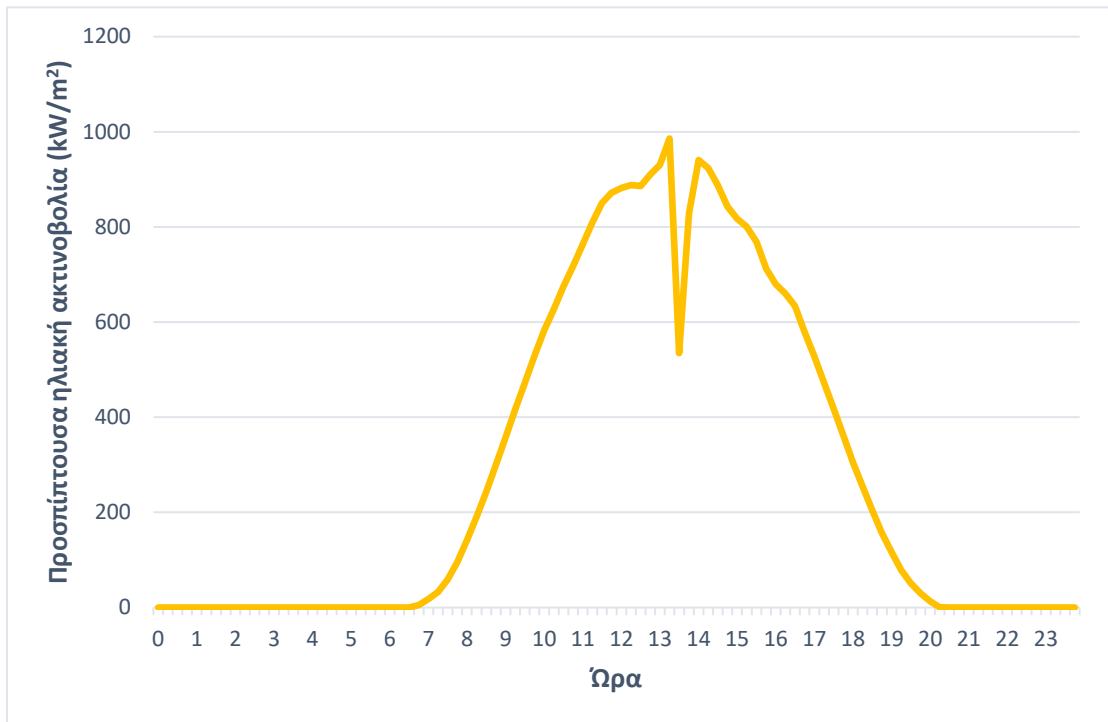


(α)

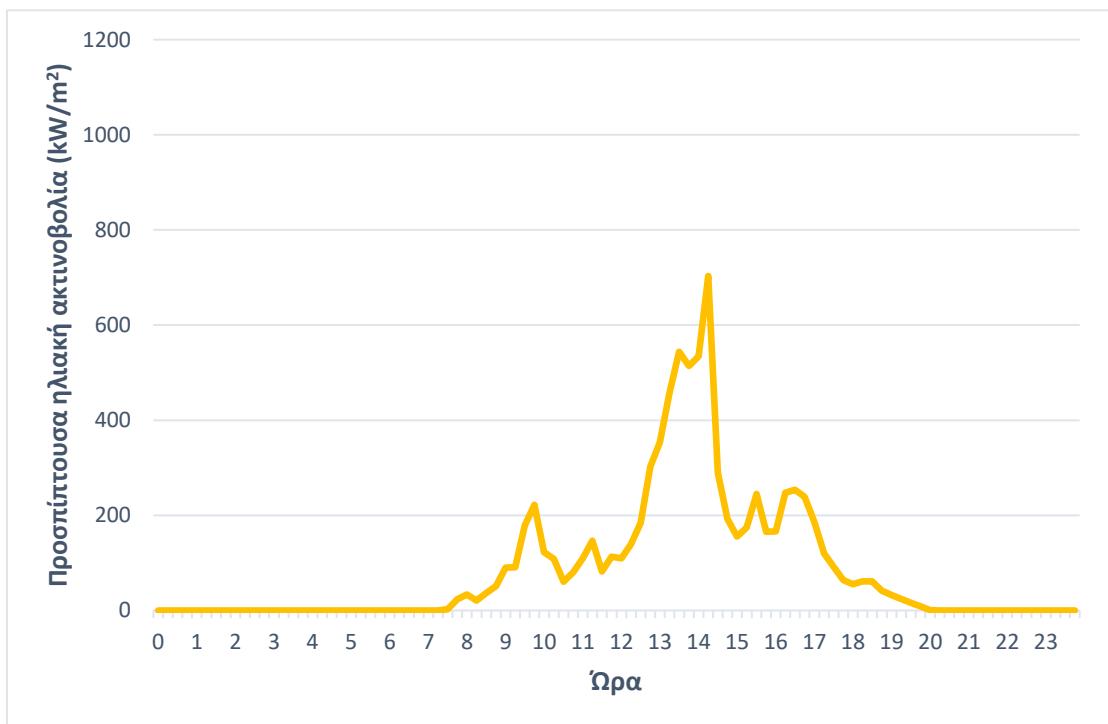


(β)

Σχήμα 6.8: Ενδεικτικές καμπύλες προσπίπτουσας ηλιακής ακτινοβολίας για μια ηλιόλουστη ημέρα.



(α)



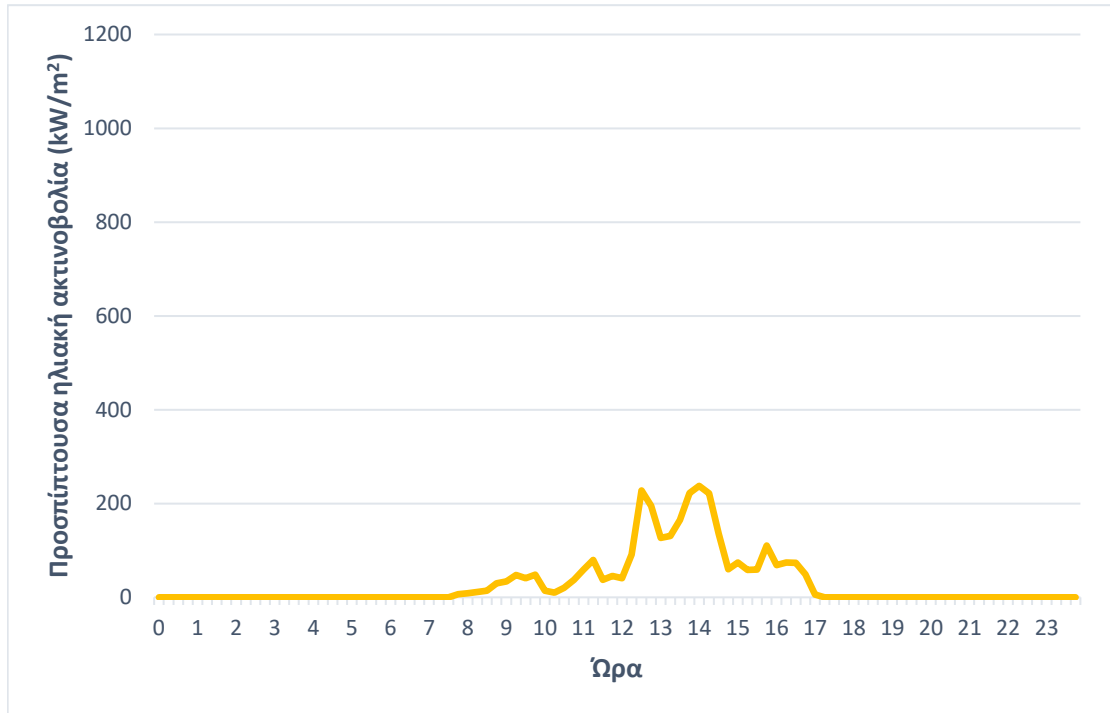
(β)

Σχήμα 6.9 : Ενδεικτικές καμπύλες προσπίπτουσας ηλιακής ακτινοβολίας για μία ημέρα με δυναμικά φαινόμενα.


Ωστόσο, ειδικά από τη στιγμή που η συγκεκριμένη έντονη μεταβολή αφορά χρονικές στιγμές μεγάλης παραγωγής, οδηγούν στην ταξινόμηση αυτής της ημέρας ως δυναμικής, εξαιτίας των παρατηρούμενων δυναμικών φαινομένων. Στην ίδια κατεύθυνση, στο Σχήμα 6.9(β) απεικονίζεται μία ημέρα η οποία, ομοίως, χαρακτηρίζεται δυναμική. Αν και στη συγκεκριμένη περίπτωση στη μεγαλύτερη διάρκεια της ημέρας κυριάρχησαν οι νεφώσεις, η αύξηση της

ηλιακής ακτινοβολίας για κάποιες ώρες σε μεγάλα επίπεδα δεν μπορούν να κατηγοριοποιήσουν την ημέρα ως συννεφιασμένη.

Αδιαμφισβήτητα, η ευκολότερη κατηγορία ταξινόμησης αφορά τις συννεφιασμένες ημέρες, καθώς η μετρούμενη ηλιακή ακτινοβολία είναι εξαιρετικά μικρότερη συγκριτικά με αυτή της ημέρας με δυναμικά φαινόμενα. Στο Σχήμα 6.10(α) παρουσιάζεται μία ημέρα με επίμονες νεφώσεις, κατά την οποία η ηλιακή ακτινοβολία αυξήθηκε περιορισμένα τις μεσημβρινές ώρες. Η μορφή της καμπύλης αλλά και οι μικρές απόλυτες τιμές της ακτινοβολίας χαρακτηρίζουν τη συγκεκριμένη ημέρα ως συννεφιασμένη.



(α)



(β)

Σχήμα 6.10 : Ενδεικτικές καμπύλες προσπίπτουσας ηλιακής ακτινοβολίας για μία συννεφιασμένη ημέρα.

Στο Σχήμα 6.10(β) απεικονίζεται επίσης μία ημέρα με έντονες σταθερές νεφώσεις και ελάχιστη ηλιοφάνεια. Για εποπτικούς λόγους και για την καλύτερη κατανόηση της κατηγοριοποίησης, η κλίμακα του κατακόρυφου άξονα των Σχημάτων 6.10(α) και 6.10(β) έχει διατηρηθεί η ίδια με αυτή των Σχημάτων 6.8 και 6.9. Επομένως, καθίσταται σαφές πως οι συννεφιασμένες ημέρες αποτελούν τη λιγότερο αμφισβητήσιμη κατηγορία, καθώς οι διαφορές τους στην ηλιακή ακτινοβολία είναι χαοτικές, συγκριτικά με τις υπόλοιπες. Συνολικά, όλες οι ημέρες για τις οποίες υπάρχουν παραγόμενες προβλέψεις (Ιούλιος – Δεκέμβριος) ταξινομήθηκαν στις τρεις κατηγορίες με βάση τα παρατηρούμενα μετεωρολογικά φαινόμενα. Εξαιτίας του γεγονότος πως τα δεδομένα της παρούσας διπλωματικής εργασίας δεν περιλαμβάνουν κάποια άλλη μετεωρολογική μεταβλητή ή κάποια διαφορετική μεθοδολογία αξιολόγησης των μετεωρολογικών φαινομένων (π.χ. φωτογραφίες του ουρανού), η ταξινόμηση πραγματοποιήθηκε με αποκλειστικό κριτήριο τη μετρούμενη ηλιακή ακτινοβολία στους ηλιακούς συλλέκτες του Φ/Β σταθμού. Η μετεωρολογική ανάλυση, τα αποτελέσματα της οποίας παρουσιάζονται ανά μήνα στον Πίνακα 6.8, χρησιμοποιείται για να αξιολογήσει το υβριδικό μοντέλο σε όλες τις δυνατές καταστάσεις και να υπολογίσει υπό ποιες συνθήκες αποδίδει καλύτερα ή χειρότερα. Σε συνδυασμό με την εποχική ανάλυση της Ενότητας 6.3, επιχειρεί να αναδείξει την επίδραση των μετεωρολογικών συνθηκών στην ακρίβεια πρόβλεψης ενός μοντέλου DL.

Όπως παρουσιάζεται στον Πίνακα 6.8, τους μήνες Ιούλιο και Αύγουστο δεν υπάρχει καμία συννεφιασμένη ημέρα, καθώς ακόμη και τις ημέρες με τη χαμηλότερη μέση παραγωγή (Σχήμα 6.3) υπάρχουν χρονικές στιγμές με μεγάλη προσπίπτουσα ηλιακή ακτινοβολία, άρα η μειωμένη παραγωγή οφείλεται σε δυναμικά μετεωρολογικά φαινόμενα. Σημειώνεται πως οι συνολικές ημέρες του Ιουλίου ανέρχονται στις 29 εξαιτίας του ισόποσου διαχωρισμού των δεδομένων σε σύνολο εκπαίδευσης και σύνολο αξιολόγησης. Για αυτόν τον λόγο, παραγόμενες προβλέψεις παραγωγής υπάρχουν από τις 03/07/2022 έως τις 31/12/2022. Επίσης, οι μήνες Σεπτέμβριος και Οκτώβριος εμφανίζουν παρόμοια μετεωρολογική συμπεριφορά, ενώ καταγράφουν και τις πρώτες ημέρες με επίμονες νεφώσεις για όλη τη διάρκειά τους. Το ίδιο παρατηρείται και για τους μήνες Νοέμβριο και Δεκέμβριο, οι οποίοι διαθέτουν μακράν λιγότερες ηλιόλουστες ημέρες σε σχέση με τις υπόλοιπες. Ωστόσο, τον Δεκέμβριο σημειώνονται οι περισσότερες συννεφιασμένες ημέρες εξαιτίας των δυσμενών καιρικών φαινομένων, με πιθανές διαρκείς βροχοπτώσεις. Συνολικά, η επίδραση της περιστροφής της γης υπό γωνία γύρω από τον άξονά της, η οποία είναι υπεύθυνη για τις διαφορετικές εποχές του έτους, είναι εμφανής στη μεταβολή των μετεωρολογικών συνθηκών. Παράλληλα, μέσω του Πίνακα 6.8 γίνονται αντιληπτά και τα ποιοτικά χαρακτηριστικά των καιρικών φαινομένων, παράγοντας ο οποίος εξαρτάται από το γεωγραφικό μήκος και πλάτος του εξεταζόμενου Φ/Β σταθμού. Πιο αναλυτικά, η ταξινόμηση των ημερών στις τρεις προαναφερθείσες κατηγορίες, οδηγεί στη διαπίστωση πως σε μία χώρα με εύκρατο κλίμα, όπως η Ελλάδα, καταγράφονται ευνοϊκές συνθήκες παραγωγής μέχρι και τους φθινοπωρινούς μήνες.

Στον Πίνακα 6.9 εμφανίζεται η μέση μετρούμενη προσπίπτουσα ηλιακή ακτινοβολία και η απόδοση του υβριδικού μοντέλου ανά μετεωρολογική συνθήκη. Όπως φαίνεται από τη διακύμανση του μέσου όρου της ηλιακής ακτινοβολίας, η διαφορά ανάμεσα σε μία ηλιόλουστη και σε μία συννεφιασμένη ημέρα είναι μεγάλη, επομένως δεν τίθεται ζήτημα σύγχυσης των δύο αυτών κατηγοριών. Ωστόσο, η μέση ακτινοβολία μίας δυναμικής ημέρας δεν είναι σημαντικά μικρότερη συγκριτικά με αυτή της ηλιόλουστης ημέρας.

Πίνακας 6.8 : Μετεωρολογική κατηγοριοποίηση ημερών πρόβλεψης υβριδικού μοντέλου

| Μήνας | Μέση ηλιακή ακτινοβολία (kW/m ² /15 λεπτά) | Ηλιόλουστες ημέρες | Δυναμικές ημέρες | Συννεφιασμένες ημέρες |
|-------------|--|-----------------------|---------------------|--------------------------|
| Ιούλιος | 302,29 | 19 | 10 | - |
| Αύγουστος | 271,37 | 12 | 19 | - |
| Σεπτέμβριος | 253,32 | 16 | 12 | 2 |
| Οκτώβριος | 227,80 | 17 | 12 | 2 |
| Νοέμβριος | 143,29 | 7 | 15 | 8 |
| Δεκέμβριος | 96,16 | 9 | 7 | 15 |

Πίνακας 6.9 : Μετεωρολογική απόδοση υβριδικού μοντέλου

| Είδος ημέρας | Μέση ηλιακή ακτινοβολία (kW/m ² /15 λεπτά) | RMSE (kW) | MAE (kW) | NMAE |
|---------------|--|--------------|--------------|--------------|
| Ηλιόλουστη | 272,26 | 34,84 | 18,04 | 3,61% |
| Δυναμική | 215,98 | 51,15 | 25,81 | 5,16% |
| Συννεφιασμένη | 42,27 | 39,76 | 19,66 | 3,93% |
| Σύνολο έτους | 215,71 | 42,97 | 21,51 | 4,30% |

Ο συγκεκριμένος παράγοντας καταδεικνύει την απαραίτητη προσοχή με την οποία πρέπει να ταξινομηθεί κάθε ημέρα, καθώς οι διαφορές μεταξύ ηλιόλουστης και δυναμικής ημέρας είναι πιθανό να είναι δυσδιάκριτες. Πέραν αυτού, αξίζει να αναφερθεί πως η μέση ηλιακή ακτινοβολία μίας δυναμικής ημέρας προσεγγίζει περισσότερο αυτή της ηλιόλουστης και όχι της συννεφιασμένης ημέρας. Το γεγονός αυτό οδηγεί στο συμπέρασμα πως η πλειονότητα των ημερών με δυναμικά φαινόμενα αφορούν ημέρες με υψηλή ακτινοβολία, η οποία όμως παρουσιάζει κάποια παροδική πτώση. Στο σημείο αυτό, καθίσταται εμφανές πως η κατηγοριοποίηση των ημερών δεν ήταν εφικτό να πραγματοποιηθεί με βάση κάποια στατιστική μέτρηση (π.χ. μέση τιμή ή τυπική απόκλιση ηλιακής ακτινοβολίας), καθώς υπάρχει μεγάλος αριθμός ημερών με μεγάλη μέση τιμή ακτινοβολίας, αλλά με αξιοσημείωτη πτώση για ορισμένο χρονικό διάστημα. Αντίστοιχα, παρατηρείται μικρότερος – αλλά μη αμελητέος – αριθμός ημερών, κατά τις οποίες αν και η μέση ηλιακή ακτινοβολία ήταν μικρή, εμφάνιζε σημαντική αύξηση για κάποιες ώρες. Επομένως, γίνεται σαφές πως μία δυναμική ημέρα δύναται να περιλαμβάνει ευρύ φάσμα μετεωρολογικών και καιρικών φαινομένων και οποιοσδήποτε διαχωρισμός πρέπει να πραγματοποιείται με προσοχή και εποπτικό έλεγχο τόσο της καμπύλης ακτινοβολίας όσο και των απόλυτων τιμών της.

Εκτός από τη μέση ηλιακή ακτινοβολία, στον Πίνακα 6.9 παρουσιάζεται η απόδοση του υβριδικού μοντέλου ανά κατηγορία ημέρας, με βάση τα υπολογιζόμενα μετρητικά σφάλματος RMSE, MAE και NMAE. Είναι εμφανές, πως η βέλτιστη ακρίβεια πρόβλεψης παρατηρείται τις ηλιόλουστες ημέρες, κατά τις οποίες η ηλιακή ακτινοβολία ακολουθεί μία ομαλή πορεία, χωρίς απρόσμενες αυξομειώσεις. Το φαινόμενο αυτό ευνοεί τη Φ/Β πρόβλεψη, καθώς το μοντέλο καλείται να λειτουργήσει υπό κανονικές συνθήκες, με τη μεγαλύτερη δυσκολία του να αφορά τον εντοπισμό της χρονικής στιγμής μέγιστης ημερήσιας παραγωγής. Ωστόσο, όπως φαίνεται από τα Σχήματα 6.2 και 6.4 η αριθμητική αναπαράσταση της ώρας βοηθάει σημαντικά το υβριδικό μοντέλο να αντιληφθεί το χρονικό σημείο της ημέρας και την πορεία του ήλιου στον ορίζοντα. Αν και σε μία ηλιόλουστη ημέρα η παραγωγή ενεργού ισχύος λαμβάνει μεγάλες τιμές, παράγοντας που αυξάνει τα υπολογιζόμενα σφάλματα, όπως παρουσιάζεται και στον Πίνακα 6.5, η αποτελεσματικότητα του μοντέλου είναι εξαιρετικά ικανοποιητική. Η συγκεκριμένη παράμετρος φέρει μεγάλη πρακτική αξία, καθώς υπάρχουν αυξημένες απαιτήσεις ακρίβειας για μία ηλιόλουστη ημέρα, χωρίς να υπάρχει το περιθώριο απώλειας παραγωγής. Στην Ενότητα 2.3 τονίζεται πως σημαντική απόκλιση μεταξύ πραγματικής και προβλεπόμενης Φ/Β παραγωγής μπορεί να οδηγήσει τόσο σε αναγκαστική περικοπή παραγωγής, όσο και σε επιβαλλόμενα πρόστιμα από το ΧΕ. Στον αντίποδα, το υβριδικό μοντέλο εμφανίζει μεγαλύτερη δυσκολία πρόβλεψης στις ημέρες με δυναμικά φαινόμενα, καταγράφοντας τη χειρότερη επίδοση σε όρους NMAE. Η εν λόγω διαπίστωση χαρακτηρίζεται αναμενόμενη, καθώς, όταν η ηλιακή ακτινοβολία μίας ημέρας αυξομειώνεται απρόσμενα, δυσχεραίνεται η λειτουργία του μοντέλου. Αν και ο χρονικός ορίζοντας πρόβλεψης είναι μόλις μία ώρα, είναι πολύ πιθανό να παρατηρούνται ταχέως μεταβαλλόμενα καιρικά φαινόμενα, η χειρότερη δηλαδή συνθήκη για να γίνει πρόβλεψη με ακρίβεια.

Όπως έχει ήδη αναφερθεί στο Κεφάλαιο 5, το υβριδικό μοντέλο της παρούσας εργασίας χρησιμοποιεί την παραγωγή ισχύος και τις μετεωρολογικές μεταβλητές της χρονικής στιγμής t , ώστε να προβλέψει τη Φ/Β παραγωγή τη χρονική στιγμή $t + n$, όπου n ο ορίζοντας πρόβλεψης που ισούται με μία ώρα (1-hour-ahead). Όταν καταγράφονται συνεχείς μετρήσεις με αυξανόμενη παραγωγή και ακτινοβολία, είναι λογικό η πρόβλεψη της επόμενης ώρας να είναι μία ακόμη μεγαλύτερη τιμή.

Πίνακας 6.10 : Μετεωρολογική απόδοση μη-βελτιωμένου υβριδικού μοντέλου

| Είδος ημέρας | Μέση ηλιακή ακτινοβολία (kW/m ² /15 λεπτά) | RMSE (kW) | MAE (kW) | NMAE |
|---------------|--|--------------|-------------|--------------|
| Ηλιόλουστη | 272,26 | 46,57 | 28,06 | 5,61% |
| Δυναμική | 215,98 | 58,23 | 31,20 | 6,24% |
| Συννεφιασμένη | 42,27 | 20,00 | 5,17 | 1,03% |
| Σύνολο έτους | 215,71 | 51,19 | 28,32 | 5,66% |

Ωστόσο, στην περίπτωση κάποιων πιθανών παροδικών νεφώσεων, οι μετεωρολογικές συνθήκες μεταβάλλονται ραγδαία, επομένως η πρόβλεψη δυσκολεύει εκθετικά. Επιπροσθέτως, το γεγονός πως οι δυναμικές ημέρες είναι κυρίως ημέρες υψηλής ακτινοβολίας με στιγμιαίες βυθίσεις, προκαλεί ακόμη μεγαλύτερη αύξηση των σφαλμάτων εξαιτίας του τρόπου υπολογισμού τους. Το μετρητικό σφάλματος MAE, από το οποίο προκύπτει το NMAE, είναι ένας τρόπος μέτρησης απόλυτης ακρίβειας. Για παράδειγμα, αν σε μία ημέρα με υψηλή ακτινοβολία η πραγματική τιμή παραγωγής ισούται στιγμιαία με 300 kW και η πρόβλεψη είναι 200 kW προκύπτει ένα MAE ίσο με 100 kW και MAPE 33,33%. Αντιθέτως, αν σε μία ημέρα χαμηλής ηλιακής ακτινοβολίας για μία παραγωγή 100 kW η πρόβλεψη προκύπτει ίση με 50 kW, τα σφάλματα MAE και MAPE είναι 50 kW και 50%, αντίστοιχα. Επομένως, γίνεται αντιληπτό πως η απόλυτη και η σχετική ακρίβεια είναι δύο συχνά αντικρουόμενες έννοιες και για αυτόν τον λόγο πρέπει να έχει προηγηθεί κατάλληλη επιλογή των υπολογιζόμενων σφαλμάτων. Συνολικά, οι δυναμικές ημέρες φέρουν χειρότερη απόλυτη ακρίβεια πρόβλεψης, γεγονός που δικαιολογεί τη χειρότερη απόδοση του υβριδικού μοντέλου ανά μετεωρολογική συνθήκη.

Αντίστοιχα, στις συννεφιασμένες ημέρες το υβριδικό μοντέλο αποδίδει χειρότερα από ότι στις ηλιόλουστες, αλλά καλύτερα από τις δυναμικές. Οι χαμηλές τιμές παραγωγής «συγχωρούν» πιθανές αστοχίες του υβριδικού μοντέλου, το οποίο έχει εκπαιδευθεί για αυξημένη παραγωγή τις μεσημβρινές ώρες. Στον Πίνακα 6.8 παρουσιάζεται ευκρινώς πως οι συννεφιασμένες ημέρες αποτελούν τη λιγότερο συχνά εμφανιζόμενη μετεωρολογική συνθήκη. Αν και το υβριδικό μοντέλο δεν έχει μεγάλο δείγμα εκπαίδευσης σε συννεφιασμένες ημέρες, η απόδοση του κρίνεται αρκετά ικανοποιητική.

Στον Πίνακα 6.10 εμφανίζεται η απόδοση του μη-βελτιωμένου υβριδικού μοντέλου ανά μετεωρολογική συνθήκη, σε αντιστοιχία με τον Πίνακα 6.9. Ο όρος «μη-βελτιωμένο» αναφέρεται στο υβριδικό μοντέλο των Li, Zhou, Lu και Yang [1], το οποίο δεν διαθέτει την αριθμητική αναπαράσταση της ώρας. Πιο αναλυτικά, το μη-βελτιωμένο μοντέλο παρουσιάζει χειρότερη ακρίβεια συγκριτικά με το βελτιωμένο υβριδικό της παρούσας διπλωματικής εργασίας, τόσο τις ηλιόλουστες ημέρες (NMAE 5,61% έναντι 3,61%) όσο και τις δυναμικές (NMAE 6,24% έναντι 5,16%). Ωστόσο, εμφανίζει αυξημένη ακρίβεια πρόβλεψης τις ημέρες με επίμονες νεφώσεις που χαρακτηρίζονται ως συννεφιασμένες, με το NMAE του να ισούται με 1,03%, σε αντίθεση με αυτό του βελτιωμένου υβριδικού που ισούται με 3,93%. Το φαινόμενο αυτό πιθανώς οφείλεται στον τρόπο ποσοτικοποίησης της ώρας, βάσει της οποίας το βελτιωμένο μοντέλο εκπαιδεύεται με το μοτίβο πως η ηλιακή ακτινοβολία – άρα και η παραγωγή – λαμβάνει αυξανόμενη τιμή έως το μεσημέρι και στη συνέχεια μειούμενη έως το βράδυ. Αν και η συγκεκριμένη μεταβολή είναι κυρίαρχη μεταξύ των ηλιόλουστων ημερών και της πλειονότητας των δυναμικών ημερών, δεν βρίσκει εφαρμογή στις συννεφιασμένες ημέρες. Χαρακτηριστικά, το βελτιωμένο υβριδικό μοντέλο έχει εκπαιδευθεί να ακολουθεί την καμπύλη τύπου «καμπάνας», παράγοντας ο οποίος εξηγεί και τη βέλτιστη απόδοσή του τις ηλιόλουστες ημέρες (Πίνακας 6.9). Επομένως, εξαιτίας και του γεγονότος πως οι ημέρες με πλήρεις νεφώσεις αποτελούν τη λιγότερο συχνή περίπτωση μετεωρολογικής συνθήκης, είναι πιθανό η αριθμητική αναπαράσταση της ώρας να λειτουργεί αρνητικά στις συννεφιασμένες ημέρες αποτελώντας πηγή θορύβου, καθώς δεν συναντάται η ομοιόμορφη κατανομή ακτινοβολίας που περιγράφει. Αντιθέτως, το μη-βελτιωμένο υβριδικό μοντέλο βασίζεται για τη Φ/Β πρόβλεψη εξ ολοκλήρου στην ηλιακή ακτινοβολία και στις μετρούμενες θερμοκρασίες, μεταβλητές πιο χρήσιμες για τις συννεφιασμένες ημέρες. Συνολικά, οι ημέρες που φέρουν αυξημένες απαιτήσεις ακρίβειας είναι κυρίως οι δυναμικές, κατά τις οποίες το μοντέλο της παρούσας

διπλωματικής εργασίας αποδίδει εμφανώς καλύτερα συγκριτικά με το μη βελτιωμένο, πέραν φυσικά της καλύτερης μέσης ακριβείας του (NMAE 4,30% έναντι 5,66%).

6.5 ΤΑΧΥΤΗΤΑ ΕΚΠΑΙΔΕΥΣΗΣ ΑΡΧΙΚΩΝ ΜΟΝΤΕΛΩΝ, ΥΒΡΙΔΙΚΟΥ ΚΑΙ ΒΕΛΤΙΩΜΕΝΟΥ ΥΒΡΙΔΙΚΟΥ

Στον Πίνακα 6.11 παρουσιάζεται ο χρόνος εκπαίδευσης κάθε εξεταζόμενου μοντέλου πρόβλεψης, όπως και ο αριθμός των επαναλήψεων που απαιτούνται για την επίτευξη της βέλτιστης ακριβείας. Είναι εμφανές, πως τα μοντέλα 1 Layer LSTM και 3 Layers LSTM χρειάζονται περισσότερες επαναλήψεις για να βελτιστοποιηθεί η αντικειμενική τους συνάρτηση, καθώς είναι απλούστερα αρχιτεκτονικά και δεν διαθέτουν σύνθετες τεχνικές επεξεργασίας. Επιπλέον, όσο απλούστερη δομή φέρει ένα RNN, τόσο μειώνεται ο κίνδυνος της υπέρ-προσαρμογής και είναι εφικτό να εκτελεστούν περισσότερες επαναλήψεις κατά τη διαδικασία εκπαίδευσης χωρίς να μειώνεται η υπολογιζόμενη ακρίβεια, όπως αναπτύχθηκε και στην Ενότητα 5.3.

Ο χρόνος εκπαίδευσης ενός μοντέλου ML εξαρτάται από ποικίλους παράγοντες, ωστόσο, αποτελεί μία σημαντική παράμετρο αξιολόγησης, καθώς ιδιαίτερα αυξημένοι χρόνοι είναι πιθανό να καταστούν απαγορευτικοί. Όπως είναι λογικό, τα αρχικά μοντέλα πρόβλεψης (1 Layer LSTM και 3 Layers LSTM) απαιτούν μικρότερους χρόνους εκπαίδευσης, όσο μειώνεται ο αριθμός των νευρώνων και των κρυφών στρωμάτων του νευρωνικού δικτύου. Αντίθετα, τα πιο σύνθετα υβριδικά μοντέλα φέρουν μεγαλύτερο υπολογιστικό χρόνο, τόσο λόγω της παρουσίας περισσότερων δικτύων LSTM, όσο και της παρουσίας της μεθόδου αποσύνθεσης WPD. Ο ελαφρά αυξημένος χρόνος εκπαίδευσης του βελτιωμένου υβριδικού μοντέλου (504 sec) οφείλεται στην επιπλέον μεταβλητή εισόδου της αριθμητικής αναπαράστασης της ώρας, την οποία πρέπει να διαχειριστεί το υπολογιστικό σύστημα. Οι χρόνοι εκπαίδευσης του Πίνακα 6.11 αφορούν μόνο τον βέλτιστο συνδυασμό υπέρ-παραμέτρων και συνολικά κρίνονται ικανοποιητικοί. Αξίζει να επισημανθεί πως η αύξηση των κρυφών στρωμάτων ενός LSTM επιφέρει εκθετική αύξηση του χρόνου εκπαίδευσης, καθώς οι υπολογιστικοί νευρώνες σε αυτή την περίπτωση λειτουργούν εμφωλευμένα και όχι ακολουθιακά, όπως η προσθήκη ενός διακριτού δικτύου LSTM. Όλοι οι υπολογισμοί εκτελέστηκαν στη γλώσσα προγραμματισμού Python, στο προγραμματιστικό περιβάλλον Spyder, σε οικιακό ηλεκτρονικό υπολογιστή (Desktop) με επεξεργαστή Intel® Core™ i5-7500 CPU (3.40GHz, 4 cores) και μνήμη RAM 16GB.

Πίνακας 6.11 : Βέλτιστος αριθμός επαναλήψεων και χρόνος εκπαίδευσης αρχικών μοντέλων, υβριδικού και βελτιωμένου υβριδικού

| Μοντέλο | Βέλτιστος Αριθμός επαναλήψεων | Χρόνος εκπαίδευσης (sec) |
|-----------------------------|-------------------------------|--------------------------|
| Persistence | - | - |
| 1 Layer LSTM | 500 | 69 |
| 3 Layers LSTM | 300 | 116 |
| Υβριδικό μοντέλο | 50 | 342 |
| Βελτιωμένο υβριδικό μοντέλο | 100 | 504 |

ΕΦΑΡΜΟΓΗ ΥΒΡΙΔΙΚΟΥ ΜΟΝΤΕΛΟΥ ΣΤΗΝ ΑΓΟΡΑ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ

7.1 ΓΕΝΙΚΑ

Η ακρίβεια πρόβλεψης της παραγωγής ηλεκτρικής ενέργειας αποτελεί καθοριστικό παράγοντα τόσο για την ορθή λειτουργία του συστήματος ηλεκτρικής ενέργειας, όσο και για την απρόσκοπτη διείσδυση μονάδων διανεμημένης παραγωγής. Οι κοινές ενεργειακές στρατηγικές των τελευταίων ετών σε επίπεδο κρατών, με σκοπό τη μείωση του περιβαλλοντικού αποτυπώματος, συνεπάγονται αυξημένες απαιτήσεις ακρίβειας για τα χρησιμοποιούμενα μοντέλα πρόβλεψης. Σε αυτή την κατεύθυνση, μέσω του πρόσφατου, στην Ελλάδα, θεσμού του ΧΕ καταβάλλεται προσπάθεια να ισοσκελιστεί η παραγωγή και η κατανάλωση σε πραγματικό χρόνο ώστε να διευκολύνεται όσο το δυνατόν περισσότερο η παραγωγή ενέργειας μέσω ΑΠΕ. Πιο συγκεκριμένα, η μετακίνηση της προθεσμίας παράδοσης ενεργειακών προϊόντων και της υποβολής δεσμευτικής προσφοράς πιο κοντά στον πραγματικό χρόνο, μειώνει τη διάρκεια των περιόδων ένταξης των μονάδων και επιτρέπει στους λειτουργούς του συστήματος να εκμεταλλεύονται το γεγονός ότι η ακρίβεια πρόβλεψης της παραγωγής βελτιώνεται σημαντικά, όταν αφορά μικρό χρονικό ορίζοντα [94]. Για αυτόν τον λόγο, ενισχύεται όλο και περισσότερο η ανάπτυξη και η χρήση μοντέλων βραχυπρόθεσμης πρόβλεψης, καθώς με αυτόν τον τρόπο μειώνεται το συνολικό κόστος διατήρησης του ισοζυγίου ανάμεσα στην παραγωγή και στη ζήτηση σε συστήματα με μεγάλη συμμετοχή μονάδων διανεμημένης παραγωγής.

Όπως αναφέρεται στο Κεφάλαιο 5, το υβριδικό μοντέλο της παρούσας διπλωματικής εργασίας δεν προβαίνει σε ευνοϊκές παραδοχές – όπως η θεώρηση για εκ των προτέρων γνώση μελλοντικών μετεωρολογικών μεταβλητών – αλλά εκπαιδεύεται και αξιολογείται υπό πραγματικές συνθήκες. Αναλυτικότερα, χρησιμοποιεί την παραγωγή ενεργού ισχύος και τα μετεωρολογικά μεγέθη της ώρας t (προσπίπτουσα ηλιακή ακτινοβολία, θερμοκρασία περιβάλλοντος, θερμοκρασία συλλέκτη, αριθμητική αναπαράσταση ώρας) για να προβλέψει την παραγωγή σε χρονικό ορίζοντα μίας ώρας. Έχοντας ως γνώμονα τα προηγούμενα, στην παρούσα εργασία επιχειρείται η απαιτητική εφαρμογή του υβριδικού μοντέλου σε ένα ρεαλιστικό πρόβλημα του ενεργειακού τοπίου, όπως είναι η αξιοποίησή του στην αγορά ηλεκτρικής ενέργειας. Αν και η πλειονότητα των μοντέλων πρόβλεψης ML περιστρέφεται γύρω από ζητήματα ερευνητικού σκοπού, το εν λόγω υβριδικό μοντέλο εφαρμόζεται στο πραγματικό πλαίσιο της αγοράς ηλεκτρικής ενέργειας και η απόδοσή του αξιολογείται υπό πραγματικές συνθήκες, όχι μόνο μέσω του υπολογισμού σφαλμάτων αλλά και μέσω μίας διαδικασίας που περιλαμβάνει και οικονομικό αντίκτυπο. Η συγκεκριμένη εφαρμογή αποτελεί την κύρια συνεισφορά της παρούσας διπλωματικής εργασίας, το κατασκευασμένο υβριδικό

μοντέλο της οποίας θα μπορούσε, υπό προϋποθέσεις, να αξιοποιηθεί από κάποιον συμμετέχοντα της αγοράς σε ένα πραγματικό πρόβλημα πρόβλεψης Φ/Β παραγωγής.

7.2 ΡΥΘΜΙΣΤΙΚΟ ΠΛΑΙΣΙΟ ΛΕΙΤΟΥΡΓΙΑΣ ΑΓΟΡΑΣ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ

Σε μία προσπάθεια αναδιοργάνωσης της ελληνικής χονδρεμπορικής αγοράς ηλεκτρικής ενέργειας και σε εφαρμογή των ευρωπαϊκών κανονισμών και οδηγιών, το 2016 συστάθηκε το ελληνικό ΧΕ (Ν. 4426/2016) [95]. Απώτερος σκοπός αυτής της κίνησης ήταν η σύζευξη της ελληνικής αγοράς ηλεκτρικής ενέργειας με τις υπόλοιπες ευρωπαϊκές αγορές, η ολοκλήρωση της ενιαίας ευρωπαϊκής αγοράς και η ενίσχυση του ανταγωνισμού και της αξιοπιστίας. Προκειμένου οι αγορές ηλεκτρικής ενέργειας, στις οποίες συμμετέχουν οι ΑΠΕ, να λειτουργούν με διαφάνεια και αποτελεσματικότητα, απαιτείται η παρουσία ενός ανεξάρτητου διαχειριστή για την ορθή εκκαθάριση και διαχείριση της παραγόμενης ενέργειας. Τον συγκεκριμένο ρόλο επιτελεί ο Διαχειριστής Ανανεώσιμων Πηγών Ενέργειας και Εγγυήσεων Προέλευσης (ΔΑΠΕΕΠ), ο οποίος διαχειρίζεται τις ΑΠΕ και τη Συμπαράγωγή Ηλεκτρισμού και Θερμότητας Υψηλής Απόδοσης (ΣΗΘΥΑ) του εθνικού διασυνδεδεμένου συστήματος, καθώς και τις εγγυήσεις προέλευσης παραγόμενης από ΑΠΕ και ΣΗΘΥΑ ηλεκτρικής ενέργειας [96]. Παράλληλα, αποτελεί τον εκπλειστηριαστή των δικαιωμάτων ρύπων στην Ελλάδα και λειτουργεί ως ΦοΣΕ παραγωγών ΑΠΕ. Ο ΔΑΠΕΕΠ είναι η μετεξέλιξη του Λειτουργού Αγοράς Ηλεκτρικής Ενέργειας (ΛΑΓΗΕ) και δημιουργήθηκε με σκοπό να ικανοποιήσει τις σύγχρονες προκλήσεις στον χώρο των ΑΠΕ, ενώ ταυτόχρονα είναι ο μεγαλύτερος μέτοχος στο ελληνικό ΧΕ και ο δεύτερος μεγαλύτερος πωλητής στην αγορά ηλεκτρικής ενέργειας.

Επειδή το ελληνικό ενεργειακό τοπίο ήταν και παραμένει δαιδαλώδες, η ευθυγράμμιση της ελληνικής αγοράς με το μοντέλο στόχο (target model) είναι μία διαδικασία η οποία υλοποιείται σταδιακά, δίνοντας έτσι την ευκαιρία στους συμμετέχοντες να εξοικειωθούν με τους νέους κανονισμούς δίχως να διακυβεύεται η προμήθεια ηλεκτρικής ενέργειας. Σε αυτή την κατεύθυνση, τον Δεκέμβριο του 2021 ο ΔΑΠΕΕΠ εξέδωσε μία μελέτη στο πλαίσιο ενός μεταβατικού μηχανισμού, ο οποίος εφαρμόστηκε κατά το έτος 2022. Ο Μεταβατικός Μηχανισμός Βέλτιστης Ακρίβειας Πρόβλεψης (ΜΜΒΑΠ), στις αρμοδιότητες του οποίου εντάσσονται οι ευθύνες εξισορρόπησης των μονάδων ΑΠΕ και ΣΗΘΥΑ υποχρεωτικής συμμετοχής στις αγορές, λειτουργεί μέχρι την ανάληψη πλήρους ευθύνης εξισορρόπησης από τις ΑΠΕ [97]. Η ανάληψη πλήρους ευθύνης εξισορρόπησης από τις ΑΠΕ τοποθετείται με την ύπαρξη συνεχούς ενδομήρησιας αγοράς, η οποία αγορά παρέχει στις ΑΠΕ τη δυνατότητα διόρθωσης της θέσης τους έως και μία ώρα πριν τη φυσική παράδοση ώστε να ελαχιστοποιούν τις αποκλίσεις τους στην αγορά εξισορρόπησης πραγματικού χρόνου. Η συγκεκριμένη μελέτη καθορίζει τα όρια ανοχής στην απόκλιση μεταξύ πραγματικής και προβλεπόμενης παραγωγής ηλεκτρικής ενέργειας, καθώς και τους συντελεστές υπολογισμού των χρεώσεων ΜΜΒΑΠ, με τις οποίες επιβαρύνονται οι ΦοΣΕ. Ουσιαστικά, προσδιορίζεται ο τρόπος με τον οποίο «τιμωρούνται» οι ΦοΣΕ κατά τη διαδικασία υποβολής των προβλέψεων παραγωγής των εκπροσωπούμενων σταθμών ΑΠΕ, εφόσον δεν προσεγγιστεί σε έναν προκαθορισμένο βαθμό η παραδοθείσα ενέργεια. Η μελέτη στο πλαίσιο του ΜΜΒΑΠ αφορά τη διαδικασία προβλέψεων της αγοράς επόμενης ημέρας, κατά την οποία οι προβλέψεις παραγωγής

υποβάλλονται μια ημέρα πριν την ημέρα φυσικής παράδοσης των ενεργειακών προϊόντων. Η συγκεκριμένη αγορά είναι καθοριστικής σημασίας για τη διασφάλιση της ενεργειακής επάρκειας, για τον προκαθορισμό του ενεργειακού μίγματος παραγωγής, καθώς και για τον έλεγχο της εντός ορίων λειτουργίας των δικτύων μεταφοράς και διανομής ηλεκτρικής ενέργειας. Αναμφίβολα, η εγκατεστημένη ισχύς των σταθμών ΑΠΕ με συμμετοχή στις αγορές ηλεκτρικής ενέργειας, η ζήτηση ηλεκτρικής ενέργειας και γενικότερα οι παράγοντες που επηρεάζουν την αγοραπωλησία ενέργειας είναι ευμετάβλητοι και για αυτόν τον λόγο οι αριθμητικές τιμές των συντελεστών και των ορίων ανοχής δύνανται να μεταβάλλονται για κάθε ημερολογιακό έτος με απόφαση της Ρυθμιστικής Αρχής Ενέργειας (ΡΑΕ), κατόπιν εισήγησης του ΔΑΠΕΕΠ. Στόχος του ΜΜΒΑΠ αποτελεί η μείωση των αποκλίσεων που επιβάλλουν οι ΑΠΕ στο ΕΣΜ, η εύρυθμη λειτουργία της αγοράς ηλεκτρικής ενέργειας και ο εξορθολογισμός της επιβαλλόμενης χρέωσης στους ΦοΣΕ, η οποία πρέπει να ανταποκρίνεται στο μέγεθος και στα έσοδα των σταθμών ΑΠΕ με υποχρεωτική συμμετοχή στις αγορές.

Σύμφωνα με την ελληνική νομοθεσία (Ν. 4414/2016) υποχρέωση συμμετοχής στις αγορές ηλεκτρικής ενέργειας έχουν όσοι σταθμοί ΑΠΕ ή ΣΗΘΥΑ έχουν συνάψει Σύμβαση Λειτουργικής Ενίσχυσης Διαφορικής Προσαύξησης (ΣΕΔΠ) [98]. Η ΣΕΔΠ είναι η σύμβαση που υπογράφουν οι κάτοχοι σταθμών παραγωγής ηλεκτρικής ενέργειας από ΑΠΕ ή ΣΗΘΥΑ με τον ΔΑΠΕΕΠ για την ένταξη του σταθμού τους στο διασυνδεδεμένο σύστημα. Η διαφορική προσαύξηση υπολογίζεται σε μηνιαία βάση ως η διαφορά της ειδικής τιμής αγοράς της συγκεκριμένης τεχνολογίας (ανηγμένη μεσοσταθμική αξία της εγγεόμενης ηλεκτρικής ενέργειας) από την τιμή αναφοράς σε €/MWh, η οποία καθορίζεται ανά τεχνολογία σταθμών και διέπει τη σύμβαση. Αντίθετα, από τη ΣΕΔΠ – άρα και από υποχρέωση συμμετοχής στην αγορά ηλεκτρικής ενέργειας – εξαιρούνται οι αοικικοί σταθμοί εγκατεστημένης ισχύος μικρότερης των 3 MW, Φ/Β σταθμοί και ΣΗΘΥΑ εγκατεστημένης ισχύος μικρότερης των 500 kW και έργα ΑΠΕ μη κερδοσκοπικού χαρακτήρα. Οι συγκεκριμένοι σταθμοί συνάπτουν με τον ΔΑΠΕΕΠ Σύμβαση λειτουργικής Ενίσχυσης Σταθερής Τιμής (ΣΕΣΤ) και, επομένως, δεν συμμετέχουν στις αγορές ηλεκτρικής ενέργειας, αλλά αποζημιώνονται με μία σταθερή τιμή ανά μονάδα παραγόμενης ενέργειας. Η αποζημίωση των κατόχων των σταθμών ΑΠΕ και ΣΗΘΥΑ που διαθέτουν Σύμβαση Πώλησης Ηλεκτρικής Ενέργειας (ΣΠΗΕ), δηλαδή είτε ΣΕΔΠ είτε ΣΕΣΤ, πραγματοποιείται από τον Ειδικό Διαχειριστικό Λογαριασμό ΑΠΕ και ΣΗΘΥΑ (ΕΛΑΠΕ), τον οποίο διαχειρίζεται ο ΔΑΠΕΕΠ.

7.3 ΤΡΟΠΟΣ ΥΠΟΛΟΓΙΣΜΟΥ ΧΡΕΩΣΕΩΝ

Όπως αναφέρεται προηγουμένως, η χρέωση ΜΜΒΑΠ είναι πρακτικά ένα πρόστιμο το οποίο επιβάλλεται από τον ΔΑΠΕΕΠ στους ΦοΣΕ, αναλογικά της απόκλισης μεταξύ πραγματικής και προβλεπόμενης ενέργειας. Το εν λόγω ρυθμιστικό πλαίσιο εφαρμόστηκε το έτος 2022 με σκοπό την αύξηση της ακρίβειας των μοντέλων πρόβλεψης και την αποφυγή συστηματικής εκούσιας αισιόδοξης ή απαισιόδοξης πρόβλεψης. Η επιβαλλόμενη χρέωση για κάθε χαρτοφυλάκιο Σταθμών ΑΠΕ με ΣΕΔΠ σε κανονική λειτουργία υπολογίζεται με βάση την εξίσωση (7.1) [97]:

$$NCBAL_GRES = BAL_GRES \cdot REPSUR \cdot |M_Q - M_S| \quad (7.1)$$

όπου $NCBAL_GRES$ η τελική χρέωση ΜΜΒΑΠ, BAL_GRES η μοναδιαία χρέωση ΜΜΒΑΠ, $REPSUR$ ο σταθμισμένος με τη μηνιαία παραγωγή ανά τεχνολογία μέσος όρος των συντελεστών SUR_GRES του χαρτοφυλακίου, M_Q η μετρηθείσα (παραγόμενη) ενέργεια στα σημεία σύνδεσης με το σύστημα ή το δίκτυο σε MWh και M_S το σύνολο ενέργειας που έχει ενταχθεί στις βραχυχρόνιες αγορές ενέργειας (προβλεπόμενη) σε MWh. Η μοναδιαία τιμή της χρέωσης ΜΜΒΑΠ (BAL_GRES) υπολογίζεται σε €/MWh ως το 50% του ετήσιου μέσου όρου της απόλυτης τιμής της διαφοράς της τιμής εκκαθάρισης αγοράς της αγοράς επόμενης ημέρας από την τιμή αποκλίσεων του προηγούμενου έτους. Τόσο η τιμή εκκαθάρισης της αγοράς επόμενης ημέρας όσο και η τιμή αποκλίσεων είναι μεταβλητά μεγέθη τα οποία προκύπτουν μέσω της λειτουργίας του ΧΕ και για αυτόν τον λόγο ανακοινώνονται για κάθε έτος από τον ΔΑΠΕΕΠ. Οι συντελεστές SUR_GRES ορίζονται από το ρυθμιστικό πλαίσιο ανά τεχνολογία, μέγεθος χαρτοφυλακίου, μέγεθος απόκλισης, καθώς και ανά εποχή, και παρουσιάζονται στον Πίνακα 7.1. Η χρέωση ΜΜΒΑΠ (εξίσωση (7.1)) επιβάλλεται στους ΦοΣΕ εφόσον ικανοποιείται μία εκ των εξισώσεων (7.2) και (7.3) σε ωριαίο επίπεδο:

$$\frac{|M_Q - M_S|}{P_{inst}} > REPTOL_1 \quad (7.2)$$

$$\frac{|M_Q - M_S|}{P_{inst}} > REPTOL_2 \quad (7.3)$$

όπου P_{inst} η εγκατεστημένη ισχύς του συνολικού χαρτοφυλακίου που συμμετέχει στην προημερήσια αγορά ενέργειας και $REPTOL_1$, $REPTOL_2$ οι σταθμισμένοι με τη μηνιαία παραγωγή ανά τεχνολογία μέσοι όροι των ορίων $BAL_TOL_GRES_1$ και $BAL_TOL_GRES_2$, αντίστοιχα. Τα όρια $BAL_TOL_GRES_1$ και $BAL_TOL_GRES_2$ ορίζονται από το ρυθμιστικό πλαίσιο και παρουσιάζονται, ομοίως, στον Πίνακα 7.1. Η ποσότητα $\frac{|M_Q - M_S|}{P_{inst}}$ είναι το κανονικοποιημένο υπό την εγκατεστημένη ισχύ απόλυτο σφάλμα, επομένως περιγράφει τη μέτρηση σφάλματος NMAE (εξίσωση (6.2)). Τα $REPTOL_1$, $REPTOL_2$ αφορούν τα προκαθορισμένα όρια ανοχής της πρόβλεψης για τα οποία ισχύει $REPTOL_1 < REPTOL_2$. Ανάλογα με την τιμή του κανονικοποιημένου σφάλματος διακρίνονται τρεις περιπτώσεις:

- $\frac{|M_Q - M_S|}{P_{inst}} < REPTOL_1$: Η πρόβλεψη θεωρείται επιτυχής και δεν υπάρχει χρέωση.
- $REPTOL_1 < \frac{|M_Q - M_S|}{P_{inst}} < REPTOL_2$: Επιβάλλεται η χρέωση $NCBAL_GRES$ βάσει των καθορισμένων συντελεστών SUR_GRES .
- $\frac{|M_Q - M_S|}{P_{inst}} > REPTOL_2$: Επιβάλλεται η χρέωση $NCBAL_GRES$ βάσει των καθορισμένων δυσμενέστερων συντελεστών SUR_GRES .

Πίνακας 7.1 : Καθορισμένοι συντελεστές ΜΜΒΑΠ

| Συντελεστής | Τεχνολογία | Ισχύς (MW) | Τιμή | |
|---|--|------------|---------|-----|
| $BAL_TOL_GRES_1$ | Αιολικά και Φ/Β | - | 6% | |
| | Λοιπές ΑΠΕ | - | 4% | |
| $BAL_TOL_GRES_2$ | Αιολικά και Φ/Β | - | 12% | |
| | Λοιπές ΑΠΕ | - | 8% | |
| SUR_GRES ($REPTOL_1 < \frac{ M_Q - M_S }{P_{inst}} < REPTOL_2$) | Αιολικά | 0-20 | 0,05 | |
| | | 20-100 | 0,15 | |
| | | 100-250 | 0,2 | |
| | | >250 | 0,5 | |
| | Φ/Β (01/10 – 30/04) | 0-2 | 0,05 | |
| | | 2-20 | 0,3 | |
| | | 20-100 | 0,5 | |
| | | >250 | 0,8 | |
| | Φ/Β (01/05 – 30/09) | 0-2 | 0,1 | |
| | | 2-20 | 0,4 | |
| | | 20-100 | 0,6 | |
| | | >250 | 0,85 | |
| | Λοιπές ΑΠΕ | - | 0,5 | |
| | SUR_GRES ($\frac{ M_Q - M_S }{P_{inst}} > REPTOL_2$) | Αιολικά | 0-20 | 0,1 |
| | | | 20-100 | 0,3 |
| | | | 100-250 | 0,5 |
| >250 | | | 0,9 | |
| Φ/Β (01/10 – 30/04) | | 0-2 | 0,1 | |
| | | 2-20 | 0,5 | |
| | | 20-100 | 0,6 | |
| | | >250 | 0,85 | |
| Φ/Β (01/05 – 30/09) | | 0-2 | 0,2 | |
| | | 2-20 | 0,6 | |
| | | 20-100 | 0,7 | |
| | | >250 | 0,95 | |
| Λοιπές ΑΠΕ | | - | 0,5 | |

Στον Πίνακα 7.1 παρουσιάζονται οι συντελεστές και τα όρια ανοχής που διέπουν τον ΜΜΒΑΠ και είναι καθορισμένα από τον ΔΑΠΕΕΠ. Βάσει αυτών προσδιορίζονται οι παράμετροι των εξισώσεων (7.1) – (7.3) και προκύπτει η χρέωση ΜΜΒΑΠ ανά MWh απόκλισης ενέργειας. Οι παρεμβαλλόμενοι συντελεστές διαφοροποιούνται ανά τεχνολογία, ανά εποχή και με βάση την εγκατεστημένη ισχύ του εξεταζόμενου σταθμού, ούτως ώστε να λάβουν υπόψη τα ποιοτικά χαρακτηριστικά της διαδικασίας πρόβλεψης παραγωγής ηλεκτρικής ενέργειας.

Συνδυάζοντας την εξίσωση (7.1) και τον Πίνακα 7.1 εξάγεται το απλό συμπέρασμα πως όσο αυξάνεται η τιμή των παραμέτρων SUR_GRES – άρα και ο συντελεστής $REPSUR$ – τόσο αυξάνεται η χρέωση $NCBAL_GRES$ για την ίδια απόκλιση μεταξύ μετρούμενης και προβλεπόμενης ενέργειας. Επιπλέον, ορίζονται οι συντελεστές χρέωσης με βάση την τιμή του

υπολογιζόμενου ωριαίου NMAE και το αν αυτό υπερβαίνει ή όχι τα όρια $REPTOL_1$, $REPTOL_2$. Εκτός των άλλων, μέσω του Πίνακα 7.1 γίνεται αντιληπτό πως ΑΠΕ με μεγαλύτερη εγκατεστημένη ισχύ φέρουν μεγαλύτερη τιμή συντελεστή SUR_GRES , το οποίο σημαίνει πως μία αποτυχημένη πρόβλεψη βαραίνει περισσότερο τον αντίστοιχο ΦοΣΕ. Το γεγονός αυτό οφείλεται στην εκτίμηση του ΔΑΠΕΕΠ πως είναι ευκολότερο να παράγονται αξιόπιστες προβλέψεις όταν αυτές αφορούν έργα με μεγάλη εγκατεστημένη ισχύ, συγκριτικά με την περίπτωση που εκπροσωπείται κάποιος σταθμός μικρής ισχύος. Αδιαμφισβήτητα, όταν στην προημερήσια αγορά ενέργειας συμμετέχει ένας σταθμός μεγάλης εγκατεστημένης ισχύος, είναι ευκολότερο τα υπολογιζόμενα σφάλματα NMAE να περιοριστούν κάτω από τα καθορισμένα όρια, καθώς αυτά κανονικοποιούνται υπό την εγκατεστημένη ισχύ του σταθμού. Στο σημείο αυτό, πρέπει να αναφερθεί πως οι ΦοΣΕ υποβάλλουν προβλέψεις παραγωγής για το σύνολο του χαρτοφυλακίου τους και όχι για κάθε επιμέρους σταθμό, επομένως μειώνεται η μεταβλητότητα των προβλέψεων συγκριτικά με την περίπτωση που εκπροσωπείται μεμονωμένα ένα έργο ΑΠΕ. Για αυτόν τον λόγο, η αποκλίνουσα ενέργεια κοστολογείται δυσμενέστερα για ΦοΣΕ με μεγάλα χαρτοφυλάκια, καθώς λαμβάνεται υπόψη πως αυτή προκύπτει από το σύνολο των σταθμών και είναι πιθανό αν σε μία περίπτωση υπάρχει υπέρ-πρόβλεψη να ισοσταθμίζεται με κάποια ενδεχόμενη υπό-πρόβλεψη αλλού. Το φαινόμενο αυτό ονομάζεται επίδραση συσσώρευσης (aggregation effect) και κατέχει κρίσιμο χαρακτήρα στη διαδικασία πρόβλεψης Φ/Β παραγωγής [99]. Όταν το χρησιμοποιούμενο μοντέλο πρόβλεψης διαχειρίζεται χωρικά και χρονικά διεσπαρμένους Φ/Β σταθμούς, το συνολικό υπολογιζόμενο σφάλμα μειώνεται λόγω της "αλληλεξουδετέρωσης" των επιμέρους αποκλίσεων. Η εν λόγω παράμετρος παρατηρείται όχι μόνο σε πολλαπλές γεωγραφικές τοποθεσίες, αλλά και σε μεμονωμένους Φ/Β σταθμούς αυξημένης εγκατεστημένης ισχύος που καταλαμβάνουν μεγάλες εκτάσεις, καθώς την ίδια στιγμή μπορεί κάποιοι ηλιακοί συλλέκτες να είναι υπό σκιά και κάποιοι όχι, και αντίστροφα.

Εκτός των άλλων, είναι προφανές μέσω του Πίνακα 7.1 πως οι μήνες από τον Μάιο έως και τον Σεπτέμβριο επιφέρουν αυξημένους συντελεστές χρέωσης σε σχέση με τους υπόλοιπους μήνες. Οι καλοκαιρινοί μήνες, όπως παρουσιάζεται αναλυτικά και στην Ενότητα 6.4, διαθέτουν λιγότερες ημέρες με δυναμικά φαινόμενα, επομένως θεωρείται πως η διαδικασία πρόβλεψης πραγματοποιείται υπό ευνοϊκότερες συνθήκες. Αντίθετα, τους φθινοπωρινούς και τους χειμερινούς μήνες εμφανίζονται περισσότερες ημέρες κατά τις οποίες τα μετεωρολογικά φαινόμενα μεταβάλλονται ταχέως και απρόσμενα, παράγοντας που δυσχεραίνει τη Φ/Β πρόβλεψη. Η συγκεκριμένη παράμετρος λαμβάνεται υπόψη από τον MMBAΠ, ο οποίος στοχεύει στον εξορθολογισμό της αγοράς ηλεκτρικής ενέργειας και όχι στην παράλογη χρέωση των ΦοΣΕ, άρα οι αντίστοιχοι συντελεστές είναι μικρότεροι.

Με βάση τα καθορισμένα μεγέθη ανά έτος από τον ΔΑΠΕΕΠ και τα μοναδικά χαρακτηριστικά του εκπροσωπούμενου έργου ΑΠΕ προκύπτουν οι συντελεστές της εξίσωσης (7.1), μέσω των οποίων υπολογίζεται η χρέωση MMBAΠ. Τα ιστορικά δεδομένα και οι προβλέψεις του υβριδικού μοντέλου της παρούσας διπλωματικής εργασίας το οποίο αξιοποιείται για να προβλέψει την παραγωγή ενεργού ισχύος σε χρονικό ορίζοντα μίας ώρας αφορούν το έτος 2022, επομένως λαμβάνοντας υπόψη τον εξεταζόμενο Φ/Β σταθμό προκύπτουν οι συντελεστές του Πίνακα 7.2. Η διαδικασία υπολογισμού των χρεώσεων MMBAΠ εκτελείται κατά τη μηνιαία εκκαθάριση του ΔΑΠΕΕΠ για όλο το χαρτοφυλάκιο εκπροσώπησης κάθε ΦοΣΕ. Πιο αναλυτικά, υπολογίζεται σε ωριαίο επίπεδο η απόκλιση μεταξύ μετρηθείσας και προβλεπόμενης ενέργειας, καθώς και το αντίστοιχο σφάλμα NMAE.

Πίνακας 7.2 : Καθορισμένοι συντελεστές για τον εξεταζόμενο Φ/Β σταθμό

| Συντελεστής | Αριθμητική τιμή |
|--|-----------------|
| <i>BAL_GRES</i> | 29,39 €/MWh |
| <i>REPTOL</i> ₁ | 6% |
| <i>REPTOL</i> ₂ | 12% |
| <i>REPSUR</i> (<i>REPTOL</i> ₁ < <i>NMAE</i> < <i>REPTOL</i> ₂ & 01/05 – 30/09) | 0,1 |
| <i>REPSUR</i> (<i>REPTOL</i> ₁ < <i>NMAE</i> < <i>REPTOL</i> ₂ & 01/10 – 30/04) | 0,05 |
| <i>REPSUR</i> (<i>NMAE</i> > <i>REPTOL</i> ₂ & 01/05 – 30/09) | 0,2 |
| <i>REPSUR</i> (<i>NMAE</i> > <i>REPTOL</i> ₂ & 01/10 – 30/04) | 0,1 |

Ανάλογα με την τιμή του σφάλματος, προκύπτει – αν προβλέπεται βάσει ορίων – το επιβαλλόμενο πρόστιμο χρησιμοποιώντας τους αντίστοιχους συντελεστές του Πίνακα 7.2 και εφαρμόζοντας την εξίσωση (7.1). Με αυτή τη μεθοδολογία υπολογίζονται οι αποκλίσεις και όλες οι χρεώσεις για κάθε ώρα κάθε ημέρας του προς εκκαθάριση μήνα, οι οποίες αθροίζονται και προκύπτει η συνολική οφειλή του ΦοΣΕ προς τον ΔΑΠΕΕΠ.

7.4 ΥΠΟΛΟΓΙΣΜΟΣ ΜΗΝΙΑΙΑΣ ΑΠΟΔΟΣΗΣ

Η εφαρμογή του κατασκευασμένου υβριδικού μοντέλου στην αγορά ηλεκτρικής ενέργειας αποτελεί την κύρια συνεισφορά και επέκταση της παρούσας διπλωματικής εργασίας. Η συγκεκριμένη κατεύθυνση είναι έκδηλη σε όλες τις πτυχές της εργασίας, καθώς σε κανένα στάδιο υλοποίησής της δεν έχουν γίνει παραδοχές εξιδανίκευσης. Η δημιουργία, η εκπαίδευση και η αξιολόγηση του υβριδικού μοντέλου έχουν διεξαχθεί υπό ρεαλιστικές συνθήκες με πραγματικά ιστορικά δεδομένα, χωρίς παρεμβαλλόμενες απλουστευτικές θωρήσεις. Στο ίδιο μήκος κύματος, η εφαρμογή του παρόντος Κεφαλαίου 7 μελετάται υπό το καθορισμένο ρυθμιστικό πλαίσιο και τις οδηγίες του ΔΑΠΕΕΠ, το οποίο εφαρμόστηκε το έτος 2022.

Προκειμένου τα ιστορικά δεδομένα και οι παραγόμενες προβλέψεις να είναι εφικτό να αξιολογηθούν στο πλαίσιο του ΜΜΒΑΠ, είναι αναγκαίο να μετατραπούν από τεταρτιαίες σε ωριαίες. Για να αποφευχθεί κάποια πιθανή προκατάληψη, επιλέχθηκε οι τέσσερις επιμέρους αριθμητικές τιμές που συνιστούν μία ώρα να αθροιστούν ισοβαρώς, ούτως ώστε κάθε τέσσερις χρονικές στιγμές να αντικατασταθούν από μία. Επομένως, υπολογίζεται ο απλός μέσος όρος των δεδομένων παραγωγής και πρόβλεψης ανά τέσσερις χρονικές στιγμές και προκύπτει μία τιμή, η οποία αναπαριστά την ωριαία παραγωγή και πρόβλεψη. Προφανώς, επειδή όπως έχει αναφερθεί, το σύνολο δεδομένων αξιολόγησης αποτελεί το 50% των αρχικών δεδομένων, ο υπολογισμός της μηνιαίας απόδοσης πραγματοποιείται για τους μήνες των διαθέσιμων προβλέψεων, δηλαδή Ιούλιο – Δεκέμβριο. Το πλαίσιο συμμετοχής στην προημερήσια αγορά αφορά το πλήρες χαρτοφυλάκιο ενός ΦοΣΕ, επομένως η διαδικασία προβλέψεων για κάθε φορέα εκπροσώπησης ακολουθεί τα ποιοτικά χαρακτηριστικά των συμπεριλαμβανομένων σταθμών. Αν και ορισμένες ΑΠΕ έχουν τη δυνατότητα παραγωγής ενέργειας όλο το εικοσιτετράωρο, οι Φ/Β σταθμοί προαπαιτούν την ύπαρξη ηλιακής ακτινοβολίας. Για αυτόν τον λόγο, στην παρούσα εφαρμογή το ενδιαφέρον και η αξιολόγηση επικεντρώνονται μόνο στις ώρες Φ/Β παραγωγής, χωρίς να λαμβάνονται υπόψη οι ώρες μηδενικής παραγωγής.

Πίνακας 7.3 : Ενδεικτικός τρόπος υπολογισμού χρέωσης MMBAΠ για τρία θεωρητικά ζεύγη παραγωγής – πρόβλεψης

| Ωρα | Actual (kW) | Forecasted (kW) | MAE (kW) | NMAE | Απόκλιση (MWh) | REPSUR | NCBAL_GRES (€) |
|-------|-------------|-----------------|----------|------|----------------|--------|----------------|
| 08:00 | 150 | 130 | 20 | 4% | 0,02 | 0 | 0 |
| 12:00 | 400 | 350 | 50 | 10% | 0,05 | 0,1 | 0,15 |
| 16:00 | 300 | 200 | 100 | 20% | 0,1 | 0,2 | 0,59 |

Το γεγονός αυτό, αν και προκαλεί αύξηση ορισμένων μετρητικών σφάλματος, προσδίδει καλύτερη αξιοπιστία και κατανόηση, με γνώμονα τις επιδιώξεις της παρούσας εφαρμογής. Ενδελεχής αξιολόγηση των αποτελεσμάτων του προτεινόμενου υβριδικού μοντέλου πραγματοποιείται στο Κεφάλαιο 6.

Στον Πίνακα 7.3 παρουσιάζεται η μεθοδολογία υπολογισμού των χρεώσεων MMBAΠ για τρεις ενδεικτικές προβλέψεις μίας ημέρας που ανήκει στο χρονικό διάστημα 01/05 – 30/09. Οι αριθμητικές τιμές παραγωγής (actual) και πρόβλεψης (forecasted) που απεικονίζονται είναι θεωρητικές για την κατανόηση του τρόπου υπολογισμού του μεγέθους *NCBAL_GRES* και δεν αφορούν πραγματικά ιστορικά δεδομένα. Οι υπόλοιπες τιμές είναι ρεαλιστικές και προκύπτουν από τον Πίνακα 7.2 για τον Φ/Β σταθμό της παρούσας διπλωματικής εργασίας εγκατεστημένης ισχύος 500 kW. Για κάθε ώρα συμμετοχής στην αγορά ηλεκτρικής ενέργειας υπολογίζεται το σφάλμα NMAE κάθε πρόβλεψης και η απόκλιση ενέργειας σε MWh. Στην ώρα 08:00 το υπολογιζόμενο NMAE είναι μικρότερο του *REPTOL₁* (6%), άρα δεν επιβάλλεται κανένα πρόστιμο. Την ώρα 12:00 η τιμή του NMAE ισούται με 10%, άρα βρίσκεται μεταξύ του *REPTOL₁* και του *REPTOL₂* (12%), επομένως επιβάλλεται χρέωση που υπολογίζεται από το γινόμενο της απόκλισης της ενέργειας, της σταθερής τιμής *BAL_GRES* (29,39 €/MWh) [100] και του κατάλληλου συντελεστή *REPSUR*, ο οποίος ισούται με 0,1 επειδή η απόκλιση αφορά Φ/Β σταθμό εγκατεστημένης ισχύος 0-2 MW για κάποια ενδεικτική ημέρα μεταξύ 01/05 – 30/09. Αντίστοιχα, κατά την ώρα 16:00 το σφάλμα NMAE υπολογίζεται ίσο με 20%, δηλαδή μεγαλύτερο του *REPTOL₂*, άρα η χρέωση MMBAΠ προκύπτει με πανομοιότυπο τρόπο μεταβάλλοντας μόνο τον συντελεστή *REPSUR*, ο οποίος ισούται με 0,2 όταν υπερβαίνεται το όριο *REPTOL₂*. Η εν λόγω διαδικασία επαναλαμβάνεται ωριαία για όλες τις ημέρες κάθε μήνα και στη συνέχεια οι επιβαλλόμενες χρεώσεις αθροίζονται και εξάγονται περαιτέρω χρήσιμα συμπεράσματα. Εφόσον εξετάζεται η συμμετοχή στην αγορά μόνο ενός Φ/Β σταθμού χωρίς λοιπές τεχνολογίες ΑΠΕ, επιλέγεται ο συντελεστής *REPSUR* των συγκεκριμένων μηνών.

Στον Πίνακα 7.4 απεικονίζεται ο υπολογισμός και τα μηνιαία αποτελέσματα της εφαρμογής του υβριδικού μοντέλου της παρούσας εργασίας στο ρυθμιστικό πλαίσιο του MMBAΠ. Οι χρεώσεις MMBAΠ (*NCBAL_GRES*) προκύπτουν χρησιμοποιώντας τους συντελεστές του Πίνακα 7.2 και τον τρόπο υπολογισμού του Πίνακα 7.3, βάσει της απόκλισης ενέργειας για κάθε ωριαία τιμή πραγματικής και προβλεπόμενης παραγωγής. Αδιαμφισβήτητα, το σημαντικότερο μέγεθος για κάθε ΦοΣΕ κατά τη μηνιαία διαδικασία εκκαθάρισης αφορά τη χρέωση MMBAΠ, καθώς αποτελεί το ποσό σε € το οποίο καλείται να καταβληθεί στον ΔΑΠΕΕΠ για την απόκλιση των προβλέψεων. Ωστόσο, κατά την αξιολόγηση ενός μοντέλου προβλέψεων η απόλυτη τιμή της χρέωσης δεν έχει ιδιαίτερη αξία, διότι εξαρτάται σε τεράστιο βαθμό από τη συνολική εγκατεστημένη ισχύ του εκπροσωπούμενου χαρτοφυλακίου.

Πίνακας 7.4 : Μηνιαίες χρεώσεις υβριδικού μοντέλου πρόβλεψης στο πλαίσιο του ΜΜΒΑΠ

| Μήνας | Χρέωση ΜΜΒΑΠ (€) | Παραγόμενη ενέργεια (MWh) | Προβλεπόμενη ενέργεια (MWh) | Μοναδιαία χρέωση ΜΜΒΑΠ (€/MWh) | Εκτίμηση μοναδιαίας χρέωσης ΜΜΒΑΠ (€/MWh) |
|-------------|------------------|---------------------------|-----------------------------|--------------------------------|---|
| Ιούλιος | 55,01 | 82,9 | 72,2 | 0,66 | 0,62 |
| Αύγουστος | 44,42 | 77,3 | 72,6 | 0,58 | 0,60 |
| Σεπτέμβριος | 38,18 | 73,8 | 70,2 | 0,52 | 0,75 |
| Οκτώβριος | 18,11 | 70,5 | 71,5 | 0,26 | 0,68 |
| Νοέμβριος | 33,15 | 42,2 | 55,7 | 0,79 | 0,66 |
| Δεκέμβριος | 36,53 | 29,5 | 45,2 | 1,24 | 0,51 |
| Μέσος όρος | 37,57 | 62,7 | 64,6 | 0,68 | 0,64 |

Είναι πολύ πιθανό σε κάποια περίπτωση το επιβαλλόμενο πρόστιμο να είναι μικρότερο έναντι άλλης, αλλά να αφορά πολύ μικρότερη ισχύ ΑΠΕ. Για αυτόν τον λόγο, το καθοριστικό μέγεθος για την αξιολόγηση του υβριδικού μοντέλου στην τρέχουσα εφαρμογή πρόκειται για τη μοναδιαία χρέωση ΜΜΒΑΠ, η οποία ισούται με τη συνολική χρέωση ανά παραγόμενη μονάδα ενέργειας (€/MWh). Με αυτόν τον τρόπο απαλείφεται η εγκατεστημένη ισχύς του Φ/Β σταθμού και καθίσταται εφικτό να εκτιμηθεί ακριβέστερα η απόδοση του μοντέλου. Η μοναδιαία χρέωση ΜΜΒΑΠ αντικατοπτρίζει σε μεγάλο βαθμό την απόδοση του μοντέλου, ωστόσο δεν ενδείκνυται για ασφαλή συμπεράσματα ακρίβειας των προβλέψεων. Ο τρόπος υπολογισμού, τα καθορισμένα όρια, η επικέντρωση μόνο στις ώρες παραγωγής και οι διαφοροποιημένοι ανά εποχή συντελεστές χρέωσης για Φ/Β σταθμούς αλλοιώνουν την απόλυτη ακρίβεια των προβλέψεων, ολοκληρωμένη αξιολόγηση της οποίας πραγματοποιείται στο Κεφάλαιο 6.

Η στήλη «Εκτίμηση μοναδιαίας χρέωσης ΜΜΒΑΠ» του Πίνακα 7.4 αναφέρεται στις κατά προσέγγιση εκτιμήσεις του ΔΑΠΕΕΠ για τις χρεοπιστώσεις το έτος 2022. Οι συγκεκριμένες τιμές βασίζονται στα δεδομένα του έτους 2021 και στις προβλέψεις του ΔΑΠΕΕΠ για την πορεία της εγκατεστημένης ισχύος και της ακρίβειας των προβλέψεων. Οι παρουσιαζόμενες χρεώσεις αφορούν τη μέση επίδοση του συνόλου των ΦοΣΕ ανεξαρτήτως της τεχνολογίας των έργων ΑΠΕ και του μεγέθους του εκπροσωπούμενου χαρτοφυλακίου. Ωστόσο, κατά τον υπολογισμό της μέσης μοναδιαίας χρέωσης ΜΜΒΑΠ των ΦοΣΕ υπεισέρχονται ποικίλες παράμετροι, οι οποίες πρέπει να ληφθούν υπόψη πριν τη σύγκρισή της με τη μοναδιαία χρέωση ενός μοντέλου πρόβλεψης. Καταρχάς, οι συγκεκριμένες τιμές μοναδιαίας χρέωσης έχουν προκύψει κατά εκτίμηση και όχι με πραγματικά δεδομένα της αγοράς ηλεκτρικής ενέργειας. Η μοναδιαία χρέωση *BAL_GRES* θεωρείται ίση με 25,78 €/MWh, ίση δηλαδή με αυτή του έτους 2021, ενώ υπό πραγματικές συνθήκες η συγκεκριμένη τιμή ανήλθε σε 29,39 €/MWh. Επιπλέον, η εν λόγω μελέτη έχει υλοποιηθεί για τα συνολικά χαρτοφυλάκια των ΦοΣΕ, δίχως να υπάρχει διαχωρισμός μεταξύ αιολικών, Φ/Β και λοιπών τεχνολογιών. Αυτή η παράμετρος επηρεάζει σημαντικά τις υπολογιζόμενες τιμές, καθώς τα ποιοτικά χαρακτηριστικά πρόβλεψης ενός φορέα με διαφοροποιημένο χαρτοφυλάκιο διαφέρουν συγκριτικά με κάποιον που διαθέτει μόνο Φ/Β σταθμούς.

Προς επίρρωση αυτού, στον Πίνακα 7.4 εμφανίζεται μία αυξητική της μοναδιαίας χρέωσης ΜΜΒΑΠ τους χειμερινούς μήνες για το υβριδικό μοντέλο της παρούσας διπλωματικής εργασίας το οποίο εφαρμόζεται αποκλειστικά σε έναν Φ/Β σταθμό, σε αντίθεση με τον μέσο όρο των ΦοΣΕ. Το φαινόμενο αυτό πιθανώς να οφείλεται στην αυξημένη εποχική

και μετεωρολογική περιοδικότητα ενός Φ/Β σταθμού σε σχέση με ένα αιολικό πάρκο, το οποίο διαθέτει δυνατότητα παραγωγής για όλη τη διάρκεια της ημέρας και εξαρτάται από διαφορετικές μετεωρολογικές μεταβλητές.

Εκτός των άλλων, οι εκτιμήσεις του ΔΑΠΕΕΠ αφορούν το σύνολο της προημερήσιας αγοράς ηλεκτρικής ενέργειας στην οποία συμμετέχουν ΦοΣΕ με χαρτοφυλάκια εκατοντάδων MW. Όπως φαίνεται και στον Πίνακα 7.3, καθοριστική παράμετρος για το επιβαλλόμενο πρόστιμο είναι το σφάλμα NMAE, το οποίο όμως εξαρτάται από τη συνολική εκπροσωπούμενη εγκατεστημένη ισχύ. Είναι λογικό, πως όσο αυξάνεται η εγκατεστημένη ισχύς τόσο μειώνεται το NMAE, ακόμη και αν η απόλυτη απόκλιση είναι μεγαλύτερη. Επομένως, εφόσον η εφαρμογή της παρούσας εργασίας αφορά μόνο έναν Φ/Β σταθμό εγκατεστημένης ισχύος 500 kW είναι αναμενόμενο η μοναδιαία χρέωση MMBAΠ να λαμβάνει μεγαλύτερες τιμές. Ωστόσο, η σημαντικά μεγαλύτερη εγκατεστημένη ισχύς δεν συνεπάγεται μόνο μείωση του υπολογιζόμενου NMAE, αλλά και μεγαλύτερη ακρίβεια των προβλέψεων παραγωγής, καθώς η διαδικασία προβλέψεων ευνοείται όταν οι πηγές παραγωγής είναι διεσπαρμένες γεωγραφικά. Στην Ενότητα 6.4 κατέστη σαφές πως τα δυναμικά μετεωρολογικά φαινόμενα δυσχεραίνουν το έργο και την ακρίβεια του υβριδικού μοντέλου, διότι είναι δυσκολότερο να ανταποκριθεί σε απρόσμενες καιρικές μεταβολές. Στον αντίποδα, όταν οι υποβαλλόμενες στο ΧΕ προβλέψεις αφορούν πολυάριθμους Φ/Β σταθμούς και αιολικά πάρκα σε διαφορετικές γεωγραφικές τοποθεσίες, η συνολική πρόβλεψη αποκτά μεγαλύτερη «αδράνεια» και καθίσταται λιγότερο ευάλωτη σε ραγδαία μεταβαλλόμενα καιρικά φαινόμενα. Υπό αυτό το καθεστώς, είναι πιθανό λόγω χάρη κάποιες απρόσμενες νεφώσεις σε κάποιον Φ/Β σταθμό να μην οδηγήσουν σε μείωση της συνολικής ακρίβειας, επειδή θα εξουδετερωθούν από κάποια άλλη μη αναμενόμενη αύξηση της ηλιακής ακτινοβολίας σε κάποιον άλλο σταθμό, αξιοποιώντας έτσι τη γεωγραφική διασπορά. Επομένως, λαμβάνοντας υπόψη τα παραπάνω και το γεγονός πως ένας μεμονωμένος Φ/Β σταθμός είναι περισσότερο ευάλωτος σε μετεωρολογικές διακυμάνσεις, εξάγεται το συμπέρασμα πως η ακρίβεια του υβριδικού μοντέλου της παρούσας εργασίας είναι παραπάνω από ικανοποιητική.

Σε αυτό το σημείο, αξίζει να αναφερθεί πως οι εκτιμήσεις μοναδιαίας χρέωσης MMBAΠ του Πίνακα 7.4 αφορούν παραγόμενες ωριαίες προβλέψεις για την προημερήσια αγορά ηλεκτρικής ενέργειας, δηλαδή έχουν υποβληθεί από την προηγούμενη ημέρα. Ωστόσο, το υβριδικό μοντέλο της παρούσας εργασίας χρησιμοποιείται για πρόβλεψη Φ/Β παραγωγής σε χρονικό ορίζοντα μίας ώρας και όχι μίας ημέρας. Ο συγκεκριμένος παράγοντας αναμφίβολα επηρεάζει την ακρίβεια των προβλέψεων, η οποία θεωρητικά αναμένεται να βελτιώνεται όσο ο χρονικός ορίζοντας πρόβλεψης μειώνεται. Με αυτόν τον τρόπο, αντισταθμίζονται σε κάποιον βαθμό τα ανωτέρω μειονεκτήματα που φέρει η εφαρμογή του ρυθμιστικού πλαισίου του MMBAΠ σε μόλις έναν Φ/Β σταθμό. Αν και δεν είναι απόλυτα βέβαιο, είναι πιθανό η ακρίβεια πρόβλεψης – άρα και η μοναδιαία χρέωση – των ΦοΣΕ να παρουσιάζει βελτίωση εφόσον η υποβολή τους λαμβάνει χώρα μία ώρα και όχι μία ημέρα πριν τη στιγμή παράδοσης των ενεργειακών προϊόντων. Επομένως, για όλους τους προαναφερθέντες λόγους στην παρούσα διπλωματική εργασία δεν επιχειρείται απευθείας σύγκριση της απόδοσης του κατασκευασμένου υβριδικού μοντέλου σε όρους μοναδιαίας χρέωσης MMBAΠ (0,68 €/MWh) με την απόδοση του μέσου όρου των ΦοΣΕ (0,64 €/MWh), αλλά ο συγκεκριμένος μέσος όρος χρησιμοποιείται ως γενικός δείκτης απόδοσης, ώστε να τονιστεί η σημασία της διαφορετικότητας των παρεμβαλλόμενων παραγόντων.

Πίνακας 7.5 : Μετρήσεις σφάλματος μηνιαίας απόδοσης υβριδικού μοντέλου

| Μήνας | NMAE | Προβλέψεις με NMAE < 6% | Προβλέψεις με < NMAE < 12% | Προβλέψεις με NMAE > 12% |
|-------------|--------------|-------------------------|----------------------------|--------------------------|
| Ιούλιος | 5,01% | 57% | 24% | 19% |
| Αύγουστος | 4,70% | 59% | 27% | 14% |
| Σεπτέμβριος | 4,38% | 62% | 24% | 14% |
| Οκτώβριος | 4,49% | 61% | 26% | 13% |
| Νοέμβριος | 6,65% | 39% | 30% | 31% |
| Δεκέμβριος | 7,53% | 34% | 30% | 36% |
| Μέσος όρος | 5,46% | 52% | 27% | 21% |

Προκειμένου η ακρίβεια του υβριδικού μοντέλου να αξιολογηθεί διεξοδικά, στον Πίνακα 7.5 παρουσιάζονται η μηνιαία επίδοση NMAE, καθώς και το ποσοστό των προβλέψεων που βρίσκονται εντός ή εκτός των καθορισμένων ορίων. Η συγκεκριμένη διαδικασία υλοποιείται διότι ο τρόπος υπολογισμού των χρεώσεων MMBAΠ δεν αντανακλούν πλήρως τα ποιοτικά χαρακτηριστικά της Φ/Β πρόβλεψης, επομένως απαιτείται να εξεταστεί η αποτελεσματικότητά του μοντέλου εκτενέστερα.

Τα σφάλματα NMAE του Πίνακα 7.5 αφορούν, όπως και όλα τα υπόλοιπα αποτελέσματα του παρόντος Κεφαλαίου 7, μόνο τις ώρες Φ/Β παραγωγής και όχι όλη τη διάρκεια της ημέρας. Για αυτόν τον λόγο, τα υπολογιζόμενα σφάλματα αυξάνονται, καθώς δεν λαμβάνονται υπόψη οι ώρες μηδενικής παραγωγής και πρόβλεψης, φαινόμενο που αναφέρεται και στην Ενότητα 6.2. Είναι σαφές πως η χειρότερη επίδοση NMAE καταγράφεται τους μήνες Νοέμβριο (6,65%) και Δεκέμβριο (7,53%), οι οποίοι είναι και οι μοναδικοί με NMAE άνω του μέσου όρου (5,46%). Η συγκεκριμένη παρατήρηση πιθανόν να οφείλεται στον αυξημένο αριθμό δυναμικών και συννεφιασμένων ημερών τους δύο αυτούς μήνες, όπως εμφανίζεται και στον Πίνακα 6.8. Συνολικά, το αυξημένο σφάλμα πρόβλεψης τους μήνες Νοέμβριο και Δεκέμβριο, καθώς επίσης και η σημαντικά μειωμένη παραγωγή ενέργειας συγκριτικά με τους υπόλοιπους μήνες, οδηγούν στην αυξημένη μοναδιαία χρέωση MMBAΠ, παρά το ότι οι χρεώσεις είναι μικρές κατά απόλυτη τιμή.

7.5 ΕΝΣΩΜΑΤΩΣΗ 2^{ΟΥ} ΦΩΤΟΒΟΛΤΑΪΚΟΥ ΣΤΑΘΜΟΥ

Η συνολική εγκατεστημένη ισχύς και η γεωγραφική διασπορά ενός χαρτοφυλακίου ΑΠΕ, επηρεάζουν σημαντικά την ακρίβεια των προβλέψεων και τις επιβαλλόμενες χρεώσεις στο πλαίσιο του MMBAΠ, όπως αναφέρεται και στην Ενότητα 7.4. Αυτό οφείλεται στο γεγονός ότι οι ΦοΣΕ υποβάλλουν τις προβλέψεις τους για το σύνολο των εκπροσωπούμενων μονάδων τους, επομένως είναι λιγότερο ευάλωτοι σε δυναμικά μετεωρολογικά φαινόμενα χωρίς να επηρεάζονται σημαντικά από ενδεχόμενη μειωμένη ακρίβεια πρόβλεψης ενός σταθμού. Αντίθετα, οι προβλέψεις της παρούσας διπλωματικής εργασίας αφορούν έναν μεμονωμένο Φ/Β σταθμό, παράγοντας που εξηγεί μερικώς την ελάχιστα υψηλότερη μοναδιαία χρέωση MMBAΠ συγκριτικά με τη μέση επίδοση της αγοράς.

Σε αυτή την κατεύθυνση, προκειμένου να μελετηθεί η επίδραση της γεωγραφικής διασποράς στην ακρίβεια των προβλέψεων, η διαδικασία της Ενότητας 7.4 επαναλαμβάνεται για έναν δεύτερο Φ/Β σταθμό εγκατεστημένης ισχύος 1000 kW στην περιοχή της Καστοριάς,

συνθέτοντας έτσι ένα συνολικό χαρτοφυλάκιο 1500 kW αποτελούμενο από δύο Φ/Β σταθμούς. Για να καταστεί εφικτή η συγκεκριμένη εφαρμογή, ακολουθείται η ίδια μεθοδολογία εκπαίδευσης και αξιολόγησης του υβριδικού μοντέλου, το οποίο τροφοδοτείται ομοίως με τα αντίστοιχα ιστορικά δεδομένα για το έτος 2022 και την αριθμητική αναπαράσταση της ώρας. Η δομή του μοντέλου πρόβλεψης για τον δεύτερο Φ/Β σταθμό είναι πανομοιότυπη με αυτή που περιγράφεται στο Κεφάλαιο 5, χρησιμοποιώντας ίδιες τεχνικές επεξεργασίας δεδομένων, και ίδιο διαχωρισμό σε σύνολο εκπαίδευσης και αξιολόγησης. Μοναδική διαφοροποίηση αποτελούν οι υπέρ-παράμετροι προς βελτιστοποίηση με χρήση επαναληπτικού βρόχου, οι οποίες βελτιστοποιήθηκαν με την ίδια διαδικασία. Οι συγκεκριμένες μεταβλητές επηρεάζουν σημαντικά την απόδοση του υβριδικού μοντέλου και επομένως, για λόγους αξιοπιστίας, βελτιστοποιούνται εκ νέου για τη δημιουργία των προβλέψεων παραγωγής του νέου Φ/Β σταθμού. Τα αποτελέσματα της βελτιστοποίησης των υπέρ-παραμέτρων του μοντέλου και η απόδοσή του στην περίπτωση του δεύτερου υπό εξέταση Φ/Β σταθμού παρουσιάζονται στους Πίνακες 7.6 και 7.7, αντίστοιχα.

Από τον Πίνακα 7.7 φαίνεται πως το υβριδικό μοντέλο παρουσιάζει μεγαλύτερα σφάλματα σε ότι αφορά τους δείκτες RMSE και MAE για τον Φ/Β σταθμό στην Καστοριά (δεύτερος υπό εξέταση Φ/Β σταθμός), σε σύγκριση με τα αντίστοιχα σφάλματα για τον Φ/Β σταθμό στην Ροδόπη. Ωστόσο, ο δείκτης σφάλματος NMAE είναι ελαφρά βελτιωμένος στην περίπτωση του δεύτερου Φ/Β σταθμού (3,97%) σε σχέση με αυτόν του πρώτου (4,30%). Επομένως, εξάγεται το συμπέρασμα πως η απόδοση του μοντέλου δεν διαφέρει σημαντικά στις δύο περιπτώσεις σε ότι αφορά τον καθοριστικό δείκτη σφάλματος NMAE, ενώ τα αυξημένα σφάλματα RMSE και MAE οφείλονται στη μεγαλύτερη εγκατεστημένη ισχύ άρα και στη μεγαλύτερη στιγμιαία παραγωγή του δεύτερου Φ/Β σταθμού (1000 kW έναντι 500 kW).

Πίνακας 7.6 : Αποτελέσματα βελτιστοποίησης παραμέτρων υβριδικού μοντέλου με χρήση επαναληπτικού βρόχου για την περίπτωση του δεύτερου υπό εξέταση Φ/Β σταθμού

| Παράμετρος | Εύρος τιμών | Βήμα | Βέλτιστη τιμή |
|---------------------|--|------|---------------|
| epochs | [10, 300] | 10 | 100 |
| units | [10, 100] | 10 | 70 |
| activation function | [sigmoid, tanh, softmax, relu, leaky relu] | - | relu |
| batch size | [16, 2048] | 16 | 32 |
| w_1 | [0,1, 1] | 0,1 | 0,1 |
| w_2 | [0,1, 1] | 0,1 | 0,1 |
| w_3 | [0,1, 1] | 0,1 | 0,1 |
| w_4 | [0,1, 1] | 0,1 | 0,7 |

Πίνακας 7.7 : Απόδοση υβριδικού μοντέλου για την περίπτωση του πρώτου και του δεύτερου υπό εξέταση Φ/Β σταθμού

| Φ/Β σταθμός | RMSE (kW) | MAE (kW) | NMAE |
|-------------|-----------|----------|--------------|
| 1 | 42,97 | 21,51 | 4,30% |
| 2 | 88,08 | 39,67 | 3,97% |

7.6 ΥΠΟΛΟΓΙΣΜΟΣ ΜΗΝΙΑΙΑΣ ΑΠΟΔΟΣΗΣ ΧΑΡΤΟΦΥΛΑΚΙΟΥ

Η μεθοδολογία για τον υπολογισμό της μηνιαίας απόδοσης των προβλέψεων του συνολικού χαρτοφυλακίου είναι πανομοιότυπη με αυτή που περιγράφεται στην Ενότητα 7.4. Αρχικά, όπως και στην περίπτωση του πρώτου σταθμού, οι παραγόμενες προβλέψεις μετατρέπονται από τεταρτιαίες σε ωριαίες, ώστε να είναι εφικτή η εφαρμογή τους στο ρυθμιστικό πλαίσιο του ΜΜΒΑΠ, το οποίο απαιτεί ωριαίες προβλέψεις. Στη συνέχεια, οι προβλέψεις των δύο Φ/Β σταθμών αντιστοιχίζονται ανά χρονική στιγμή, ώστε να αφορούν την ίδια ώρα της ίδιας ημέρας, χωρίς να υπάρχει κάποια χρονική υστέρηση ή προπόρευση. Τέλος, αθροίζονται τόσο η πραγματική όσο και η προβλεπόμενη παραγωγή κάθε σταθμού, με αποτέλεσμα να δημιουργείται η μετρούμενη ενέργεια M_Q και η υποβαλλόμενη στο ΧΕ ενέργεια M_S την ίδια χρονική στιγμή σε επίπεδο συνολικού χαρτοφυλακίου. Οι δύο Φ/Β σταθμοί φέρουν άθροισμα εγκατεστημένης ισχύος 1,5 MW, άρα εμπίπτουν στην ίδια κατηγορία 0-2 MW του Πίνακα 7.1 αναφορικά με τους συντελεστές *SUR_GRES*. Επομένως, οι χρησιμοποιούμενοι συντελεστές και τα καθορισμένα όρια για το χαρτοφυλάκιο των δύο Φ/Β σταθμών είναι ίδια με αυτά του Πίνακα 7.2.

Στον Πίνακα 7.8 παρουσιάζεται ο υπολογισμός και τα μηνιαία αποτελέσματα της εφαρμογής του υβριδικού μοντέλου της παρούσας εργασίας στο ρυθμιστικό πλαίσιο του ΜΜΒΑΠ για τους δύο Φ/Β σταθμούς σε Ροδόπη και Καστοριά συνολικής εγκατεστημένης ισχύος 1500 kW. Είναι εμφανές, πως αν και τα συνολικά πρόστιμα είναι υψηλότερα εξαιτίας της αυξημένης εκπροσωπούμενης ενέργειας, η μοναδιαία χρέωση ΜΜΒΑΠ είναι αρκετά μικρότερη. Το φαινόμενο αυτό αναδεικνύει την αποδοτικότητα του κατασκευασμένου υβριδικού μοντέλου, καθώς η χρήση του συνεπάγεται μικρότερη μέση χρέωση ανά παραγόμενη MWh (0,43 €/MWh) σε σύγκριση με τον μέσο όρο των ΦοΣΕ (0,64 €/MWh). Επομένως, γίνεται αντιληπτό πως η προσθήκη ενός δεύτερου Φ/Β σταθμού στη συγκεκριμένη εφαρμογή έχει ως αποτέλεσμα τη βελτιωμένη ακρίβεια συνολικής πρόβλεψης και μείωση των μοναδιαίων επιβαλλόμενων προστίμων. Το γεγονός πως οι δύο Φ/Β σταθμοί είναι εγκατεστημένοι σε διαφορετικές γεωγραφικές περιοχές και επομένως λειτουργούν υπό διαφορετικές μετεωρολογικές συνθήκες, ευνοεί το υβριδικό μοντέλο και μειώνει την επίδραση που έχουν τα δυναμικά φαινόμενα στην ακρίβεια των προβλέψεων.

Συνολικά, επισημαίνεται ξανά πως η εκτίμηση της μοναδιαίας χρέωσης ΜΜΒΑΠ από τον ΔΑΠΕΕΠ έχει προκύψει υπό διαφορετικές συνθήκες, με χαμηλότερη τιμή *BAL_GRES* και για ΦοΣΕ με μικτές τεχνολογίες εκπροσωπούμενων έργων εγκατεστημένης ισχύος πολλών εκατοντάδων MW. Επιπλέον, το γεγονός πως αφορούν προβλέψεις που έχουν υποβληθεί την προηγούμενη ημέρα και όχι την προηγούμενη ώρα, δυσχεραίνουν την αξιολόγηση κάθε μεθόδου πρόβλεψης. Ωστόσο, στο πλαίσιο της παρούσας διπλωματικής εργασίας η εκτίμηση μοναδιαίας χρέωσης χρησιμοποιείται ως γενικός δείκτης επίδοσης ώστε να αξιολογηθεί η απόδοση του υβριδικού μοντέλου και όχι για να εξαχθούν συμπεράσματα οικονομικής φύσης.

Πίνακας 7.8 : Μηνιαίες χρεώσεις υβριδικού μοντέλου πρόβλεψης σε επίπεδο συνολικού χαρτοφυλακίου

| Μήνας | Χρέωση ΜΜΒΑΠ (€) | Παραγόμενη ενέργεια (MWh) | Προβλεπόμενη ενέργεια (MWh) | Μοναδιαία χρέωση ΜΜΒΑΠ (€/MWh) | Εκτίμηση μοναδιαίας χρέωσης ΜΜΒΑΠ (€/MWh) |
|-------------|------------------|---------------------------|-----------------------------|--------------------------------|---|
| Ιούλιος | 115,31 | 248,1 | 234,8 | 0,47 | 0,62 |
| Αύγουστος | 123,90 | 225,6 | 233,3 | 0,55 | 0,60 |
| Σεπτέμβριος | 90,16 | 217,1 | 220,3 | 0,42 | 0,75 |
| Οκτώβριος | 38,63 | 207,1 | 212,4 | 0,19 | 0,68 |
| Νοέμβριος | 58,46 | 115,4 | 143,7 | 0,51 | 0,66 |
| Δεκέμβριος | 40,09 | 88,1 | 113,3 | 0,46 | 0,51 |
| Μέσος όρος | 77,76 | 183,6 | 200,0 | 0,43 | 0,64 |

Πίνακας 7.9 : Μετρήσεις σφάλματος μηνιαίας απόδοσης υβριδικού μοντέλου σε επίπεδο συνολικού χαρτοφυλακίου

| Μήνας | NMAE | Προβλέψεις με NMAE < 6% | Προβλέψεις με < NMAE < 12% | Προβλέψεις με NMAE > 12% |
|-------------|--------------|-------------------------|----------------------------|--------------------------|
| Ιούλιος | 4,11% | 64% | 26% | 10% |
| Αύγουστος | 4,48% | 61% | 28% | 11% |
| Σεπτέμβριος | 3,82% | 66% | 24% | 10% |
| Οκτώβριος | 3,78% | 68% | 23% | 9% |
| Νοέμβριος | 4,84% | 54% | 30% | 16% |
| Δεκέμβριος | 4,41% | 59% | 32% | 9% |
| Μέσος όρος | 4,24% | 62% | 27% | 11% |

Συγκρίνοντας τους Πίνακες 7.9 και 7.5, εξάγεται το συμπέρασμα πως στην περίπτωση του συνολικού χαρτοφυλακίου των δύο Φ/Β σταθμών, η υπολογιζόμενη ακρίβεια του προτεινόμενου υβριδικού μοντέλου είναι βελτιωμένη όχι μόνο αναφορικά με τη μέση μοναδιαία χρέωση MMBAΠ (0,43 €/MWh έναντι 0,68 €/MWh), αλλά και βάσει του μέσου όρου του μετρητικού σφάλματος NMAE (4,24% έναντι 5,46%). Επομένως, λόγω της επίδρασης συσσώρευσης, όπως αναλύθηκε στην Ενότητα 7.3, οι παραγόμενες προβλέψεις σε επίπεδο συνολικού χαρτοφυλακίου παρουσιάζουν ουσιαστική αυξημένη ακρίβεια, καθώς το υβριδικό μοντέλο αξιοποιεί την παράμετρο της χωρικής διασποράς. Τέλος, αν και το ποσοστό των προβλέψεων με NMAE μεταξύ των $REPTOL_1$ και $REPTOL_2$ είναι ίδιο (27%) και στις δύο περιπτώσεις, στην περίπτωση του συνολικού χαρτοφυλακίου των δύο Φ/Β σταθμών αυξάνεται σημαντικά ο αριθμός των προβλέψεων οι οποίες δεν επισύρουν καμία χρέωση (62% έναντι 52%), παράμετρος που αποτελεί την απόλυτη επιδίωξη κάθε χρησιμοποιούμενου μοντέλου πρόβλεψης στο πλαίσιο της αγοράς ηλεκτρικής ενέργειας.

7.7 ΝΕΟ ΡΥΘΜΙΣΤΙΚΟ ΠΛΑΙΣΙΟ – ΣΥΝΕΧΗΣ ΕΝΔΟΗΜΕΡΗΣΙΑ ΑΓΟΡΑ

Βάσει της απόφασης της ΡΑΕ με αριθμό 862/2022 [101], ορίζεται η έναρξη της συζευγμένης λειτουργίας της ενδοημερήσιας αγοράς μέσω της συνεχούς ενδοημερήσιας συναλλαγής (European Cross-Border Intra-Day / XBID) στις 29 Νοεμβρίου 2022. Η XBID είναι ένα εργαλείο αγοραπωλησίας ενεργειακών προϊόντων, με σκοπό τη διευκόλυνση των αναγκών προγραμματισμού των συμμετεχόντων στην αγορά, τη μεγιστοποίηση της αξίας και την ενσωμάτωση των ανανεώσιμων πηγών ενέργειας στην εσωτερική αγορά ενέργειας της ΕΕ. Η λειτουργία της XBID έρχεται να επεκτείνει την ενδοημερήσια αγορά, την αγορά επόμενης ημέρας και τις τρεις συμπληρωματικές περιφερειακές ενδοημερήσιες δημοπρασίες (Complementary Regional Intraday Auctions / CRIDAs).

Το παρόν ρυθμιστικό πλαίσιο επιτρέπει στους συμμετέχοντες στην αγορά ηλεκτρικής ενέργειας με χαρτοφυλάκια ΑΠΕ να προσαρμόζουν τη θέση τους, δηλαδή να υποβάλουν βελτιωμένες επικαιροποιημένες προβλέψεις, σε συνεχή βάση και να διαχειρίζονται τις ευθύνες εξισορρόπησης που αναλαμβάνουν. Οι συγκεκριμένες συναλλαγές αγοραπωλησίας ενέργειας πραγματοποιούνται σε ωριαίο επίπεδο και επί εικοσιτετράωρου βάσης. Ωστόσο, οι προαναφερθείσες συναλλαγές πραγματοποιούνται λαμβάνοντας υπόψη και κριτήρια αγοράς του ΧΕ, καθώς έχουν ως απώτερο στόχο τη μεγιστοποίηση του κέρδους του εκάστοτε συμμετέχοντα και όχι αποκλειστικά τη μείωση των αποκλίσεων από την πραγματική παραγωγή. Επομένως, γίνεται αντιληπτό πως η εφαρμογή του προτεινόμενου υβριδικού μοντέλου στο τρέχον ρυθμιστικό πλαίσιο δεν συμπεριλαμβάνεται στις επιδιώξεις της παρούσας

διπλωματικής εργασίας, καθώς δεν είναι εφικτό να εξαχθούν αξιόλογα συμπεράσματα αποκλειστικά για την ακρίβεια των παραγόμενων προβλέψεων, αλλά υπεισέρχονται και οικονομικά μεγέθη τα οποία δεν εντάσσονται στους άμεσους σκοπούς του υβριδικού μοντέλου.

Σε αντιπαράβολή με το κανονιστικό πλαίσιο του ΜΜΒΑΠ, ο οποίος αποτελούσε μέχρι πρότινος τον βασικό μηχανισμό εκκαθάρισης αποκλίσεων, ο υπολογισμός των χρεώσεων ή πιστώσεων $IMBC_{e,t}$ από την εκκαθάριση αποκλίσεων μίας οντότητας υπηρεσίας εξισορρόπησης e για μια περίοδο εκκαθάρισης t γίνεται όπως ακολούθως:

$$IMBC_{e,t} = IP_t \cdot (MQ_{e,t} - MS_{e,t}) \quad (7.4)$$

όπου IP_t η τιμή αποκλίσεων και $MQ_{e,t}$, $MS_{e,t}$ η μετρούμενη και η προβλεπόμενη ενέργεια την περίοδο εκκαθάρισης t . Μέσω της εξίσωσης (7.4) αναδεικνύεται πως δεν εισάγεται κάποιος αυστηρός μηχανισμός ακρίβειας πρόβλεψης ούτε προκαθορισμένα όρια ανοχής στο παρόν ρυθμιστικό πλαίσιο, καθώς και η τιμή αποκλίσεων δεν μπορεί να προβλεφθεί κατά την διάρκεια της ημέρας που λαμβάνουν χώρα οι όποιες συναλλαγές, αλλά προκύπτει εκ των υστέρων από τον ΔΑΠΕΕΠ. Σε κάθε περίπτωση, όμως, τονίζεται η σημασία για παραγωγή αξιόπιστων και επικαιροποιημένων προβλέψεων, καθώς αυτές με τη σειρά τους οδηγούν σε μικρότερες αποκλίσεις, άρα και μικρότερες πιθανές χρεώσεις, δεδομένου ότι η τιμή αποκλίσεων δεν μπορεί να προβλεφθεί κατά τη διάρκεια της ημέρας που λαμβάνουν χώρα οι παρεμβαλλόμενες συναλλαγές. Συνολικά, αν και το υφιστάμενο κανονιστικό πλαίσιο δεν εξυπηρετεί την αξιολόγηση της απόδοσης των παραγόμενων προβλέψεων, επισημαίνεται η αυξανόμενη πρακτική αξία και εφαρμογή των βραχυπρόθεσμων μοντέλων πρόβλεψης, όπως αυτό που προτείνεται στην παρούσα διπλωματική εργασία [102].

ΣΥΜΠΕΡΑΣΜΑΤΑ

8.1 ΣΥΝΟΨΗ ΜΟΝΤΕΛΩΝ ΚΑΙ ΜΕΘΟΔΟΛΟΓΙΩΝ

Στην παρούσα διπλωματική εργασία, γίνεται αντιληπτή η καθοριστική σημασία της πρόβλεψης Φ/Β παραγωγής για μία σειρά παραμέτρων που αφορούν την εύρυθμη λειτουργία της αγοράς ηλεκτρικής ενέργειας. Συγκεκριμένα, το ενδιαφέρον εστιάζεται στη βραχυπρόθεσμη πρόβλεψη, την πιο κρίσιμη κατηγορία πρόβλεψης, η οποία λαμβάνει όλο και μεγαλύτερη αξία τα τελευταία χρόνια. Βασική συνεισφορά της παρούσας εργασίας αποτελεί η ανάπτυξη υβριδικού μοντέλου βαθιάς μάθησης, το οποίο εκπαιδεύεται με πραγματικά ιστορικά δεδομένα και μετεωρολογικές μεταβλητές, και μέσω σύνθετων τεχνικών επεξεργασίας επιχειρεί την πρόβλεψη της Φ/Β παραγωγής σε χρονικό ορίζοντα μίας ώρας. Κεντρική μονάδα επεξεργασίας του εν λόγω μοντέλου αποτελεί το LSTM δίκτυο, ένα αναδρομικό νευρωνικό δίκτυο γνωστό για την ικανότητα αναγνώρισης μακροχρόνιων χρονικών συσχετίσεων στις χρονοσειρές των δεδομένων. Στη χρονοσειρά ισχύος του υβριδικού μοντέλου εφαρμόζεται η τεχνική αποσύνθεσης πακέτου κυματιδίων, ούτως ώστε η αρχική χρονοσειρά να διαχωριστεί σε τέσσερις συνιστώσες διαφορετικής συχνότητας. Με αυτόν τον τρόπο αξιοποιούνται σε μεγαλύτερο βαθμό οι συνιστώσες χαμηλής συχνότητας που περιγράφουν την πραγματική τάση της χρονοσειράς και μειώνεται η επίδραση του θορύβου. Οι αποσυντιθέμενες συνιστώσες εισάγονται ως είσοδοι σε τέσσερα επιμέρους LSTM δίκτυα τριών κρυφών στρωμάτων, η έξοδος των οποίων παράγει την τελική πρόβλεψη μέσω γραμμικού συνδυασμού.

Για την ολοκληρωμένη και αμερόληπτη αξιολόγηση των προβλέψεων του προτεινόμενου υβριδικού μοντέλου, κατασκευάζονται και αξιολογούνται μία σειρά από απλούστερα μοντέλα πρόβλεψης. Η σύγκριση της απόδοσης όλων των μοντέλων γίνεται στη βάση τριών διαφορετικών μετρητικών σφάλματος, ώστε οι προβλέψεις να αξιολογηθούν από πολλαπλές οπτικές γωνίες και να εξασφαλιστεί η ανωτερότητα του προτεινόμενου υβριδικού μοντέλου. Τέλος, πέραν της εποχικής και μετεωρολογικής ανάλυσης των αποτελεσμάτων, το προτεινόμενο υβριδικό μοντέλο αξιολογείται βάσει της εφαρμογής του σε ένα πραγματικό πρόβλημα στο πλαίσιο του ΜΜΒΑΠ, καθώς εξετάζεται η συμμετοχή του στην προημερήσια αγορά ηλεκτρικής ενέργειας. Το γεγονός πως εκπαιδεύεται με πραγματικά ιστορικά δεδομένα και υπό ρεαλιστικές συνθήκες χωρίς παραδοχές εξιδανίκευσης, προσδίδει αυξημένη σημασία στη συγκεκριμένη εφαρμογή του υβριδικού μοντέλου, καθώς ανταγωνίζεται με μοντέλα πρόβλεψης πραγματικών φορέων εκπροσώπησης έργων ΑΠΕ.

8.2 ΣΥΝΟΛΙΚΑ ΣΥΜΠΕΡΑΣΜΑΤΑ

Το προτεινόμενο υβριδικό μοντέλο εμφανίζει υψηλότερη ακρίβεια πρόβλεψης σε σύγκριση με όλα τα υπόλοιπα αξιολογούμενα μοντέλα (persistence, 1 Layer LSTM, 3 Layers

LSTM, μη-βελτιωμένο υβριδικό), τόσο βάσει του βασικού μετρητικού NMAE, όσο και όλων των υπολογιζόμενων μετρητικών σφαλμάτων (RMSE, MAE). Λαμβάνοντας υπόψη τις επιδιώξεις και τα ποιοτικά χαρακτηριστικά των παρεμβαλλόμενων μεγεθών της παρούσας διπλωματικής εργασίας, ως βασικό κριτήριο αξιολόγησης θεωρείται το μετρητικό NMAE, το οποίο κανονικοποιεί τα απόλυτα σφάλματα με βάση την εγκατεστημένη ισχύ του Φ/Β σταθμού και αποτελεί την πλέον ενδεδειγμένη επιλογή. Συνολικά, ο συνδυασμός της μεθόδου αποσύνθεσης, των τεσσάρων διακριτών LSTM δικτύων, του γραμμικού συνδυασμού αλλά και της προσθήκης της αριθμητικής αναπαράστασης της ώρας ως χρονοσειρά εισόδου, ευνοεί το υβριδικό μοντέλο στην επιτυχή συσχέτιση των μετεωρολογικών δεδομένων με την παραγόμενη πρόβλεψη Φ/Β παραγωγής, με αποτέλεσμα να υπερκεράζει σε απόδοση τα υπόλοιπα εξεταζόμενα μοντέλα πρόβλεψης, χωρίς σημαντική αύξηση στον απαιτούμενο χρόνο εκπαίδευσης.

Ένας Φ/Β σταθμός κατά τη λειτουργία του σε όλη τη διάρκεια του έτους συναντά πληθώρα διαφορετικών εξωγενών συνθηκών, οι οποίες επηρεάζουν την απόδοσή του, και κατά συνέπεια, την ακρίβεια της πρόβλεψης. Μέσω της εποχικής ανάλυσης της παρούσας εργασίας, αναδεικνύεται πως το υβριδικό μοντέλο αποδίδει καλύτερα τους φθινοπωρινούς μήνες και χειρότερα τον χειμερινό σε σύγκριση με τον ετήσιο μέσο όρο του, ενώ η απόδοσή του το καλοκαίρι δεν εμφανίζει σημαντική απόκλιση σε σχέση με την ετήσια αντίστοιχη τιμή. Το φαινόμενο αυτό οφείλεται κυρίως στο εύκρατο κλίμα της Ελλάδας, αλλά και στον τρόπο υπολογισμού του μετρητικού NMAE. Μία ακόμη σημαντική συνεισφορά της εποχικής ανάλυσης, αφορά τη διαπίστωση πως η προσπίπτουσα ηλιακή ακτινοβολία δεν ακολουθεί κάποια αξιοσημείωτη εποχική αυξομείωση, δηλαδή δεν είναι αξιολογικά μειωμένη τους χειμερινούς μήνες και αντίστοιχα αυξημένη τους καλοκαιρινούς. Αντίθετα, η διαφοροποίηση της Φ/Β παραγωγής ανά εποχή είναι κυρίως αποτέλεσμα της διαφορετικής χρονικής διάρκειας της ημέρας, παράμετρος που δυσχεραίνει το έργο του μοντέλου πρόβλεψης, και αναδεικνύει την ανάγκη για ξεχωριστή εκπαίδευση ανά εποχή ή και μήνα.

Προκειμένου το βελτιωμένο υβριδικό μοντέλο να αξιολογηθεί απόλυτα υπό όλες τις δυνατές συνθήκες λειτουργίας του Φ/Β σταθμού, υλοποιείται πλήρης μετεωρολογική ανάλυση με χειροκίνητο διαχωρισμό κάθε ημέρας βάσει των επικρατουσών μετεωρολογικών συνθηκών. Μέσω της συγκεκριμένης κατηγοριοποίησης, καθίσταται εμφανές πως οι ημέρες με δυναμικές και μεταβαλλόμενες συνθήκες αποτελούν τη δυσκολότερη συνθήκη για το υβριδικό μοντέλο, καθώς καλείται να προσαρμοστεί σε απρόσμενα καιρικά φαινόμενα, τα οποία δεν ακολουθούν κάποιο μοτίβο συσχέτισης. Αντίθετα, κατά τις ηλιόλουστες ημέρες παρατηρούνται οι ιδανικότερες συνθήκες πρόβλεψης, διότι η ηλιακή ακτινοβολία ακολουθεί αναμενόμενη πορεία χωρίς ανεπιθύμητες αυξομειώσεις και, επομένως, εμφανίζεται η βέλτιστη ακρίβεια πρόβλεψης. Κατά τις ημέρες με επίμονες νεφώσεις, ο τρόπος υπολογισμού του μετρητικού NMAE και οι πολύ μικρές τιμές παραγωγής οδηγούν σε μία ακρίβεια πρόβλεψης καλύτερη του συνολικού μέσου όρου. Συνολικά, το προτεινόμενο υβριδικό μοντέλο εμφανίζει καλύτερη απόδοση και στις δυναμικές ημέρες συγκριτικά με το μη-βελτιωμένο μοντέλο, γεγονός που πιστοποιεί την ανωτερότητά του, ακόμη και υπό τις πιο απαιτητικές συνθήκες.

Εξαιτίας της ρεαλιστικής προσέγγισης που ακολουθείται σε όλα τα στάδια δημιουργίας, εκπαίδευσης, και αξιολόγησης του υβριδικού μοντέλου της παρούσας διπλωματικής εργασίας, είναι εφικτή η εξέτασή του σε ένα πραγματικό πρόβλημα του συστήματος ηλεκτρικής ενέργειας όπου αξιοποιείται η πρόβλεψη Φ/Β παραγωγής, στην προημερήσια αγορά ηλεκτρικής ενέργειας. Η εφαρμογή του στη διαδικασία της προημερήσιας αγοράς ηλεκτρικής ενέργειας πιστοποιεί εμφατικά την αποτελεσματικότητά του, παρά το

γεγονός πως εκπαιδεύεται με τα ιστορικά δεδομένα μόλις ενός Φ/Β σταθμού. Αν και η εγκατεστημένη ισχύς του σταθμού είναι σχετικά μικρή (500 kW) και εμφανίζεται αρχικά χειρότερη μοναδιαία χρέωση ΜΜΒΑΠ σε σύγκριση με τον μέσο όρο των ΦοΣΕ, γίνεται εμφανής η ανωτερότητά του μόλις ενσωματωθεί ένας δεύτερος Φ/Β σταθμός στη διαδικασία των προβλέψεων. Όταν η υποβολή προβλέψεων παραγωγής αφορά ένα συνολικό χαρτοφυλάκιο, αναδεικνύεται η σημασία της γεωγραφικής και χρονικής διασποράς των εκπροσωπούμενων μονάδων. Αν και η εκτίμηση της μέσης χρέωσης των φορέων εκπροσώπησης έχει προκύψει βάσει προβλέψεων με χρονικό ορίζοντα μίας ώρας, η απόδοση του υβριδικού μοντέλου είναι εξαιρετική, παρά το γεγονός πως συνηθίζεται φορείς να διαθέτουν χαρτοφυλάκια αποτελούμενα από δεκάδες ή και εκατοντάδες Φ/Β σταθμούς.

8.3 ΠΡΟΤΑΣΕΙΣ ΜΕΛΛΟΝΤΙΚΗΣ ΕΠΕΚΤΑΣΗΣ

Σε όλη την έκταση της παρούσας διπλωματικής εργασίας είναι έκδηλη η ρεαλιστική προσέγγιση που ακολουθείται, καθώς και η πολυπαραμετρική αξιολόγηση του προτεινόμενου υβριδικού μοντέλου. Για αυτόν τον λόγο, θεωρείται εφικτή η περαιτέρω βελτίωση της ακρίβειας, εφόσον το μοντέλο πρόβλεψης υποβληθεί σε ορισμένες τροποποιήσεις. Οι κυριότερες από αυτές, οι οποίες είτε δεν ήταν άμεσα εφαρμόσιμες είτε δεν σχετίζονται με τις βασικές επιδιώξεις της παρούσας εργασίας, παρουσιάζονται στη συνέχεια:

- **Επέκταση διαθέσιμων δεδομένων:** Το παρόν υβριδικό μοντέλο εκπαιδεύεται με πραγματικά ιστορικά δεδομένα, τα οποία όμως αφορούν μόλις ένα πλήρες ημερολογιακό έτος. Εφόσον εκπαιδευτεί με μετεωρολογικά δεδομένα και δεδομένα παραγωγής περισσότερων ετών, είναι αναμενόμενη η αύξηση της υπολογιζόμενης ακρίβειας πρόβλεψης. Ταυτόχρονα, η χρήση άλλου είδους δεδομένων, όπως δεδομένα εικόνων του ουρανού (sky images), θα μπορούσαν να αυξήσουν την δυνατότητα απόκρισης του μοντέλου σε βραχυπρόθεσμες και ταχείες μεταβολές της νεφοκάλυψης.
- **Επιμέρους εκπαίδευση υβριδικού μοντέλου:** Όπως γίνεται αντιληπτό μέσω της εποχικής και της μετεωρολογικής ανάλυσης, το προτεινόμενο υβριδικό μοντέλο καλείται να συσχετίσει τη Φ/Β παραγωγή με μεταβαλλόμενες και διαφοροποιήσιμες μετεωρολογικές συνθήκες. Επομένως, η επιμέρους εκπαίδευσή του ανά εποχή ή και ανά μετεωρολογική συνθήκη, αναμένεται να βελτιώσουν την ακρίβεια των προβλέψεών του, καθώς δεν θα απαιτείται να ανταποκρίνεται σε έντονες διακυμάνσεις κρίσιμων παραγόντων, όπως η διάρκεια της ημέρας και η ηλιακή ακτινοβολία.
- **Προσθήκη στατιστικού μοντέλου πρόβλεψης μετεωρολογικών δεδομένων:** Προκειμένου το υβριδικό μοντέλο να προβλέψει τη Φ/Β παραγωγή σε χρονικό ορίζοντα μίας ώρας, τροφοδοτείται με μετεωρολογικά δεδομένα και δεδομένα παραγωγής της τρέχουσας ώρας. Ωστόσο, είναι πιθανό σε μία ημέρα με δυναμικά φαινόμενα, οι καιρικές συνθήκες να διαφέρουν δραματικά ακόμη και εντός μίας ώρας, παράγοντας στον οποίο οφείλεται η μειωμένη ακρίβειά του μοντέλου τις δυναμικές ημέρες. Η προσθήκη ενός 1-hour-ahead στατιστικού μοντέλου πρόβλεψης μετεωρολογικών δεδομένων – με τα αποτελέσματα του

οποίου θα τροφοδοτείται το υβριδικό μοντέλο – είναι δυνατό να μετριάσει το φαινόμενο μειωμένης απόδοσης τις δυναμικές ημέρες.

- Υλοποίηση παράλληλης αρχιτεκτονικής LSTM: Η μεθοδολογία της παρούσας διπλωματικής εργασίας περιλαμβάνει ακολουθιακή σύνδεση των επιμέρους δικτύων LSTM, καθώς η εκπαίδευσή τους πραγματοποιείται διαδοχικά. Η χρονική διάρκεια εκπαίδευσης ενός νευρωνικού δικτύου αποτελεί καθοριστική παράμετρο για την αξία του, καθώς ιδιαίτερα μεγάλοι υπολογιστικοί χρόνοι το καθιστούν δυσλειτουργικό. Εφόσον μάλιστα υλοποιηθούν ορισμένες από τις παραπάνω προτάσεις μελλοντικής επέκτασης, όπως η διεύρυνση των δεδομένων εισόδου ή η προσθήκη ενός στατιστικού μοντέλου πρόβλεψης, είναι πιθανό ο απαιτούμενος χρόνος υπολογισμού να αυξηθεί σημαντικά. Για αυτόν τον λόγο, η τροποποίηση της αρχιτεκτονικής των τεσσάρων LSTM δικτύων από ακολουθιακή σε παράλληλη, μπορεί να μειώσει σημαντικά τον χρόνο εκπαίδευσής τους, θεωρητικά έως και κατά 75%.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] P. Li, K. Zhou, X. Lu, and S. Yang, “A hybrid deep learning model for short-term PV power forecasting,” *Appl Energy*, vol. 259, p. 114216, Feb. 2020, doi: 10.1016/J.APENERGY.2019.114216.
- [2] D. Alhakeem, P. Mandal, A. U. Haque, A. Yona, T. Senjyu, and T. L. Tseng, “A new strategy to quantify uncertainties of wavelet-GRNN-PSO based solar PV power forecasts using bootstrap confidence intervals,” *IEEE Power and Energy Society General Meeting*, vol. 2015-September, Sep. 2015, doi: 10.1109/PESGM.2015.7286233.
- [3] P. Mandal, S. T. S. Madhira, A. Ul haque, J. Meng, and R. L. Pineda, “Forecasting Power Output of Solar Photovoltaic System Using Wavelet Transform and Artificial Intelligence Techniques,” *Procedia Comput Sci*, vol. 12, pp. 332–337, Jan. 2012, doi: 10.1016/J.PROCS.2012.09.080.
- [4] Y. K. Wu, C. R. Chen, and H. Abdul Rahman, “A novel hybrid model for short-term forecasting in PV power generation,” *International Journal of Photoenergy*, vol. 2014, 2014, doi: 10.1155/2014/569249.
- [5] K. Wang, X. Qi, and H. Liu, “Photovoltaic power forecasting based LSTM-Convolutional Network,” *Energy*, vol. 189, p. 116225, Dec. 2019, doi: 10.1016/J.ENERGY.2019.116225.
- [6] X. Huang, Q. Li, Y. Tai, Z. Chen, J. Zhang, J. Shi, B. Gao and W. Liu, “Hybrid deep neural model for hourly solar irradiance forecasting,” *Renew Energy*, vol. 171, pp. 1041–1060, Jun. 2021, doi: 10.1016/J.RENENE.2021.02.161.
- [7] D. Kothona, I. P. Panapakidis, and G. C. Christoforidis, “A novel hybrid ensemble LSTM-FFNN forecasting model for very short-term and short-term PV generation forecasting,” *IET Renewable Power Generation*, vol. 16, no. 1, pp. 3–18, Jan. 2022, doi: 10.1049/RPG2.12209.
- [8] I. Renewable Energy Agency, “RENEWABLE ENERGY STATISTICS 2023 STATISTIQUES D’ÉNERGIE RENOUVELABLE 2023 ESTADÍSTICAS DE ENERGÍA RENOVABLE 2023 About IRENA,” 2023. [Online]. Available: www.irena.org
- [9] Διεύθυνση εγγυήσεων προέλευσης και ενεργειακού μίγματος “Ενεργειακό μείγμα 2022, Ιούνιος 2023”. [Online]. Available: <https://www.dapeep.gr/wp-content/uploads/2023/07/%CE%95%CE%9D%CE%95%CE%A1%CE%93%CE%95%CE%99%CE%91%CE%9A%CE%9F-%CE%9C%CE%95%CE%99%CE%93%CE%9C%CE%91-2022.pdf>
- [10] M. H. M. Hariri, M. K. Mat Desa, S. Masri, and M. A. A. M. Zainuri, “Grid-Connected PV Generation System—Components and Challenges: A Review,” *Energies 2020, Vol. 13, Page 4279*, vol. 13, no. 17, p. 4279, Aug. 2020, doi: 10.3390/EN13174279.
- [11] P. Gupta and R. Singh, “PV power forecasting based on data-driven models: a review,” *International Journal of Sustainable Engineering*, vol. 14, no. 6, pp. 1733–1755, 2021, doi: 10.1080/19397038.2021.1986590.
- [12] Σύνδεσμος εταιριών φωτοβολταϊκών “Μια ‘ακτινογραφία’ της ελληνικής αγοράς φωτοβολταϊκών 2010-2022”. [Online]. Available: <https://helapco.gr/statistika-agoras-fwtovoltaikwn/mia-aktinografia-tis-ellinikis-agoras-fotovoltaikon-2010-2022-2/>
- [13] “EUR-Lex - 32011R1227 - EN - EUR-Lex.” [Online]. Available: <https://eur-lex.europa.eu/legal-content/el/TXT/?uri=CELEX%3A32011R1227>

- [14] M. Hosenuzzaman, N. A. Rahim, J. Selvaraj, and M. Hasanuzzaman, "Factors affecting the PV based power generation," *IET Seminar Digest*, vol. 2014, no. CP659, 2014, doi: 10.1049/CP.2014.1467.
- [15] K. V. Vidyandandan, "An Overview of Factors Affecting the Performance of Solar PV Systems," 2017. [Online]. Available: <https://www.researchgate.net/publication/319165448>
- [16] M. E. Meral and F. Diner, "A review of the factors affecting operation and efficiency of photovoltaic based electricity generation systems," *Renewable and Sustainable Energy Reviews*, vol. 15, no. 5, pp. 2176–2184, Jun. 2011, doi: 10.1016/J.RSER.2011.01.010.
- [17] D. Markovics and M. J. Mayer, "Comparison of machine learning methods for photovoltaic power forecasting based on numerical weather prediction," *Renewable and Sustainable Energy Reviews*, vol. 161, p. 112364, Jun. 2022, doi: 10.1016/J.RSER.2022.112364.
- [18] M. Zamo, O. Mestre, P. Arbogast, and O. Pannekoucke, "A benchmark of statistical regression methods for short-term forecasting of photovoltaic electricity production, part I: Deterministic forecast of hourly production," *Solar Energy*, vol. 105, pp. 792–803, Jul. 2014, doi: 10.1016/J.SOLENER.2013.12.006.
- [19] C. Voyant, G. Notton, S. Kalogirou, M.L. Nivet, C. Paoli, F. Motte and A. Fouilloy, "Machine learning methods for solar radiation forecasting: A review" *Renew Energy*, vol. 105, pp. 569–582, May 2017, doi: 10.1016/J.RENENE.2016.12.095.
- [20] F. Wang, X. Lu, S. Mei, Y. Su, Z. Zhen, Z. Zou, X. Zhang, R. Yin, N. Duić, M. Shafiekhah and J.P.S. Catalão, "A satellite image data based ultra-short-term solar PV power forecasting method considering cloud information from neighboring plant" *Energy*, vol. 238, p. 121946, Jan. 2022, doi: 10.1016/J.ENERGY.2021.121946.
- [21] A. El Hendouzi and A. Bourouhou, "Solar Photovoltaic Power Forecasting," *Journal of Electrical and Computer Engineering*, vol. 2020, 2020, doi: 10.1155/2020/8819925.
- [22] R. A. Rajagukguk, R. A. A. Ramadhan, and H. J. Lee, "A Review on Deep Learning Models for Forecasting Time Series Data of Solar Irradiance and Photovoltaic Power," *Energies 2020, Vol. 13, Page 6623*, vol. 13, no. 24, p. 6623, Dec. 2020, doi: 10.3390/EN13246623.
- [23] J. Helm, A. Swiergosz, H. Haeberle, J. Karnuta, J. Schaffer, V. Krebs, A. Spitzer and P. Ramkumar, "Machine Learning and Artificial Intelligence: Definitions, Applications, and Future Directions" *Curr Rev Musculoskelet Med*, vol. 13, no. 1, pp. 69–76, Feb. 2020, doi: 10.1007/S12178-020-09600-8/METRICS.
- [24] J. Gracia, A. J. Mazón, and I. Zamora, "Best ANN structures for fault location in single- and double-circuit transmission lines," *IEEE Transactions on Power Delivery*, vol. 20, no. 4, pp. 2389–2395, Oct. 2005, doi: 10.1109/TPWRD.2005.855482.
- [25] D. Anderson and G. Mcneill, "ARTIFICIAL NEURAL NETWORKS TECHNOLOGY A DACS State-of-the-Art Report," 1992.
- [26] Y. Wang, Y. Li, Y. Song, and X. Rong, "The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition," *Applied Sciences 2020, Vol. 10, Page 1897*, vol. 10, no. 5, p. 1897, Mar. 2020, doi: 10.3390/APP10051897.
- [27] P. S. Georgilakis, "Spotlight on modern transformer design," *Power Systems*, vol. 38, 2009, doi: 10.1007/978-1-84882-667-0/COVER.
- [28] N. C. Majee and A. B. Roy, "Asymptotic Behavior of an Artificial Neural Network Defined on Multipartite Directed Graph," *Online J Biol Sci*, vol. 10, no. 1, pp. 44–49, 2010. [Online]. Available: <https://www.researchgate.net/publication/237584452>
- [29] A. D. Dongare, R. R. Kharde, and A. D. Kachare, "Introduction to Artificial Neural Network," *Certified International Journal of Engineering and Innovative Technology (IJEIT)*, vol. 9001, no. 1, pp. 2277–3754, 2008.
- [30] M. H. Sazli, "A brief review of feed-forward neural networks," *Communications Faculty of Sciences University of Ankara Series A2-A3 Physical Sciences and Engineering*, vol. 50, no. 01, pp. 11–17, Jan. 2006, doi: 10.1501/COMMUA1-2_0000000026.

- [31] Z.C. Lipton, J. Berkowitz, C. Elkan, “A Critical Review of Recurrent Neural Networks for Sequence Learning,” 2015. [Online]. Available: <https://arxiv.org/abs/1506.00019>
- [32] J. Zou, Y. Han, and S. S. So, “Overview of artificial neural networks,” *Methods in Molecular Biology*, vol. 458, pp. 15–23, 2008, doi: 10.1007/978-1-60327-101-1_2/COVER.
- [33] “THE SCIENCE AND INFORMATION ORGANIZATION INTERNATIONAL JOURNAL OF ADVANCED RESEARCH IN ARTIFICIAL INTELLIGENCE”. [Online]. Available: www.ijarai.thesai.org
- [34] J. D. Kelleher, “Deep Learning”, Google Books. [Online]. Available: https://books.google.gr/books?hl=en&lr=&id=b06qDwAAQBAJ&oi=fnd&pg=PP9&dq=deep+learning&ots=_oH-WPmZUL&sig=kLWvtwH3Mv6dup9bML4ApC90o2U&redir_esc=y#v=onepage&q=deep%20learning&f=false.
- [35] X. Hao, G. Zhang, and S. Ma, “Deep Learning,” *International Journal of Semantic Computing*, vol. 10, no. 3, pp. 417–439, Nov. 2016, doi: 10.1142/S1793351X16500045.
- [36] S. Mittal, “A survey on modeling and improving reliability of DNN algorithms and accelerators,” *Journal of Systems Architecture*, vol. 104, p. 101689, Mar. 2020, doi: 10.1016/J.SYSARC.2019.101689.
- [37] S. Abirami and P. Chitra, “Energy-efficient edge based real-time healthcare support system,” *Advances in Computers*, vol. 117, no. 1, pp. 339–368, Jan. 2020, doi: 10.1016/BS.ADCOM.2019.09.007.
- [38] K. Janocha and W. M. Czarnecki, “On Loss Functions for Deep Neural Networks in Classification,” *Schedae Informaticae*, vol. 25, pp. 49–59, Feb. 2017, doi: 10.4467/20838476SI.16.004.6185.
- [39] J. Li, J. H. Cheng, J. Y. Shi, and F. Huang, “Brief introduction of back propagation (BP) neural network algorithm and its improvement,” *Advances in Intelligent and Soft Computing*, vol. 169 AISC, no. VOL. 2, pp. 553–558, 2012, doi: 10.1007/978-3-642-30223-7_87/COVER.
- [40] H. Robbins and S. Monro, “A Stochastic Approximation Method,” *The Annals of Mathematical Statistics*, vol. 22, no. 3, pp. 400–407, Sep. 1951, doi: 10.1214/AOMS/1177729586.
- [41] L. Bottou, “Stochastic Gradient Learning in Neural Networks,” 1991.
- [42] K. A. Sankararaman, S. De, Z. Xu, W. R. Huang, and T. Goldstein, “The Impact of Neural Network Overparameterization on Gradient Confusion and Stochastic Gradient Descent.” PMLR, pp. 8469–8479, Nov. 21, 2020. [Online]. Available: <https://proceedings.mlr.press/v119/sankararaman20a.html>
- [43] J. Zhang, S.P. Karimireddy, A. Veit, S. Kim, S.J. Reddi, S. Kumar and S. Sra, “Why ADAM Beats SGD for Attention Models.”, ICLR 2020 Conference Blind Submission, Sep. 25, 2019.
- [44] D. P. Kingma and J. L. Ba, “Adam: A Method for Stochastic Optimization,” *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, Dec. 2014. [Online]. Available: <https://arxiv.org/abs/1412.6980v9>
- [45] Z. Fei, Z. Wu, Y. Xiao, J. Ma, and W. He, “A new short-arc fitting method with high precision using Adam optimization algorithm,” *Optik (Stuttg)*, vol. 212, p. 164788, Jun. 2020, doi: 10.1016/J.IJLEO.2020.164788.
- [46] K. Deb, “Multi-Objective Optimization Using Evolutionary Algorithms: An Introduction,” 2011. [Online]. Available: <http://www.iitk.ac.in/kangal/deb.htm>
- [47] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory,” *Neural Comput*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/NECO.1997.9.8.1735.
- [48] J.F. Kolen and S.C. Kremer, “Gradient flow in recurrent nets: the difficulty of learning long-term dependencies | BibSonomy.”, Wiley-IEEE Press, pp. 237-243, 2001, doi: 10.1109/9780470544037.ch14
- [49] Y. Yu, X. Si, C. Hu, and J. Zhang, “A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures,” *Neural Comput*, vol. 31, no. 7, pp. 1235–1270, Jul. 2019, doi: 10.1162/NECO_A_01199.

- [50] F. A. Gers, J. Schmidhuber, and F. Cummins, "Learning to forget: continual prediction with LSTM," *Neural Comput*, vol. 12, no. 10, pp. 2451–2471, 2000, doi: 10.1162/089976600300015015.
- [51] R. Jozefowicz, W. Zaremba, and I. Sutskever, "An Empirical Exploration of Recurrent Network Architectures." PMLR, pp. 2342–2350, Jun. 01, 2015. [Online]. Available: <https://proceedings.mlr.press/v37/jozefowicz15.html>
- [52] F. A. Gers and J. Schmidhuber, "Recurrent nets that time and count," *Proceedings of the International Joint Conference on Neural Networks*, vol. 3, pp. 189–194, 2000, doi: 10.1109/IJCNN.2000.861302.
- [53] P. Doetsch, M. Kozielski, and H. Ney, "Fast and Robust Training of Recurrent Neural Networks for Offline Handwriting Recognition," *Proceedings of International Conference on Frontiers in Handwriting Recognition, ICFHR*, vol. 2014-December, pp. 279–284, Dec. 2014, doi: 10.1109/ICFHR.2014.54.
- [54] S. H. Noh, "Analysis of Gradient Vanishing of RNNs and Performance Comparison," *Information 2021, Vol. 12, Page 442*, vol. 12, no. 11, p. 442, Oct. 2021, doi: 10.3390/INFO12110442.
- [55] S. Hochreiter and J. Schmidhuber, "LSTM can Solve Hard Long Time Lag Problems," *Adv Neural Inf Process Syst*, vol. 9, 1996.
- [56] F. A. Gers and J. Schmidhuber, "LSTM recurrent networks learn simple context-free and context-sensitive languages," *IEEE Transactions on Neural Networks*, vol. 12, no. 6, pp. 1333–1340, Nov. 2001, doi: 10.1109/72.963769.
- [57] S. Siami-Namini, N. Tavakoli, and A. Siami Namin, "A Comparison of ARIMA and LSTM in Forecasting Time Series," *Proceedings - 17th IEEE International Conference on Machine Learning and Applications, ICMLA 2018*, pp. 1394–1401, Jan. 2019, doi: 10.1109/ICMLA.2018.00227.
- [58] S. Leva, A. Dolara, F. Grimaccia, M. Mussetta, and E. Ogliari, "Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power," *Math Comput Simul*, vol. 131, pp. 88–100, Jan. 2017, doi: 10.1016/J.MATCOM.2015.05.010.
- [59] B. Bazartseren, G. Hildebrandt, and K. P. Holz, "Short-term water level prediction using neural networks and neuro-fuzzy approach," *Neurocomputing*, vol. 55, no. 3–4, pp. 439–450, Oct. 2003, doi: 10.1016/S0925-2312(03)00388-6.
- [60] S. J. Wu, C. T. Hsu, and C. H. Chang, "Stochastic modeling of artificial neural networks for real-time hydrological forecasts based on uncertainties in transfer functions and ANN weights," *Hydrology Research*, vol. 52, no. 6, pp. 1490–1525, Dec. 2021, doi: 10.2166/NH.2021.030/921410/NH2021030.PDF.
- [61] J. T. Kuo, Y. Y. Wang, and W. S. Lung, "A hybrid neural-genetic algorithm for reservoir water quality management," *Water Res*, vol. 40, no. 7, pp. 1367–1376, Apr. 2006, doi: 10.1016/J.WATRES.2006.01.046.
- [62] R. R. Tan, "Hybrid evolutionary computation for the development of pollution prevention and control strategies," *J Clean Prod*, vol. 15, no. 10, pp. 902–906, Jan. 2007, doi: 10.1016/J.JCLEPRO.2006.01.011.
- [63] B. Abolpour, M. Javan, and M. Karamouz, "Water allocation improvement in river basin using Adaptive Neural Fuzzy Reinforcement Learning approach," *Appl Soft Comput*, vol. 7, no. 1, pp. 265–285, Jan. 2007, doi: 10.1016/J.ASOC.2005.02.007.
- [64] A. A. S. Raj, N. Dheetsith, S. S. Nair, and D. Ghosh, "Auto analysis of ECG signals using artificial neural network," *2014 International Conference on Science Engineering and Management Research, ICSEMR 2014*, Feb. 2014, doi: 10.1109/ICSEMR.2014.7043597.
- [65] S. H. Chen, A. J. Jakeman, and J. P. Norton, "Artificial Intelligence techniques: An introduction to their use for modelling environmental systems," *Math Comput Simul*, vol. 78, no. 2–3, pp. 379–400, Jul. 2008, doi: 10.1016/J.MATCOM.2008.01.028.
- [66] S. Rajasekaran, G.A.V. Pai, "Neural Networks, Fuzzy Logic and Genetic Algorithm: Synthesis and Applications", PHI Learning Pvt. Ltd., vol. 10, pp. 297-304, 2003

- [67] R. E. Carrillo, M. Leblanc, B. Schubnel, R. Langou, C. Topfel, and P. J. Alet, “High-Resolution PV Forecasting from Imperfect Data: A Graph-Based Solution,” *Energies* 2020, Vol. 13, p. 5763, vol. 13, no. 21, p. 5763, Nov. 2020, doi: 10.3390/EN13215763.
- [68] K. Hara, M. Akitomi, A. Masuda, T. Dewi, P. Risma, and Y. Oktarina, “A Review of Factors Affecting the Efficiency and Output of a PV System Applied in Tropical Climate,” *IOP Conf Ser Earth Environ Sci*, vol. 258, no. 1, p. 012039, Apr. 2019, doi: 10.1088/1755-1315/258/1/012039.
- [69] S. B. Kotsiantis, D. Kanellopoulos and P. E. Pintelas “Data Preprocessing for Supervised Learning,” 2006. [Online]. Available: https://www.researchgate.net/publication/228084519_Data_Preprocessing_for_Supervised_Learning.
- [70] S. Gopal, K. Patro, and K. Kumar Sahu, “Normalization: A Preprocessing Stage,” *IARJSET*, pp. 20–22, Mar. 2015, doi: 10.17148/iarjset.2015.2305.
- [71] “Quartiles.” [Online]. Available: <https://www.clubbenchmarking.com/quartiles>.
- [72] “sklearn preprocessing Robust Scaler — scikit-learn 1.3.0 documentation.” [Online]. Available: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.RobustScaler.html>.
- [73] H. Liu, X. Mi, and Y. Li, “Comparison of two new intelligent wind speed forecasting approaches based on Wavelet Packet Decomposition, Complete Ensemble Empirical Mode Decomposition with Adaptive Noise and Artificial Neural Networks,” *Energy Convers Manag*, vol. 155, pp. 188–200, Jan. 2018, doi: 10.1016/J.ENCONMAN.2017.10.085.
- [74] H. Ocak, K. A. Loparo, and F. M. Discenzo, “Online tracking of bearing wear using wavelet packet decomposition and probabilistic modeling: A method for bearing prognostics,” *J Sound Vib*, vol. 302, no. 4–5, pp. 951–961, May 2007, doi: 10.1016/J.JSV.2007.01.001.
- [75] M. F. Guo, X. D. Zeng, D. Y. Chen, and N. C. Yang, “Deep-Learning-Based Earth Fault Detection Using Continuous Wavelet Transform and Convolutional Neural Network in Resonant Grounding Distribution Systems,” *IEEE Sens J*, vol. 18, no. 3, pp. 1291–1300, Feb. 2018, doi: 10.1109/JSEN.2017.2776238.
- [76] L. S. Safavian, W. Kinsner, and H. Turanli, “A quantitative comparison of different mother wavelets for characterizing transients in power systems,” *Canadian Conference on Electrical and Computer Engineering*, vol. 2005, pp. 1453–1456, 2005, doi: 10.1109/CCECE.2005.1557253.
- [77] C. Vonesch, T. Blu, and M. Unser, “Generalized daubechies wavelet families,” *IEEE Transactions on Signal Processing*, vol. 55, no. 9, pp. 4415–4429, Sep. 2007, doi: 10.1109/TSP.2007.896255.
- [78] Q. Zhang, F. Zhang, J. Liu, X. Wang, Q. Chen, L. Zhao, L. Tian and Y. Wang, “A method for identifying the thin layer using the wavelet transform of density logging data” *J Pet Sci Eng*, vol. 160, pp. 433–441, Jan. 2018, doi: 10.1016/J.PETROL.2017.10.048.
- [79] Z. Hajirahimi and M. Khashei, “Hybrid structures in time series modeling and forecasting: A review,” *Eng Appl Artif Intell*, vol. 86, pp. 83–106, Nov. 2019, doi: 10.1016/J.ENGAPPAI.2019.08.018.
- [80] L. Tang, J. Li, H. Du, L. Li, J. Wu, and S. Wang, “Big Data in Forecasting Research: A Literature Review,” *Big Data Research*, vol. 27, p. 100289, Feb. 2022, doi: 10.1016/J.BDR.2021.100289.
- [81] R. R. Coifman, Y. Meyer, S. Quake, and M. V. Wickerhauser, “Signal processing and compression with wavelet packets,” in *Wavelets and Their Applications*, 1994. doi: 10.1007/978-94-011-1028-0_18.
- [82] H. Liu, H. Q. Tian, D. F. Pan, and Y. F. Li, “Forecasting models for wind speed using wavelet, wavelet packet, time series and Artificial Neural Networks,” *Appl Energy*, vol. 107, 2013, doi: 10.1016/j.apenergy.2013.02.002.
- [83] L. Wang, M. Song, S. Liu, B. Wang, S. Chen, T. Hu and W. Hu, “An effective algorithm for offshore air temperature prediction with LSTM neural network and wavelet

- decomposition and reconstruction”, *Journal of Physics: Conference Series*, 2022. doi: 10.1088/1742-6596/2414/1/012016.
- [84] H. Li, Y. Shen, and Y. Zhu, “Stock Price Prediction Using Attention-based Multi-Input LSTM,” in *Proceedings of Machine Learning Research*, 2018.
- [85] N. Bacanin, C. Stoean, M. Zivkovic, M. Rakic, R. Strulak-Wójcikiewicz, and R. Stoean, “On the Benefits of Using Metaheuristics in the Hyperparameter Tuning of Deep Learning Models for Energy Load Forecasting,” *Energies*, vol. 16, no. 3. 2023. doi: 10.3390/en16031434.
- [86] P. S. Pravin, J. Z. M. Tan, K. S. Yap, and Z. Wu, “Hyperparameter optimization strategies for machine learning-based stochastic energy efficient scheduling in cyber-physical production systems,” *Digital Chemical Engineering*, vol. 4, 2022, doi: 10.1016/j.dche.2022.100047.
- [87] S. Bouktif, A. Fiaz, A. Ouni, and M. A. Serhani, “Multi-sequence LSTM-RNN deep learning and metaheuristics for electric load forecasting,” *Energies (Basel)*, vol. 13, no. 2, 2020, doi: 10.3390/en13020391.
- [88] Y. Xia, C. Liu, Y. Y. Li, and N. Liu, “A boosted decision tree approach using Bayesian hyper-parameter optimization for credit scoring,” *Expert Syst Appl*, vol. 78, 2017, doi: 10.1016/j.eswa.2017.02.017.
- [89] C. V. Nastos, T. C. Theodosiou, C. S. Rekatsinas, and D. A. Saravanos, “A 2D Daubechies finite wavelet domain method for transient wave response analysis in shear deformable laminated composite plates,” *Comput Mech*, vol. 62, no. 5, 2018, doi: 10.1007/s00466-018-1558-9.
- [90] J. Brownlee, “How to Tune LSTM Hyperparameters with Keras for Time Series Forecasting,” *Long Short-Term Memory Networks*, 2017.
- [91] X. Ying, “An Overview of Overfitting and its Solutions,” in *Journal of Physics: Conference Series*, 2019. doi: 10.1088/1742-6596/1168/2/022022.
- [92] A. Botchkarev, “Performance Metrics (Error Measures) in Machine Learning Regression, Forecasting and Prognostics: Properties and Typology,” *Interdisciplinary Journal of Information, Knowledge, and Management*, vol. 14, pp. 45–76, Sep. 2018, doi: 10.28945/4184.
- [93] W. Liu, Y. Liu, X. Zhou, Y. Xie, Y. Han, S. Yoo and M. Sengupta, “Use of physics to improve solar forecast: Physics-informed persistence models for simultaneously forecasting GHI, DNI, and DHI” *Solar Energy*, vol. 215, pp. 252–265, Feb. 2021, doi: 10.1016/J.SOLENER.2020.12.045.
- [94] Π. Γεωργιάκης, (2015). Σύγχρονα συστήματα μεταφοράς και διανομής ηλεκτρικής ενέργειας. Κάλλιπος, Ανοικτές Ακαδημαϊκές Εκδόσεις. <https://hdl.handle.net/11419/2013>
- [95] Υπουργείο Περιβάλλοντος και Ενέργειας “ Νόμος υπ’ αριθμόν 4426 ΦΕΚ 187/06.10.2016 Κύρωση της Συμφωνίας των Παρισίων στη Σύμβαση Πλαίσιο των Ηνωμένων Εθνών για την κλιματική αλλαγή”. [Online]. Available: https://www.kodiko.gr/nomologia/download_fek?f=fek/2016/a/fek_a_187_2016.pdf&t=ffd06405613dc7617230c06fbb42ed20
- [96] Διαχειριστής ΑΠΕ & Εγγυήσεων Προέλευσης Α.Ε. - ΔΑΠΕΕΠ “Οραμα και Σκοπός - Α.Ε.” [Online]. Available: <https://www.dapeep.gr/etairia/orama-kai-skopos>.
- [97] Διαχειριστής Ανανεώσιμων Πηγών Ενέργειας και Εγγυήσεων Προέλευσης Α.Ε. “Μελέτη στο πλαίσιο του Μεταβατικού Μηχανισμού Βέλτιστης Ακρίβειας Πρόβλεψης”, Διεύθυνση Διαχείρισης Ειδικού Λογαριασμού ΑΠΕ (ΕΛΑΠΕ), Δεκέμβριος 2021. [Online]. Available: https://www.rae.gr/wp-content/uploads/2022/02/%CE%9C%CE%B5%CE%BB%CE%AD%CF%84%CE%B7_%CE%9C%CE%9C%CE%92%CE%91%CE%A0_public_consultation.pdf
- [98] Υπουργείο Περιβάλλοντος και Ενέργειας “Νέο καθεστώς στήριξης των σταθμών παραγωγής ηλεκτρικής ενέργειας από ανανεώσιμες πηγές ενέργειας και συμπαραγωγή ηλεκτρισμού και θερμότητας υψηλής απόδοσης Άρθρο 1Α” [Online]. Available: <http://www.opengov.gr/minenv/?p=12882>.

- [99] L. Visser, T. AlSkaif, and W. van Sark, “Operational day-ahead solar power forecasting for aggregated PV systems with a varying spatial distribution,” *Renew Energy*, vol. 183, pp. 267–282, Jan. 2022, doi: 10.1016/J.RENENE.2021.10.102.
- [100] Διαχειριστής ΑΠΕ & Εγγυήσεων Προέλευσης Α.Ε. - ΔΑΠΕΕΠ Α.Ε “Μοναδιαίες Χρεώσεις για ΜΜΒΑΠ και ΠΑΕΣΑ” [Online]. Available: <https://www.dapeep.gr/monadiaies-xrewseis-gia-mmbap-kai-paes-a-2>.
- [101] Ρυθμιστική Αρχή Ενέργειας - ΡΑΕ “ Απόφαση ΡΑΕ υπ’ αριθμόν 862/2022: Ημέρα έναρξης της συζευγμένης λειτουργίας της Ενδοημερήσιας Αγοράς μέσω της Συνεχούς Ενδοημερήσιας Συναλλαγής” [Online]. Available: <https://www.rae.gr/wp-content/uploads/2022/11/%CE%91%CE%A0%CE%9F%CE%A6%CE%91%CE%A3%CE%97-862-S.pdf>.
- [102] Π. Γεωργιλάκης, (2023). Οικονομική και αξιόπιστη λειτουργία σύγχρονων Συστημάτων Ηλεκτρικής Ενέργειας. Κάλλιπος, Ανοικτές Ακαδημαϊκές Εκδόσεις. <https://dx.doi.org/10.57713/kallipos-213>