



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

**ΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ
ΠΑΡΑΓΩΓΗΣ ΜΕ ΧΡΗΣΗ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ
ΔΙΚΤΥΩΝ ΤΥΠΟΥ ΜΑΚΡΑΣ ΒΡΑΧΕΙΑΣ ΜΝΗΜΗΣ
(LONG-SHORT TERM MEMORY)**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Δήμητρα Οικονόμου

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

Επόπτευση: Ιωάννης Μπαζιώνης, Υποψήφιος Διδάκτορας Ε.Μ.Π.

Αθήνα, Οκτώβριος 2023



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

**ΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ
ΠΑΡΑΓΩΓΗΣ ΜΕ ΧΡΗΣΗ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ
ΔΙΚΤΥΩΝ ΤΥΠΟΥ ΜΑΚΡΑΣ ΒΡΑΧΕΙΑΣ ΜΝΗΜΗΣ
(LONG-SHORT TERM MEMORY)**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Δήμητρα Οικονόμου

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

Επόπτευση: Ιωάννης Μπαζιώνης, Υποψήφιος Διδάκτορας Ε.Μ.Π.

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

.....
Παύλος Γεωργιλάκης
Καθηγητής Ε.Μ.Π.

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

.....
Ιωάννης Γκόνος
Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2023

.....

Δήμητρα Οικονόμου

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών

Ε.Μ.Π.

Copyright © Δήμητρα Οικονόμου, 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 την χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς την συγγραφέα.

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

ΠΕΡΙΛΗΨΗ

Σκοπός της παρούσας διπλωματικής εργασίας είναι η αξιοποίηση των μεθόδων Μηχανικής Μάθησης και των Τεχνητών Νευρωνικών Δικτύων, για την υλοποίηση αλγορίθμων, που εξάγουν αποτελέσματα για βραχυπρόθεσμη πρόβλεψη της ισχύος ενός φωτοβολταϊκού πάρκου, χρησιμοποιώντας ιστορικά δεδομένα του πάρκου, που προέκυψαν ύστερα από κατάλληλες μετρήσεις. Συγκεκριμένα, στόχος είναι η μελέτη δύο βασικών μοντέλων πρόβλεψης, καθώς και του υβριδικού μοντέλου που προκύπτει από τον συνδυασμό τους. Κατόπιν, μελετώνται τα αντίστοιχα σφάλματα κάθε μεθόδου, τα οποία θα οδηγήσουν σε σαφή συμπεράσματα, όσον αφορά την ακρίβεια της πρόβλεψης ισχύος για κάθε περίπτωση, τις απαιτήσεις των μοντέλων, την αποτελεσματικότητά τους και την καταλληλότητά τους για εφαρμογές σε πραγματικό χρόνο.

Αρχικά, μελετώνται οι συνθήκες που οδήγησαν στην ανάγκη αναζήτησης μεθόδων πρόβλεψης της ηλιακής ισχύος και οι νέες απαιτήσεις στον χώρο της ενέργειας. Στη συνέχεια, αναπτύσσονται διεξοδικά οι μέθοδοι των Τεχνητών Νευρωνικών Δικτύων, η ανάγκη αξιοποίησής τους και η αιτία διείσδυσής τους στον χώρο της ενέργειας. Έπειτα, γίνεται ενδελεχής ανάπτυξη δύο βασικών αλγορίθμων των Τεχνητών Νευρωνικών Δικτύων, με αναλυτική περιγραφή της υλοποίησής τους σε Η/Υ σε γλώσσα Python και συγκρίνονται τα αντίστοιχα αποτελέσματα. Με βάση τα αποτελέσματα αυτά, γίνεται αυτόματα σύγκριση των μοντέλων μεταξύ τους και με το υβριδικό και προτείνονται ορισμένες πιθανές επεκτάσεις της εργασίας.

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ

Βραχυπρόθεσμη πρόβλεψη ισχύος, Μηχανική Μάθηση, Τεχνητά Νευρωνικά Δίκτυα, Αλγόριθμοι LSTM, ARIMA, υβριδικό μοντέλο

SUMMARY

The purpose of this thesis is to use Machine Learning and Artificial Neural Network methods to implement algorithms that extract results for short-term prediction of the power output of a photovoltaic park, using historical data of the farm obtained after appropriate measurements. In particular, the objective is to study two basic prediction models, as well as the hybrid model resulting from their combination. Then, the respective errors of each method are studied which will lead to clear conclusions regarding the accuracy of power prediction for each case, the requirements of the models, their effectiveness and their suitability for real-time applications.

First, the circumstances that led to the search for solar power prediction methods and the new requirements in the energy field are studied. Then, the methods of Artificial Neural Networks, the need for their exploitation and the reason for their penetration in the energy field are developed in detail. Finally, two basic algorithms of Artificial Neural Networks are thoroughly developed with a detailed description of their implementation on PCs in Python language and the respective results are compared. Based on these results the models are automatically compared with each other and with the hybrid one and some possible extensions of the work are proposed.

KEY WORDS

Short-term power prediction, Machine Learning, Artificial Neural Networks, LSTM algorithms, ARIMA, hybrid model

ΕΥΧΑΡΙΣΤΙΕΣ

Η παρούσα διπλωματική εργασία εκπονήθηκε κατά το ακαδημαϊκό έτος 2023–2024 υπό την επίβλεψη του κ. Παύλου Γεωργιλιάκη, 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 δημιουργικό θέμα. Επίσης, θα ήθελα να ευχαριστήσω θερμά τον υποψήφιο διδάκτορα Γιάννη Μπαζιώνη για την υπομονή και την πολύτιμη βοήθεια και καθοδήγηση που μου παρείχε σε όλη την διάρκεια εκπόνησης της εργασίας, καθώς και για τον πολύτιμο χρόνο που μου αφιέρωσε.

Τέλος, θα ήθελα να ευχαριστήσω την οικογένειά μου, η οποία με στηρίζει σε κάθε μου βήμα και απόφαση σε όλη την μέχρι σήμερα πορεία μου, καθώς και την καθηγήτρια των μαθητικών μου χρόνων κα. Ελισάβετ, στην αφοσίωση και αγάπη της οποίας οφείλω το μέλλον μου.

ΠΕΡΙΕΧΟΜΕΝΑ

ΚΕΦΑΛΑΙΟ 1^ο : ΕΙΣΑΓΩΓΗ	15
1.1 Εξελίξεις στον τομέα της ενέργειας	15
1.2 Ανάγκη πρόβλεψης ισχύος	16
1.3 Αντικείμενο της εργασίας	17
1.4 Δομή της εργασίας	17
ΚΕΦΑΛΑΙΟ 2^ο: ΜΕΘΟΔΟΙ ΠΡΟΒΛΕΨΗΣ ΠΑΡΑΓΩΓΗΣ ΦΩΤΟΒΟΛΤΑΪΚΩΝ (ΦΒ) ΠΑΡΚΩΝ	19
2.1 Γενικά για τη λειτουργία των φωτοβολταϊκών πάρκων	19
2.1.1 Λειτουργία ΦΒ πλαισίων	19
2.1.2 ΦΒ πάρκο Λαμπρινής	21
2.1.3 Είδη πρόβλεψης	21
2.1.4 Διάκριση ημερών πρόβλεψης βάσει των καιρικών συνθηκών	23
2.1.5 Διαθέσιμα δεδομένα	25
2.2 Βασικά Μοντέλα πρόβλεψης ηλιακής ισχύος	26
2.2.1 Αριθμητική πρόγνωση καιρού	26
2.2.2 Δορυφορικά Μοντέλα Πρόβλεψης	26
2.2.3 Απεικόνιση Νεφών	26
2.2.4 Στατιστικά Μοντέλα Χρονοσειρών	27
2.2.5 Εισαγωγή στα Τεχνητά Νευρωνικά Δίκτυα	27
2.3 Μοντέλα Μηχανικής Μάθησης	27
2.3.1 Γενικά στοιχεία μεθόδου Μηχανικής Μάθησης	28
2.3.2 Μηχανική Μάθηση για πρόβλεψη ηλιακής ισχύος	28
2.3.3 Είδη μοντέλων Μηχανικής Μάθησης	30
2.4 Τεχνητά Νευρωνικά Δίκτυα	30
2.4.1 Τεχνητά Νευρωνικά Δίκτυα στην πρόβλεψη ηλιακής ενέργειας	31
2.4.2 Δομή και παράμετροι των Τεχνητών Νευρωνικών Δικτύων	32
2.4.3 Συνάρτηση ενεργοποίησης	34
2.4.4 Είδη Τεχνητών Νευρωνικών Δικτύων	35
2.4.5 Εξέλιξη των Τεχνητών Νευρωνικών Δικτύων στη σημερινή τους μορφή	36
2.4.6 Εφαρμογές Τεχνητών Νευρωνικών Δικτύων	38
2.4.7 Εφαρμογές Τεχνητών Νευρωνικών Δικτύων στην ηλιακή πρόβλεψη	39
ΚΕΦΑΛΑΙΟ 3^ο: ΑΛΓΟΡΙΘΜΟΙ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΚΑΙ ΜΕΘΟΔΟΣ ΒΕΛΤΙΩΣΗΣ ΤΟΥΣ	41
3.1 Γενικά	41
3.2 Αλγόριθμος LSTM	41
3.2.1 Γενικά στοιχεία	41
3.2.2 Δομή του μοντέλου LSTM	42

3.2.3	Παράμετροι του μοντέλου LSTM	44
3.2.4	Υπερπαράμετροι του μοντέλου LSTM	45
3.2.5	Ροή της πληροφορίας σε κάθε βαθμίδα LSTM	46
3.2.6	Μονομεταβλητό μοντέλο LSTM	47
3.2.7	Πολυμεταβλητό μοντέλο LSTM	48
3.2.8	Προεπεξεργασία δεδομένων εισόδου LSTM	50
3.2.9	Σύνολα Εκπαίδευσης, Ελέγχου και Επικύρωσης	51
3.2.10	Συνοπτική επεξήγηση κώδικα LSTM σε Python	53
3.3	Αλγόριθμος ARIMA	54
3.3.1	Γενικά στοιχεία	54
3.3.2	Δομή και παράμετροι του μοντέλου ARIMA	55
3.3.3	Ανάπτυξη κώδικα σε Python για το μοντέλο ARIMA	56
3.3.4	Επιλογή βασικών παραμέτρων μοντέλου με AUTO-ARIMA	58
3.4	Σύγκριση Αλγορίθμων ARIMA και LSTM	59
3.4.1	Διαφοροποίηση μοντέλων	59
3.4.2	Σημασία συνδυασμού των δύο μοντέλων	61
3.4.3	Αναφορά στη δημιουργία υβριδικού μοντέλου	61
ΚΕΦΑΛΑΙΟ 4^ο : ΥΒΡΙΔΙΚΟ ΜΟΝΤΕΛΟ LSTM ΚΑΙ ARIMA		63
4.1	Γενικά	63
4.2	Δεδομένα Εισόδου	64
4.3	Μέθοδοι ανάπτυξης υβριδικού μοντέλου	64
4.3.1	Μέθοδος εξαγωγής μέσης τιμής προβλέψεων	64
4.3.2	Μέθοδος χρήσης προβλέψεων ARIMA ως είσοδος στο LSTM	67
4.4	Σημασία δημιουργίας υβριδικού μοντέλου	70
ΚΕΦΑΛΑΙΟ 5^ο : ΑΠΟΤΕΛΕΣΜΑΤΑ		71
5.1	Υλοποίηση αλγορίθμων και εξαγωγή διαγραμμάτων	71
5.1.1	Διαγράμματα αλγορίθμου LSTM	71
5.1.2	Διαγράμματα αλγορίθμου ARIMA	76
5.1.3	Διαγράμματα υβριδικού μέσης τιμής LSTM και ARIMA	76
5.1.4	Διαγράμματα υβριδικού ARIMA ως είσοδος στο LSTM	77
5.2	Σφάλματα αλγορίθμων για κάθε μήνα	78
5.2.1	Σφάλματα LSTM για δεδομένα εκπαίδευσης κάθε μήνα του έτους	80
5.2.2	Σφάλματα ARIMA για δεδομένα εκπαίδευσης κάθε μήνα του έτους	83
5.2.3	Σφάλματα υβριδικού μέσης τιμής προβλέψεων LSTM και ARIMA	86
5.2.4	Σφάλματα υβριδικού μοντέλου ARIMA ως είσοδος στο LSTM	89
5.2.5	Σφάλματα μοντέλων για κάθε εποχή	94
5.3	Σύγκριση σφαλμάτων	94
5.3.1	Σύγκριση ARIMA και LSTM	94
5.3.2	Σύγκριση ARIMA και LSTM με τα υβριδικά τους μοντέλα	95

ΚΕΦΑΛΑΙΟ 6: ΣΥΜΠΕΡΑΣΜΑΤΑ-ΕΠΕΚΤΑΣΕΙΣ	97
6.1 Σύνοψη και συμπεράσματα εργασίας	97
6.2 Επεκτάσεις εργασίας	101
ΚΕΦΑΛΑΙΟ 7:ΒΙΒΛΙΟΓΡΑΦΙΑ	103

ΕΙΣΑΓΩΓΗ

1.1 ΕΞΕΛΙΞΕΙΣ ΣΤΟΝ ΤΟΜΕΑ ΤΗΣ ΕΝΕΡΓΕΙΑΣ

Τα τελευταία χρόνια, η εξερεύνηση και η εκμετάλλευση των ανανεώσιμων πηγών ενέργειας ανοίγουν ένα νέο κεφάλαιο στον τομέα της ενέργειας σε κάθε πτυχή του, τόσο οικονομική, όσο και οικολογική και επιχειρηματική.

Ως Ανανεώσιμες Πηγές Ενέργειας (ΑΠΕ) έχουν οριστεί οι ενεργειακές πηγές, οι οποίες υπάρχουν σε αφθονία στο φυσικό περιβάλλον και οι οποίες πρακτικά είναι ανεξάντλητες και φιλικές προς το περιβάλλον. Το ιδιαίτερο ενδιαφέρον για την ανάπτυξη των τεχνολογιών αυτών εμφανίστηκε αρχικά μετά την πρώτη πετρελαϊκή κρίση του 1974 και παγιώθηκε την τελευταία δεκαετία [1], [2], [3]. Πλέον οι ΑΠΕ αποτελούν μια εγχώρια πηγή ενέργειας για πολλές χώρες ανά τον κόσμο, με ευνοϊκές προοπτικές για περαιτέρω ανάπτυξη και διεξόδου στον κλάδο παραγωγής και αξιοποίησης ενέργειας. Παράλληλα, συμβάλλουν στην βελτίωση της ποιότητας του περιβάλλοντος, πράγμα ιδιαίτερα σημαντικό, καθώς μέχρι πρότινος ο ενεργειακός τομέας ήταν ο κλάδος που ευθυνόταν κατά κύριο λόγο για την ρύπανση του περιβάλλοντος.

Οι κυριότερες πηγές ανανεώσιμης ενέργειας είναι η ηλιακή, η αιολική, η βιομάζα, η γεωθερμία και η υδροηλεκτρική ενέργεια. Είναι μορφές ενέργειας που παράγουν μόνο μικρά επίπεδα διοξειδίου του άνθρακα και εκπομπών με αποτέλεσμα να συμβάλλουν στην καταπολέμηση της κλιματικής αλλαγής, που προκαλείται κατά κύριο λόγο από την καύση ορυκτών καυσίμων [2], [3]. Ο κλάδος αυτός μπορεί να καταστήσει τις τιμές της ηλεκτρικής ενέργειας σταθερές, δεδομένου ότι το κόστος των ανανεώσιμων πηγών εξαρτάται μόνο από την αρχική επένδυση του κεφαλαίου και είναι απαλλαγμένο από το μεταβαλλόμενο κόστος του άνθρακα, του πετρελαίου και του φυσικού αερίου, το οποίο επηρεάζεται από ποικίλους παράγοντες, μεταξύ των οποίων και η πολιτική σταθερότητα της εκάστοτε χώρας [4]. Ταυτόχρονα, είναι αξιοσημείωτο, πως τα αποθέματα άνθρακα, φυσικού αερίου και πετρελαίου, δηλαδή των βασικών μη ανανεώσιμων πηγών, είναι περιορισμένα και συγκεκριμένα, με αποτέλεσμα η εξόρυξη και εκμετάλλευσή τους να είναι, εκτός από δύσκολη και ιδιαίτερα δαπανηρή.

Το σχέδιο προώθησης των ΑΠΕ στην ενεργειακή πολιτική στηρίζεται ιδιαιτέρως από την Ευρωπαϊκή Ένωση (ΕΕ), η οποία με την υπογραφή της Ευρωπαϊκής Πράσινης Συμφωνίας, προέβλεψε μεταξύ άλλων, την στήριξη της έρευνας και της ανάπτυξης αγοράς των ΑΠΕ και την υποχρεωτική μείωση ρυπογόνων πηγών ενέργειας. Ιδιαίτερα μετά την έναρξη του πολέμου στην Ουκρανία, στις 24 Φεβρουαρίου του 2022, η ενεργειακή κρίση που ξεκίνησε και επεκτάθηκε σε μεγάλο βαθμό, λόγω της παγκόσμιας εξάρτησης από τα ρωσικά καύσιμα, οδήγησε στην ανάγκη υλοποίησης της ιδέας αυτής όσο το δυνατόν γρηγορότερα [1]. Αυτό οδήγησε στην υποβολή του σχεδίου REPowerEU τον Μάρτιο του ίδιου έτους, που έχει σκοπό την ταχεία αντικατάσταση των ορυκτών καυσίμων από καθαρές μορφές ενέργειας [1], [4]

Συγκεκριμένα, για την ηλιακή ενέργεια στο σχέδιο αυτό προβλέπεται η εγκατάσταση νέων ηλιακών φωτοβολταϊκών, ισχύος άνω των 320 GW έως το 2025, υπερδιπλάσιας δηλαδή σε σχέση με τα σημερινά επίπεδα και σχεδόν 600 GW έως το 2030. Η παροχή κινήτρων και ευκαιριών ευνοεί και προωθεί την επέκταση των ΑΠΕ.

Στο πλαίσιο αυτό, με την στροφή του ανθρώπου προς τις ανανεώσιμες πηγές ενέργειας τίθενται διάφορα ερωτήματα όσον αφορά κυρίως την απόδοση και την αξιοπιστία τους σε όλη την διάρκεια του έτους και σε όλες τις καιρικές συνθήκες. Ως αποτέλεσμα, η ανάγκη πρόβλεψης της παραγόμενης ενέργειας και ισχύος γίνεται ύψιστη ανάγκη.

Ιδιαίτερη αναφορά γίνεται για την διεξόδυση της ηλιακής ενέργειας στην ενεργειακή πολιτική και για τον τρόπο που η εκμετάλλευσή της θα μπορούσε να γίνει όσο το δυνατόν πιο αποδοτική και ουσιαστική. Σε αυτή την μορφή ενέργειας βασίζεται και η λειτουργία των φωτοβολταϊκών πάρκων, τα οποία αποτελούν και κέντρο ενδιαφέροντος της παρούσας διπλωματικής εργασίας.

1.2 ΑΝΑΓΚΗ ΠΡΟΒΛΕΨΗΣ ΙΣΧΥΟΣ

Η ηλιακή ενέργεια, ως μια από τις πιο σημαντικές και συχνά αξιοποιούμενες μορφές ανανεώσιμης ενέργειας, έχει προκαλέσει το ενδιαφέρον των επιστημόνων σε παγκόσμιο επίπεδο, για την διερεύνηση των ποικίλων εφαρμογών που ήδη έχει, αλλά και εκείνων που αναμένεται να έχει στο άμεσο μέλλον. Είναι ίσως η πιο σημαντική μορφή ανανεώσιμης πηγής ενέργειας και για την Ελλάδα. Ιδιαίτερα μέσω των φωτοβολταϊκών πάρκων γίνεται μία προσπάθεια για μέγιστη εκμετάλλευση της ηλιακής ακτινοβολίας [5].

Η φωτοβολταϊκή επίδραση και αξιοποίηση στον κλάδο της ενέργειας έχει εισέλθει ιστορικά πρώτη φορά το 1839, με την ιδιαιτερότητα όμως ότι μέχρι και το έτος 1954 οι επιστήμονες δεν ήταν σε θέση να γνωρίζουν λεπτομέρειες για τον τρόπο λειτουργίας της [6]. Μία από τις βασικότερες εφαρμογές ήταν στα διαστημικά προγράμματα, ως βέλτιστη πηγή ενέργειας για τους δορυφόρους. Πλέον, οι εφαρμογές ποικίλουν και αφορούν ενδεικτικά την παροχή ενέργειας σε σπίτια, αυτοκίνητα, μεγάλα κτήρια και πολλά άλλα. Δεδομένης της υψηλής απόδοσής τους και του προβλήματος που υπάρχει με την περιβαλλοντική κρίση, λόγω των ορυκτών καυσίμων, η αξιοποίηση των φωτοβολταϊκών εγκαταστάσεων έχει αυξηθεί ραγδαία μέσα στην τελευταία δεκαετία.

Η φωτοβολταϊκή λειτουργία βασίζεται στην μετατροπή της ενέργειας των προσπιπτόντων φωτονίων μίας φωτοβολταϊκής διάταξης, σε ηλεκτρική ενέργεια. Συγκεκριμένα, η αρχή λειτουργίας ενός φωτοβολταϊκού συστήματος στηρίζεται στο φωτοβολταϊκό φαινόμενο, κατά το οποίο δύο υλικά με συγκεκριμένα χαρακτηριστικά (ημιαγωγοί προσμίξεων διαφορετικής πολικότητας ιόντων), όταν βρεθούν σε επαφή και εν συνεχεία εκτεθούν σε ηλιακή ακτινοβολία παράγουν ηλεκτρικό ρεύμα. Οι επαφές αυτές σχηματίζουν τα φωτοβολταϊκά στοιχεία, τα οποία συνδέονται σε πλαίσια, πάνελ και τελικά συστοιχίες [6], [7].

Η λειτουργία και απόδοση των φωτοβολταϊκών πλαισίων επηρεάζεται από διάφορους παράγοντες, όπως η ποσότητα της ηλιακής ακτινοβολίας, η γωνία πρόσπτωσης των φωτονίων στην φωτοβολταϊκή επιφάνεια και η πιθανή σκίαση των πλαισίων. Είναι προφανές, πως ανάλογα με το κλίμα, τις καιρικές συνθήκες και το γεωγραφικό μήκος και πλάτος, η ποσότητα της ηλιακής ακτινοβολίας αλλάζει. Με άλλα λόγια, η απόδοση ενός φωτοβολταϊκού συστήματος είναι άρρηκτα συνδεδεμένη με τα μετεωρολογικά και κλιματικά στοιχεία μιας περιοχής (όχι μόνο η ηλιακή ακτινοβολία, αλλά και η θερμοκρασία της επηρεάζει την παραγωγή ηλεκτρικής ενέργειας) [6]. Επίσης το γεωγραφικό μήκος, το γεωγραφικό πλάτος και

το υψόμετρο του συστήματος επηρεάζουν δραστικά την απόδοση του φωτοβολταϊκού. Για να είναι εφικτή η μεγιστοποίηση της ενεργειακής αποδοτικότητας των φωτοβολταϊκών πλαισίων, θα πρέπει να επιτυγχάνεται βέλτιστη εκμετάλλευση της προσπίπτουσας ηλιακής ακτινοβολίας, μέσω της επιλογής βέλτιστης κλίσης και προσανατολισμού των πλαισίων.

Δεδομένης αυτής της ευμεταβλητότητας της απόδοσης, λόγω των κλιματικών συνθηκών, μπορεί πλέον να καταστεί σαφής η ανάγκη πρόβλεψης της παραγωγής ισχύος. Αφού ο άνθρωπος διαθέτει πολύ περιορισμένη ικανότητα επέμβασης στην παραγωγή της, η πρόβλεψη αποτελεί πλέον βασικό ερευνητικό στόχο, με την ανάγκη να επιτευχθεί με τη μέγιστη δυνατή ακρίβεια.

Στην πάροδο των ετών έχουν διερευνηθεί διάφορες μέθοδοι πρόβλεψης και πλέον, με την ανάπτυξη της τεχνολογίας, ο επιστημονικός κόσμος αξιοποιεί κατά κύριο λόγο τους Η/Υ για τον σκοπό αυτό.

1.3 ΑΝΤΙΚΕΙΜΕΝΟ ΤΗΣ ΕΡΓΑΣΙΑΣ

Η ανάγκη πρόβλεψης της παραγόμενης ισχύος αποτελεί βασικό αντικείμενο ενδιαφέροντος της παρούσας διπλωματικής εργασίας. Λόγω της εξάρτησης της ισχύος από τις καιρικές συνθήκες, όπως το νέφος ή ο άνεμος, η ανάγκη αυτή γίνεται ολοένα και πιο επιτακτική. Έτσι, με την βοήθεια της Μηχανικής Μάθησης και των Τεχνητών Νευρωνικών Δικτύων αναπτύσσονται δύο βασικοί αλγόριθμοι για πρόβλεψη για μία ημέρα. Μελετώνται τα σφάλματα για πρόβλεψη συνεφιασμένων, ηλιόλουστων και ημι-συννεφιασμένων ημερών αντίστοιχα. Έπειτα, κατασκευάζεται το υβριδικό μοντέλο και αποτυπώνονται τα τελικά συμπεράσματα. Με τον τρόπο αυτό, προκύπτουν αποτελέσματα σχετικά με την ικανότητα και απόδοση του φωτοβολταϊκού (ΦΒ) πάρκου, καθώς και για το εάν και πως αυτή η απόδοση θα μπορούσε να βελτιστοποιηθεί.

1.4 ΔΟΜΗ ΤΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία οργανώνεται σε επτά (7) Κεφάλαια, μεταξύ των οποίων και το παρόν Κεφάλαιο 1 στο οποίο έγινε μια εισαγωγή στο αντικείμενο της εργασίας και στις νέες απαιτήσεις στο χώρο της ενέργειας. Τα υπόλοιπα Κεφάλαια διαρθρώνονται ως εξής:

- Στο Κεφάλαιο 2 γίνεται μια εισαγωγή στην έννοια των φωτοβολταϊκών πάρκων και αναπτύσσεται διεξοδικά η λειτουργία τους. Στην συνέχεια γίνεται αναφορά στην Μηχανική Μάθηση και στα Τεχνητά Νευρωνικά Δίκτυα.
- Στο Κεφάλαιο 3 παρουσιάζονται οι δύο βασικοί αλγόριθμοι που αποτελούν κέντρο ενδιαφέροντος της παρούσας διπλωματικής εργασίας.
- Στο Κεφάλαιο 4 παρουσιάζεται το υβριδικό μοντέλο των μεθόδων του Κεφαλαίου 3.
- Στο Κεφάλαιο 5 αναλύονται τα αποτελέσματα και τα σφάλματα από την υλοποίηση των μεθόδων του Κεφαλαίου 3 σε γλώσσα Python.
- Στο Κεφάλαιο 6 παρατίθενται τα αντίστοιχα συμπεράσματά και προτείνονται επεκτάσεις της παρούσας διπλωματικής εργασίας.
- Στο Κεφάλαιο 7 παρουσιάζεται η βιβλιογραφία που χρησιμοποιήθηκε σε όλη την έκταση της παρούσας διπλωματικής εργασίας.

ΜΕΘΟΔΟΙ ΠΡΟΒΛΕΨΗΣ ΠΑΡΑΓΩΓΗΣ ΦΩΤΟΒΟΛΤΑΪΚΩΝ (ΦΒ) ΠΑΡΚΩΝ

2.1 ΓΕΝΙΚΑ ΓΙΑ ΤΗΝ ΛΕΙΤΟΥΡΓΙΑ ΤΩΝ ΦΩΤΟΒΟΛΤΑΪΚΩΝ ΠΑΡΚΩΝ

Τα φωτοβολταϊκά (ΦΒ) πάρκα βασίζουν την λειτουργία τους στα ΦΒ πλαίσια, τα οποία με την σειρά τους εκμεταλλεύονται το φωτοβολταϊκό φαινόμενο και μετατρέπουν την ηλιακή ενέργεια σε ηλεκτρική [8]. Συγκεκριμένα, η λειτουργία βασίζεται στα επιμέρους φωτοβολταϊκά πλαίσια, στα οποία λαμβάνει χώρα αυτή η μετατροπή ενέργειας. Στο παρόν κεφάλαιο μελετάται με ακρίβεια ο τρόπος λειτουργίας και δομής του ΦΒ πάρκου. Στη συνέχεια, γίνεται παρουσίαση του ΦΒ πάρκου Λαμπρινή που χρησιμοποιείται για τις προβλέψεις και έπειτα παρουσιάζονται τα μοντέλα Μηχανικής Μάθησης και Τεχνητών Νευρωνικών Δικτύων, με βάση τα οποία υλοποιούνται οι προβλέψεις παραγωγής των ΦΒ πάρκων στην παρούσα διπλωματική εργασία.

2.1.1 Λειτουργία ΦΒ Πλαισίων

Η λειτουργία ενός φωτοβολταϊκού συστήματος με βάση το φωτοβολταϊκό φαινόμενο βασίζεται στις ιδιότητες των ημιαγωγών.

Όταν το φως προσπέσει σε μια επιφάνεια τότε υπάρχουν τρεις δυνατές εκδοχές: είτε ανακλάται, είτε την διαπερνά (διαπερατότητα), είτε απορροφάται από το υλικό της επιφάνειας. Η τελευταία περίπτωση, κατά την οποία το φως ουσιαστικά απορροφάται σημαίνει πως μετά την απορρόφηση ακολουθεί και η μετατροπή του σε μια άλλη μορφή ενέργειας [7], [8]. Τις περισσότερες φορές, αυτή η μορφή στην οποία γίνεται η μετατροπή είναι η θερμική ενέργεια, χωρίς όμως αυτό να είναι απόλυτο. Στην πραγματικότητα, υπάρχουν ορισμένα υλικά, τα οποία μετατρέπουν την ηλιακή ενέργεια σε ηλεκτρική και ονομάζονται ημιαγωγοί. Ουσιαστικά, η αρχική ηλιακή ενέργεια αναφέρεται στην ενέργεια των φωτονίων, που προσπίπτουν με τη μορφή πακέτων ενέργειας πάνω στην φωτοβολταϊκή επιφάνεια. Οι ημιαγωγοί που επιτυγχάνουν την μετατροπή της ηλιακής σε ηλεκτρική ενέργεια έχουν την ιδιότητα να μεταβάλλουν την αγωγιμότητά τους [7], [8]. Μάλιστα, η ηλεκτρική τους αγωγιμότητα μπορεί να ελεγχθεί και να μεταβληθεί είτε μόνιμα, είτε δυναμικά και για αυτόν τον λόγο έχουν προκαλέσει το τεράστιο ενδιαφέρον των επιστημόνων σε παγκόσμιο επίπεδο [8]. Αυτό πρακτικά σημαίνει πως αν σε έναν ημιαγωγό μετρηθεί η αγωγιμότητά του σε φως και σκοτάδι τότε το αποτέλεσμα θα είναι σαφώς διαφορετικό.

Κάθε ημιαγωγός περιέχει δύο φορείς: ελεύθερα ηλεκτρόνια και οπές (δηλαδή έλλειμμα ηλεκτρονίων). Όλοι οι ημιαγωγοί σχηματίζουν κρυσταλλική δομή. Σε έναν κρύσταλλο απαντώνται τρεις ενεργειακές ζώνες [6], [8]:

- Η ζώνη σθένους, που περιλαμβάνει τα ηλεκτρόνια των εξωτερικών στοιβάδων.

- Η απαγορευμένη ζώνη, που δεν έχει καμία ενεργειακή στάθμη.
- Η ζώνη αγωγιμότητας, στην οποία μπαίνουν τα ηλεκτρόνια όταν προσλάβουν ικανή ενέργεια, ώστε να σπάσουν τους δεσμούς τους για συγκεκριμένη θερμοκρασία του υλικού.

Τα ελεύθερα ηλεκτρόνια βρίσκονται στην ζώνη αγωγιμότητας και οι οπές στην ζώνη σθένους. Η απόσταση ανάμεσα στην ζώνη σθένους και την ζώνη αγωγιμότητας ονομάζεται ενεργειακό διάκενο, Eg.

Με βάση τα παραπάνω, ορίζεται ως φωτοβολταϊκό φαινόμενο μια πόλωση των ηλεκτρικών φορτίων όταν αυτά εκτεθούν σε ηλιακή ακτινοβολία. Τα φωτόνια που προσπίπτουν στο κρυσταλλικό πλέγμα έχουν την ιδιότητα να μεταφέρουν ενέργεια στα δεσμευμένα ηλεκτρόνια σθένους και να τα καταστήσουν ελεύθερα. Το αποτέλεσμα είναι η αγωγιμότητα του ημιαγωγού να αυξάνεται και μέρος της ενέργειας να απορροφάται και να μετατρέπεται σε ηλεκτρική. Επομένως, προϋπόθεση για να γίνει αυτό είναι η ενέργεια του προσπίπτοντος φωτονίου να ξεπερνά την ενέργεια του διακένου [7], [8].

Η παραπάνω διαδικασία συντελείται στα ηλιακά κύτταρα ή αλλιώς φωτοστοιχεία που οργανώνονται σε φωτοβολταϊκά πλαίσια. Με άλλα λόγια, τα φωτοστοιχεία είναι στην ουσία οι ημιαγωγικές διατάξεις διόδων, συνήθως δισκοειδείς, που δέχονται στην επιφάνειά τους την ηλιακή ενέργεια και φροντίζουν για την μετατροπή της σε ηλεκτρική. Η σύνδεση είτε σειριακά, είτε παράλληλα των φωτοστοιχείων αυτών σε ένα πλαίσιο δημιουργεί συνεχές ηλεκτρικό ρεύμα [8].

Τα πλαίσια με την σειρά τους οργανώνονται σε συστοιχίες. Μια συστοιχία (string) είναι κάθε ηλεκτρική συνδεσμολογία όμοιων πλαισίων σε σειρά. Όλα τα πλαίσια διαρρέονται από το ίδιο ρεύμα, ενώ η συνολική τάση εξαρτάται από το πλήθος των πλαισίων.

Όλες οι συστοιχίες συνθέτουν ένα φωτοβολταϊκό πεδίο. Το φωτοβολταϊκό πεδίο DC δημιουργείται από πολλές παράλληλες συστοιχίες και αναφέρεται στον χώρο της εγκατάστασης των φωτοβολταϊκών πλαισίων. Εμπεριέχει τις καλωδιώσεις, τις διατάξεις ασφαλείας (μικροαντόμετοι διακόπτες, varistors, ασφάλειες ρεύματος), τους πίνακες των συστοιχιών (junction boxes) και εκτείνεται μέχρι τον κεντρικό διακόπτη DC του ΦΒ πεδίου, που παρεμβάλλεται πριν από τον χειριστή της εγκατάστασης (ρυθμιστές φόρτισης συσσωρευτών ή αναστροφέας) [9].

Ανάλογα με το είδος της κάθε ΦΒ εγκατάστασης μπορεί να υπάρχουν ποικίλες διατάξεις ελέγχου, προστασίας ή και μετατροπής του συνεχούς ρεύματος σε εναλλασσόμενο. Επίσης, κάθε διάταξη είναι σχεδιασμένη και προσαρμοσμένη στα ιδιαίτερα χαρακτηριστικά, τις καιρικές συνθήκες, την επιθυμητή λειτουργικότητα και την τοποθεσία της περιοχής στην οποία βρίσκεται. Όμως, σε κάθε περίπτωση τα δύο βασικότερα στοιχεία μιας φωτοβολταϊκής εγκατάστασης είναι η ισχύς που παράγεται και είναι αντικείμενο πρόβλεψης και το κόστος του συστήματος ανά μονάδα ισχύος.

Η πυκνότητα της ισχύος ενός ΦΒ πάρκου, ως ένα εκ των βασικότερων στοιχείων του, χρήζει μελέτης. Εξαρτάται από διάφορους παράγοντες που σχετίζονται άμεσα και με τους παράγοντες που επιδρούν στην απόδοση της φωτοβολταϊκής μετατροπής ενός ΦΒ στοιχείου. Οι βασικότεροι είναι [8], [10]: τα χρησιμοποιούμενα υλικά κατασκευής, η κατασκευαστική γεωμετρία των διατάξεων μετατροπής [11], η κρυσταλλική ποιότητα και καθαρότητα των ημιαγωγικών υλικών, η θερμοκρασία λειτουργίας, η χροιά της προσπίπτουσας φωτεινής ακτινοβολίας, η απορροφώμενη πυκνότητα φωτεινής ισχύος και οι κλιματικές συνθήκες. Επιπλέον, η ίδια η πυκνότητα εξαρτάται από την θέση του ήλιου σε σχέση με τον προσανατολισμό των ηλιακών συλλεκτών, την ώρα της ημέρας και την εποχή, αλλά και την

ανακλαστικότητα του εδάφους της εγκατάστασης. Για την μέγιστη εκμετάλλευση αυτών των παραγόντων απαιτούνται σχετικά πολύπλοκες εγκαταστάσεις [12].

2.1.2 ΦΒ Πάρκο Λαμπρινής

Το φωτοβολταϊκό (ΦΒ) πάρκο «Λαμπρινή» έχει ονομαστική ενεργό ισχύ 1550,78 kW και διαθέτει έναν μετεωρολογικό σταθμό και αισθητήρες θερμοκρασίας και ηλιακής ακτινοβολίας σε δύο σημεία του πάρκου. Από το πάρκο «Λαμπρινή» είναι διαθέσιμα τα εξής δεδομένα:

- Χρονική στιγμή λήψης (Χρονοσήμανση) σε απόλυτη ημερολογιακή ώρα μορφής Y-M-D h:m:s (Timestamp).
- Ολική παραγόμενη ενεργός ισχύς στο σημείο κοινής σύνδεσης (PCC) σε kW (Active Power).
- Ολική παραγόμενη άεργος ισχύς PCC σε kVAr (Reactive Power).
- Ολική πυκνότητα της ηλιακής ακτινοβολίας σε W/m^2 (Inclined Irradiance) σε δύο διαφορετικά σημεία του πάρκου.
- Στοιχεία από τον μετεωρολογικό σταθμό εντός του πάρκου με αισθητήρες για:
 - Ηλιακή ακτινοβολία (W/m^2)
 - Θερμοκρασία περιβάλλοντος ($^{\circ}C$)
 - Βροχόπτωση (mm/h)
 - Σχετική υγρασία (%)
 - Διεύθυνση ανέμου (μοίρες)
 - Ταχύτητα ανέμου (m/s)
 - Θερμοκρασία μονάδας ΦΒ ($^{\circ}C$)

Οι μετρήσεις από κάθε αισθητήρα λαμβάνονται με χρονική απόσταση 1 λεπτού η καθεμία από την επόμενη, αφορούν ολόκληρο το έτος 2021 και είναι διαθέσιμες μέσω Microsoft Excel.

2.1.3 Είδη Πρόβλεψης

Η πρόβλεψη της ισχύος είναι ένα φλέγον ζήτημα, το οποίο απασχολούσε και θα απασχολεί την επιστημονική κοινότητα. Για τον λόγο αυτό, μέσα στην πάροδο των ετών, έχουν αναζητηθεί ποικίλες μέθοδοι για ακριβή και ταχεία πρόβλεψη. Στην αρχή, οι μέθοδοι πρόβλεψης ήταν πιο απλοϊκές, δεδομένης και της απλότητας των αντίστοιχων προβλημάτων. Με την πάροδο των ετών και λόγω της αύξησης της πολυπλοκότητας και της ποικιλομορφίας των προβλημάτων και των διαθέσιμων δεδομένων, αλλά και της εξάρτησης του εκάστοτε προς πρόβλεψη μεγέθους από ποικίλα άλλα μεγέθη, οι μέθοδοι αυτές εξελίχθηκαν σε πιο πολύπλοκες.

Ιδιαίτερα όσον αφορά την πρόβλεψη ισχύος των φωτοβολταϊκών πάρκων, οι αντίστοιχες μέθοδοι πρόβλεψης χωρίζονται σε ποικίλες κατηγορίες με βάση βέβαια και τον βασικό άξονα ως προς τον οποίο αυτές διακρίνονται. Συγκεκριμένα, υπάρχουν οι παρακάτω κατηγοριοποιήσεις:

- Με βάση το χρονικό εύρος πρόβλεψης [13], [14]:

- Βραχυπρόθεσμη πρόβλεψη: Αφορά την μέθοδο που προβλέπει την παραγωγή των ΦΒ για τα επόμενα λεπτά, τις επόμενες ώρες, έως και τις επόμενες ημέρες, που μπορεί να αγγίξουν και την μία εβδομάδα. Η μορφή αυτή πρόβλεψης διευκολύνει οτιδήποτε έχει να κάνει με την ρύθμιση των βασικών λειτουργιών των ΑΠΕ, όπως ο συντονισμός λειτουργίας και παραγωγής, αλλά και η ασφάλεια του συστήματος.
 - Μεσοπρόθεσμη πρόβλεψη: Είναι αυτή που προβλέπει σε βάθος μερικών ημερών, έως και ενός μήνα και στοχεύει στην σωστή συντήρηση ενός σταθμού παραγωγής ενέργειας.
 - Μακροπρόθεσμη πρόβλεψη: Αφορά διάστημα μηνών έως και ενός έτους ή και μερικών ετών. Με τον τρόπο αυτό και λόγω αυτής της μακροπρόθεσμης διορατικότητας, μπορεί μια τέτοια πρόβλεψη να συντελέσει στην μελλοντική ανάπτυξη του συστήματος παραγωγής, μεταφοράς και διανομής της ηλεκτρικής ενέργειας και στην καλύτερη οργάνωση του δικτύου.
- Ανάλογα με την μορφή των διαθέσιμων δεδομένων πρόβλεψης:
 - Άμεση πρόβλεψη: Αφορά την απευθείας πρόβλεψη της ισχύος και απαιτεί ενδελεχή έλεγχο των μεταβλητών που μπορούν να την επηρεάσουν.
 - Έμμεση πρόβλεψη: Αφορά την πρόβλεψη μεταβλητών που επηρεάζουν και την τελική παραγωγή της ισχύος. Στην περίπτωση του πάρκου Λαμπρινή τα μεγέθη αυτά είναι η άεργος ισχύς ($kVar$), η ακτινοβολία σε κεκλιμένο επίπεδο (W/m^2), η θερμοκρασία περιβάλλοντος (σε βαθμούς $^{\circ}C$), η βροχόπτωση (mm/h), η σχετική υγρασία (%), η διεύθυνση του ανέμου (σε μοίρες), η ταχύτητα του ανέμου (m/s) και η θερμοκρασία του ΦΒ πλαισίου (σε βαθμούς $^{\circ}C$) [15], [16]. Στόχος είναι να μελετηθεί εάν η πρόβλεψη των μεγεθών αυτών που επηρεάζουν το μέγεθος που τίθεται ως αρχικός στόχος πρόβλεψης (παραγωγή ισχύος) είναι πράγματι ωφέλιμη.
 - Ανάλογα με τον τρόπο αξιοποίησης των ιστορικών δεδομένων:
 - Φυσική μέθοδος πρόβλεψης: Οι φυσικές μέθοδοι χρησιμοποιούν μαθηματικές εξισώσεις για την περιγραφή της φυσικής κατάστασης και της δυναμικής κίνησης των μετεωρολογικών συνθηκών. Τα μοντέλα πρόβλεψης που βασίζονται σε φυσικές μεθόδους, αποδίδουν καλύτερα όταν οι καιρικές συνθήκες είναι σταθερές.
 - Επίμονη πρόβλεψη: Είναι μια μορφή πρόβλεψης, που υποθέτει ένα μοτίβο εποχικότητας, μέσω της επανάληψης των καιρικών συνθηκών ανά ημέρα. Είναι κεντρικό μοντέλο, πυρήνας όλων των υπολοίπων μοντέλων πρόβλεψης. Υποθέτει μια πολύ ισχυρή συσχέτιση μεταξύ των σημερινών και των μελλοντικών τιμών. Οι μελλοντικές τιμές των χρονοσειρών υπολογίζονται στην ουσία με την υπόθεση ότι οι συνθήκες παραμένουν αμετάβλητες από την χρονική στιγμή t έως την χρονική στιγμή $t + \Delta t$.

- Στατιστική πρόβλεψη: Σε αυτή την μορφή πρόβλεψης, το προς πρόβλεψη μέγεθος θεωρείται ως μια εξηρημένη μεταβλητή, ενώ οι εισόδοι θεωρούνται ως ανεξάρτητες μεταβλητές [17]. Επομένως, για την επεξεργασία των μεταβλητών αυτών χρησιμοποιούνται μαθηματικά και στατιστικά μοντέλα. Τα μοντέλα που βασίζονται σε στατιστικές μεθόδους στοχεύουν στο να μετρήσουν την σχέση μεταξύ της ισχύος των φωτοβολταϊκών και των καιρικών παραμέτρων. Οι στατιστικές μέθοδοι βασίζονται συνήθως στην διαδικασία εκμάθησης του μοντέλου πρόβλεψης και των ιστορικών μεταβλητών. Η απόδοση των στατιστικών μεθόδων είναι ιδιαίτερα ευαίσθητη στον χρονικό ορίζοντα και στην ποιότητα των δεδομένων εισόδου. Οι πιο δημοφιλείς στατιστικές μέθοδοι που χρησιμοποιούνται στην πρόβλεψη της φωτοβολταϊκής ισχύος περιλαμβάνουν την ARIMA, την ARMA, την RM, την ELM και την SVM. Τα στατιστικά μοντέλα μπορούν συνήθως να παράγουν πιο ακριβή βραχυπρόθεσμα αποτελέσματα πρόβλεψης.
- Πρόβλεψη Μηχανικής Μάθησης: Είναι η μορφή πρόβλεψης, που χρησιμοποιεί αλγόριθμους που στηρίζονται σε ιστορικά δεδομένα και προηγούμενες παρατηρήσεις. Με τον τρόπο αυτό και ανανεώνοντας τα ιστορικά δεδομένα εκπαίδευσης, αποκτούν αρκετά καλά ποσοστά ακρίβειας και για αυτόν τον λόγο προτιμώνται από την επιστημονική κοινότητα [18].
- Υβριδική πρόβλεψη: Συνδυάζει τις ανωτέρω μεθόδους πρόβλεψης (Στατιστικές και Μηχανικής Μάθησης) με αποτέλεσμα να συνδυάζει τα πλεονεκτήματα της κάθε μεθόδου, να αποτρέπει κατά το δυνατόν τις αντίστοιχες αδυναμίες τους και να βελτιώνει σε μεγάλο βαθμό την ακρίβεια και την απόδοση της πρόβλεψης [19].

2.1.4 Διάκριση Ημερών Πρόβλεψης βάσει των Καιρικών Συνθηκών

Βασικό βήμα για μια σωστή πρόβλεψη είναι η ομαδοποίηση των ημερών σε ηλιόλουστες, συννεφιασμένες και ημι-συννεφιασμένες, ώστε να διερευνηθούν όλες οι δυνατές περιπτώσεις. Για τα δεδομένα του ΦΒ πάρκου Λαμπρινή αυτό πραγματοποιείται με δύο τρόπους, των οποίων τα αποτελέσματα συγκρίνονται, για να ελεγχθεί η εγκυρότητά τους.

Πρώτη μέθοδος είναι η απλή αναζήτηση στο διαθέσιμο αρχείο δεδομένων Excel, η οποία πρέπει να γίνεται ιδιαίτερα προσεκτικά, καθότι, λόγω της πολυπλοκότητας των δεδομένων αλλά και της ποσότητας και ποικιλίας τους, υπάρχει κίνδυνος λάθους. Η αναζήτηση βασίζεται στην παρατήρηση κυρίως της ηλιακής ισχύος και ακτινοβολίας, μεγέθη τα οποία για ημέρες καλοκαιρινών μηνών έχουν ιδιαίτερα υψηλές τιμές και για περισσότερες ώρες μέσα στην ημέρα, ενώ για συννεφιασμένες ημέρες έχουν χαμηλότερες τιμές. Όσον αφορά τις ημι-συννεφιασμένες ημέρες παρατηρείται ένα ακαθόριστο μοτίβο, το οποίο παρουσιάζει σκαμπανεβάσματα στα προαναφερθέντα μεγέθη, με αποτέλεσμα ο εντοπισμός και η εξακρίβωσή του να καθίσταται ακόμα δυσκολότερη.


Λόγω αυτής της δυσκολίας ομαδοποίησης των ημερών πρόβλεψης εφαρμόστηκε μια δεύτερη μέθοδος που βασίζεται σε έναν απλό αλγόριθμο. Η υλοποίηση του αλγόριθμου έγινε

σε γλώσσα προγραμματισμού Python και βασίστηκε στον ορισμό κατωφλίων με βάση την ονομαστική ισχύ του πάρκου, τα οποία διέκριναν τις ημέρες σε ηλιόλουστες, συννεφιασμένες και ημι-συννεφιασμένες. Συγκεκριμένα ο αλγόριθμος ακολουθεί τα παρακάτω βήματα:

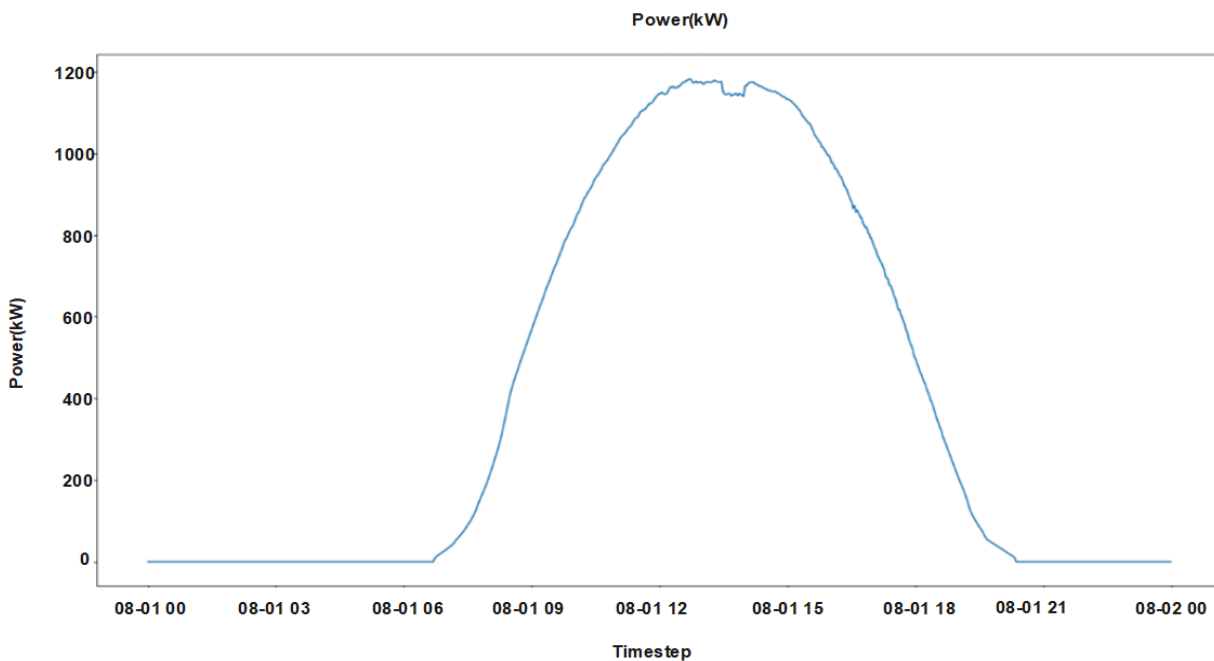
- 1) Φορτώνει ένα σύνολο δεδομένων από ένα αρχείο Excel που περιέχει τα δεδομένα του ΦΒ πάρκου Λαμπρινή.
- 2) Ορίζει τιμές κατωφλίου για την κατηγοριοποίηση των ημερών με βάση τις τιμές ισχύος. Η ονομαστική ισχύς του συγκεκριμένου ΦΒ πάρκου είναι 1550,78 kW. Ορίζονται τρεις κατηγορίες.
 - Συννεφιασμένες ημέρες: Ημέρες με τιμές ισχύος μικρότερες ή ίσες με το 20% της ονομαστικής ισχύος, το οποίο είναι το κατώφλι cloudy.
 - Ηλιόλουστες ημέρες: Ημέρες με τιμές ισχύος ίσες ή μεγαλύτερες από το 80% της ονομαστικής ισχύος, το οποίο είναι το κατώφλι sunny.
 - Ημι-ηλιόλουστες/ημι-συννεφιασμένες ημέρες: Ημέρες με τιμές ισχύος μεταξύ 50% και 70% της ονομαστικής ισχύος.
- 3) Φιλτράρει το σύνολο δεδομένων με βάση τις καθορισμένες τιμές κατωφλίου για την δημιουργία τριών υποσυνόλων:
 - cloudy_days: Περιέχει γραμμές από το σύνολο δεδομένων, όπου η ισχύς είναι μικρότερη ή ίση με το κατώφλι cloudy.
 - sunny_days: Περιέχει γραμμές από το σύνολο δεδομένων, όπου η ισχύς είναι μεγαλύτερη ή ίση με το κατώφλι sunny.
 - semi_sunny_days: Περιέχει σειρές από το σύνολο δεδομένων, όπου η ισχύς είναι μεταξύ του ελάχιστου και του μέγιστου ορίου ηλιοφάνειας.
- 4) Επιλέγει τυχαία μία ημέρα από κάθε κατηγορία (εάν είναι διαθέσιμη) χρησιμοποιώντας την συνάρτηση random.choice() και τα αντίστοιχα φιλτραρισμένα σύνολα δεδομένων. Οι επιλεγμένες ημερομηνίες αποθηκεύονται στις μεταβλητές random_sunny_day, random_cloudy_day και random_semi_sunny_day.
- 5) Τέλος, εκτυπώνει τις ημερομηνίες των τυχαία επιλεγμένων ημερών από κάθε κατηγορία.

Φυσικά, για την τελική επικύρωση των αποτελεσμάτων, ελέγχονται και συγκρίνονται τα αποτελέσματα των παραπάνω δύο μεθόδων.

Στα Σχήματα 2.1 και 2.2 φαίνεται η παραγωγή ισχύος για μία συννεφιασμένη ημέρα και για μία ηλιόλουστη ημέρα, αντίστοιχα.



Σχήμα 2.1: Παραγωγή ισχύος για μια συννεφιασμένη ημέρα του Ιανουαρίου



Σχήμα 2.2: Παραγωγή ισχύος για μια ηλιόλουστη μέρα του Αυγούστου

2.1.5 Διαθέσιμα Δεδομένα

Τα διαθέσιμα δεδομένα από το ΦΒ πάρκο Λαμπρινή περιέχουν πληθώρα ιστορικών μετρήσεων για την ηλιακή ακτινοβολία, την θερμοκρασία, τον άνεμο και την υγρασία, παραγόντων που αποδεδειγμένα επηρεάζουν την παραγωγή ισχύος των φωτοβολταϊκών πλαισίων και κατά επέκταση όλου του πάρκου.

Τα δεδομένα της Λαμπρινής λαμβάνονται ανά 1 λεπτό και αφορούν όλο το έτος 2021. Για ευκολία και πιο γρήγορη εξαγωγή των αποτελεσμάτων έγινε μία τροποποίηση στην είσοδο

των μοντέλων πρόβλεψης ώστε να λαμβάνουν εισόδο ανά 5 λεπτά. Τα μοντέλα πρόβλεψης είναι σαφώς γρηγορότερα για εισόδο ανά 5 λεπτά, σε σχέση με εισόδο ανά 1 λεπτό.

2.2 ΒΑΣΙΚΑ ΜΟΝΤΕΛΑ ΠΡΟΒΛΕΨΗΣ ΗΛΙΑΚΗΣ ΙΣΧΥΟΣ

Τα βασικά μοντέλα που χρησιμοποιούνται για την πρόβλεψη της ηλιακής ισχύος είναι τα ακόλουθα:

- η αριθμητική πρόγνωση του καιρού (NWP)
- τα δορυφορικά μοντέλα (satellite-based models)
- η απεικόνιση νεφών (cloud imagery)
- τα Στατιστικά Μοντέλα Χρονοσειρών (statistical time-series models) και
- τα Τεχνητά Νευρωνικά Δίκτυα (ANN - Artificial Neural Networks), τα οποία αποτελούν έναν από τους πιο δημοφιλείς αλγόριθμους και διερευνώνται στην παρούσα διπλωματική εργασία.

2.2.1 Αριθμητική Πρόγνωση Καιρού

Η μέθοδος πρόβλεψης NWP αντιπροσωπεύει τα αρχικά της φράσης Numerical Weather Prediction (Αριθμητική Πρόγνωση Καιρού) και χρησιμοποιείται για την πρόβλεψη καιρικών συνθηκών και μεταβλητών, συμπεριλαμβανομένης της ηλιακής ακτινοβολίας, σε συγκεκριμένες τοποθεσίες για μια δεδομένη χρονική περίοδο [20]. Τα μοντέλα NWP χρησιμοποιούν μαθηματικές εξισώσεις και αλγόριθμους για την προσομοίωση της συμπεριφοράς της ατμόσφαιρας και άλλων μεγεθών-συστατικών του συστήματος καιρού της Γης. Στο πλαίσιο της πρόβλεψης της ηλιακής ενέργειας, τα NWP χρησιμοποιούνται για την εκτίμηση της ηλιακής ακτινοβολίας, η οποία είναι η ποσότητα της ηλιακής ενέργειας που λαμβάνεται ανά μονάδα επιφάνειας κατά την διάρκεια μιας συγκεκριμένης χρονικής περιόδου. Η ηλιακή ακτινοβολία είναι ένας κρίσιμος παράγοντας για τον προσδιορισμό της ποσότητας ηλιακής ενέργειας και κατά επέκταση της ισχύος, που είναι και το αντικείμενο της πρόβλεψης.

2.2.2 Δορυφορικά Μοντέλα Πρόβλεψης

Τα δορυφορικά μοντέλα πρόβλεψης της ηλιακής ενέργειας (satellite-based models) περιλαμβάνουν την χρήση δορυφορικών δεδομένων για την εκτίμηση της ηλιακής ακτινοβολίας και την πρόβλεψη της δυναμικής παραγωγής ηλιακής ενέργειας σε συγκεκριμένες τοποθεσίες [21]. Τα μοντέλα αυτά αξιοποιούν τον πλούτο των πληροφοριών που καταγράφονται από τους μετεωρολογικούς δορυφόρους, όπως η νεφοκάλυψη, οι ατμοσφαιρικές συνθήκες και η ηλιακή ακτινοβολία, για να παρέχουν ακριβείς προβλέψεις ηλιακής ενέργειας. Υπάρχουν διάφοροι τύποι δορυφορικών μοντέλων για την πρόβλεψη της ηλιακής ενέργειας, με έναν από τους πιο σημαντικούς και ευρέως χρησιμοποιούμενους να είναι η απεικόνιση νεφών (cloud imagery).

2.2.3 Απεικόνιση Νεφών

Η πρόβλεψη μέσω απεικόνισης των νεφών (cloud imagery) για την ηλιακή ενέργεια είναι μια τεχνική που χρησιμοποιείται για την πρόβλεψη της κίνησης και της κάλυψης των σύννεφων στον ουρανό σε μια συγκεκριμένη τοποθεσία και χρονική περίοδο [21]. Αυτή η μέθοδος πρόβλεψης είναι ιδιαίτερα σημαντική, καθώς τα σύννεφα μπορούν να επηρεάσουν

σημαντικά την ποσότητα της ηλιακής ακτινοβολίας που φτάνει στους ηλιακούς συλλέκτες και, κατά συνέπεια, την παραγωγή ηλεκτρικής ενέργειας από τα ηλιακά φωτοβολταϊκά (ΦΒ) συστήματα. Η πρόβλεψη εικόνων σύννεφων περιλαμβάνει συνήθως τα ακόλουθα βήματα:

- Χρήση Δορυφορικών εικόνων ως είσοδο για την παρακολούθηση της κάλυψης και της κίνησης των νεφών σε πραγματικό χρόνο.
- Παρακολούθηση σύννεφων και της κίνησής τους μέσω ανάλυσης των εικόνων και επεξεργασίας τους με κατάλληλους αλγορίθμους.
- Ταξινόμηση νεφών με βάση τα χαρακτηριστικά τους, όπως το υψόμετρο ή το πάχος με στόχο την κατανόηση της πιθανής επίδρασης συγκεκριμένων τύπων σύννεφων στην ηλιακή ακτινοβολία.
- Μοντελοποίηση της ακτινοβολίας: Οι προβλέψεις εικόνων σύννεφων συνδυάζονται με μοντέλα ηλιακής ακτινοβολίας για την εκτίμηση της αναμενόμενης παραγωγής ηλιακής ενέργειας υπό διαφορετικές συνθήκες νεφοκάλυψης.
- Εξαγωγή αποτελεσμάτων τελικής πρόβλεψης παραγωγής ενέργειας και ισχύος.

2.2.4 Στατιστικά Μοντέλα Χρονοσειρών

Τα στατιστικά μοντέλα χρονοσειρών (statistical time-series models) είναι μια κατηγορία μοντέλων πρόβλεψης που χρησιμοποιούν ιστορικά δεδομένα χρονοσειρών για να κάνουν προβλέψεις για μελλοντικές τιμές. Αυτά τα μοντέλα αναλύουν τα μοτίβα, τις τάσεις και τις εξαρτήσεις εντός των δεδομένων χρονοσειρών [17]. Χρησιμοποιούνται ευρέως σε διάφορους τομείς, όπως η οικονομία, τα χρηματοοικονομικά, η μετεωρολογία και η μηχανική, για την πρόβλεψη μελλοντικών τιμών με βάση παρατηρήσεις του παρελθόντος.

2.2.5 Εισαγωγή στα Τεχνητά Νευρωνικά Δίκτυα

Η πρόβλεψη μέσω Τεχνητών Νευρωνικών Δικτύων (ANNs) χρησιμοποιεί ένα είδος μοντέλου Μηχανικής Μάθησης, εμπνευσμένο από την δομή του ανθρώπινου εγκεφάλου για την πρόβλεψη μελλοντικών τιμών σε δεδομένα χρονοσειρών [22]. Τα ANNs μαθαίνουν μοτίβα και σχέσεις από ιστορικά δεδομένα για να κάνουν ακριβείς προβλέψεις για μελλοντικά χρονικά βήματα. Χρησιμοποιούνται ευρέως για σύνθετες και μη γραμμικές εργασίες πρόβλεψης.

2.3 ΜΟΝΤΕΛΑ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

Η Μηχανική Μάθηση είναι ένα υποσύνολο της Τεχνητής Νοημοσύνης που επιτρέπει στα συστήματα υπολογιστών να μαθαίνουν από δεδομένα, να εντοπίζουν μοτίβα, να κάνουν προβλέψεις ή να λαμβάνουν αποφάσεις, χρησιμοποιώντας αλγόριθμους και στατιστικά μοντέλα [18]. Με τον όρο Τεχνητή Νοημοσύνη (TN) νοείται ο κλάδος της επιστήμης των υπολογιστών που επικεντρώνεται στην δημιουργία ευφυών μηχανών που μπορούν να μιμηθούν τις ανθρώπινες γνωστικές ικανότητες, όπως η μάθηση, η συλλογιστική, η επίλυση προβλημάτων και η λήψη αποφάσεων. Στην Ενότητα αυτή γίνεται μια αναλυτική και σαφής περιγραφή της συσχέτισης και επίδρασης της Μηχανικής Μάθησης στον τομέα της πρόβλεψης ισχύος, επεξηγούνται τα βασικότερα μοντέλα της και γίνεται μια εισαγωγή για το βασικό κομμάτι των Τεχνητών Νευρωνικών Δικτύων.

2.3.1 Γενικά Στοιχεία Μεθόδου Μηχανικής Μάθησης

Η Μηχανική Μάθηση και η πρόβλεψη είναι στενά συνδεδεμένα πεδία που αξιοποιούν μοντέλα βασισμένα σε δεδομένα για την πρόβλεψη μελλοντικών αποτελεσμάτων με βάση ιστορικά δεδομένα. Ακολουθεί μια σύντομη επισκόπηση των δύο εννοιών (παγιώνοντας τους ακριβείς ορισμούς τους), αλλά και μία σαφής επεξήγηση της μεταξύ τους σχέσης:

- **Μηχανική Μάθηση:** Η Μηχανική Μάθηση είναι ένας κλάδος της Τεχνητής Νοημοσύνης που επικεντρώνεται στην ανάπτυξη αλγορίθμων και μοντέλων που μπορούν να μαθαίνουν μοτίβα και σχέσεις από δεδομένα [18], [23]. Οι αλγόριθμοι Μηχανικής Μάθησης χρησιμοποιούν στατιστικές τεχνικές για να αναλύουν δεδομένα και να κάνουν προβλέψεις, ταξινομήσεις ή να λαμβάνουν αποφάσεις.
- **Πρόβλεψη:** Πρόκειται για τη διαδικασία πρόβλεψης μελλοντικών τιμών ή γεγονότων με βάση ιστορικά δεδομένα και πρότυπα. Χρησιμοποιείται συνήθως σε διάφορους τομείς, όπως τα οικονομικά, ο καιρός και οι πωλήσεις.

Το ερώτημα επομένως παραμένει. Με ποιον ακριβώς τρόπο υπεισέρχεται η Μηχανική Μάθηση στον κλάδο της πρόβλεψης; Στο πλαίσιο της πρόβλεψης, οι αλγόριθμοι Μηχανικής Μάθησης μπορούν να εφαρμοστούν σε δεδομένα χρονοσειρών για τον εντοπισμό υποκείμενων μοτίβων και τάσεων. Τα μοντέλα πρόβλεψης χρονοσειρών χρησιμοποιούν ιστορικά δεδομένα για να κάνουν προβλέψεις για μελλοντικές τιμές, λαμβάνοντας υπόψη παράγοντες, όπως η εποχικότητα και οι τάσεις.

Τεχνικές Μηχανικής Μάθησης, όπως αυτοπαλίνδρομα μοντέλα, δέντρα αποφάσεων, παλινδρόμηση διανυσμάτων υποστήριξης και νευρωνικά δίκτυα, μπορούν να χρησιμοποιηθούν για εργασίες πρόβλεψης χρονοσειρών. Αυτά τα μοντέλα εκπαιδεύονται σε ιστορικά δεδομένα και η απόδοσή τους αξιολογείται με την χρήση μετρικών, όπως το μέσο τετραγωνικό σφάλμα (MSE) ή το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE) σε σύνολα δεδομένων επικύρωσης.

Η πρόβλεψη με βάση την Μηχανική Μάθηση επιτρέπει μεγαλύτερη ευελιξία και προσαρμοστικότητα σε μεταβαλλόμενα πρότυπα και μη γραμμικές σχέσεις στα δεδομένα. Μπορεί να χειριστεί σύνθετες εργασίες πρόβλεψης και να προσαρμοστεί σε δυναμικά περιβάλλοντα, καθιστώντας την πολύτιμη σε σενάρια όπου οι παραδοσιακές στατιστικές μέθοδοι μπορεί να μην επαρκούν [18].

Συνολικά, οι τεχνικές Μηχανικής Μάθησης έχουν αποδειχθεί ισχυρά εργαλεία για εργασίες πρόβλεψης, επιτρέποντας ακριβείς προβλέψεις, βελτιστοποιώντας την κατανομή των πόρων και βελτιώνοντας την λήψη αποφάσεων σε διάφορους κλάδους.

2.3.2 Μηχανική Μάθηση για Πρόβλεψη Ηλιακής Ισχύος

Η Μηχανική Μάθηση για την πρόβλεψη της ηλιακής ισχύος των φωτοβολταϊκών περιλαμβάνει την χρήση ιστορικών δεδομένων ηλιακής ακτινοβολίας, πληροφοριών για τις καιρικές συνθήκες και άλλων σχετικών μεταβλητών για συγκεκριμένες εγκαταστάσεις ηλιακών συλλεκτών. Για την περίπτωση του ΦΒ πάρκου Λαμπρινή, τα ιστορικά δεδομένα αφορούν τόσο δεδομένα ηλιακής ισχύος από διαφορετικές εποχές για το έτος 2021, όσο και τιμές μεγεθών που επηρεάζουν την ισχύ. Ακολουθεί μια σύντομη και σαφής επισκόπηση της διαδικασίας, με την οποία μπορεί να επιτευχθεί πρόβλεψη με Μηχανική Μάθηση. Φυσικά, αυτή είναι μια γενίκευση της μεθόδου, αφού για κάθε μοντέλο Μηχανικής Μάθησης που

χρησιμοποιείται και για κάθε πρόβλημα που τίθεται, η διαδικασία ελαφρώς διαφοροποιείται. Τα βασικά βήματα είναι κοινά για κάθε μέθοδο [24]:

- 1) Συλλογή δεδομένων: Συλλέγονται ιστορικά δεδομένα από τους αισθητήρες και τους μετεωρολογικούς σταθμούς των ηλιακών συλλεκτών. Τα δεδομένα αυτά περιλαμβάνουν τα επίπεδα ηλιακής ακτινοβολίας, την θερμοκρασία, την υγρασία, την ταχύτητα του ανέμου και άλλους περιβαλλοντικούς παράγοντες.
- 2) Ανάλυση χαρακτηριστικών δεδομένων: Από τα συλλεχθέντα δεδομένα εξάγονται σχετικά χαρακτηριστικά, όπως η ώρα της ημέρας, η ημέρα της εβδομάδας και η εποχικότητα, για να καταγραφούν μοτίβα και εξαρτήσεις.
- 3) Προεπεξεργασία δεδομένων: Τα δεδομένα καθαρίζονται, κανονικοποιούνται και χωρίζονται σε σύνολα εκπαίδευσης και ελέγχου. Οι ελλείπουσες και οι ακραίες τιμές αντιμετωπίζονται κατάλληλα.
- 4) Επιλογή μοντέλου: Διάφορα μοντέλα Μηχανικής Μάθησης, όπως αυτοπαλίνδρομα μοντέλα και νευρωνικά δίκτυα μπορούν να χρησιμοποιηθούν για την πρόβλεψη της ηλιακής ενέργειας.
- 5) Εκπαίδευση μοντέλων: Το επιλεγμένο μοντέλο Μηχανικής Μάθησης εκπαιδεύεται με ιστορικά δεδομένα και οι παράμετροί του βελτιστοποιούνται για την ελαχιστοποίηση των σφαλμάτων πρόβλεψης.
- 6) Επικύρωση μοντέλου: Το εκπαιδευμένο μοντέλο αξιολογείται στο σύνολο ελέγχου, για να εκτιμηθεί η απόδοσή του χρησιμοποιώντας μετρικές, όπως το μέσο τετραγωνικό σφάλμα (MSE) ή το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE).
- 7) Πρόβλεψη: Μόλις επικυρωθεί το μοντέλο, μπορεί να χρησιμοποιηθεί για την πρόβλεψη της μελλοντικής παραγωγής ηλιακής ενέργειας και ισχύος, με βάση τα δεδομένα καιρού σε πραγματικό χρόνο.
- 8) Συνεχής παρακολούθηση και ενημέρωση: Το μοντέλο πρόβλεψης παρακολουθείται συνεχώς και ενημερώνεται με νέα δεδομένα, για να προσαρμόζεται στις μεταβαλλόμενες συνθήκες και να βελτιώνεται η ακρίβειά του.

Τα οφέλη της Μηχανικής Μάθησης για την πρόβλεψη της ηλιακής ενέργειας είναι πολλά. Τα μοντέλα Μηχανικής Μάθησης μπορούν να χειριστούν πολύπλοκες, μη γραμμικές σχέσεις μεταξύ των μεταβλητών του καιρού και της παραγωγής ηλιακής ενέργειας, βελτιώνοντας την ακρίβεια σε σύγκριση με τις παραδοσιακές στατιστικές μεθόδους. Μπορούν να συλλάβουν βραχυπρόθεσμα και μακροπρόθεσμα πρότυπα, όπως οι ημερήσιες διακυμάνσεις και οι εποχιακές επιδράσεις, για να παρέχουν πιο αξιόπιστες προβλέψεις.

Η πρόβλεψη με βάση την Μηχανική Μάθηση επιτρέπει την προσαρμογή σε πραγματικό χρόνο στις μεταβαλλόμενες καιρικές συνθήκες, επιτρέποντας την αποτελεσματική αξιοποίηση των πόρων ηλιακής ενέργειας. Μπορεί να συμβάλει στην βελτιστοποίηση της διαχείρισης ενέργειας, της εξισορρόπησης φορτίου και της ενσωμάτωσης της ηλιακής ενέργειας στο δίκτυο, οδηγώντας σε εξοικονόμηση κόστους και βελτιωμένη ευστάθεια του δικτύου.

Συνολικά, η πρόβλεψη με βάση την Μηχανική Μάθηση για την ηλιακή ενέργεια στους ηλιακούς συλλέκτες επιτρέπει πιο αποτελεσματική και βιώσιμη διαχείριση της ενέργειας, συμβάλλοντας στην αποτελεσματική ενσωμάτωση των ανανεώσιμων πηγών ενέργειας στο δίκτυο ηλεκτρικής ενέργειας.

2.3.3 Είδη Μοντέλων Μηχανικής Μάθησης

Η Μηχανική Μάθηση περιλαμβάνει διάφορους τύπους μοντέλων. Αυτά τα μοντέλα μπορούν να κατηγοριοποιηθούν ανάλογα με την φύση της διαδικασίας μάθησης. Οι βασικές κατηγορίες είναι [25]:

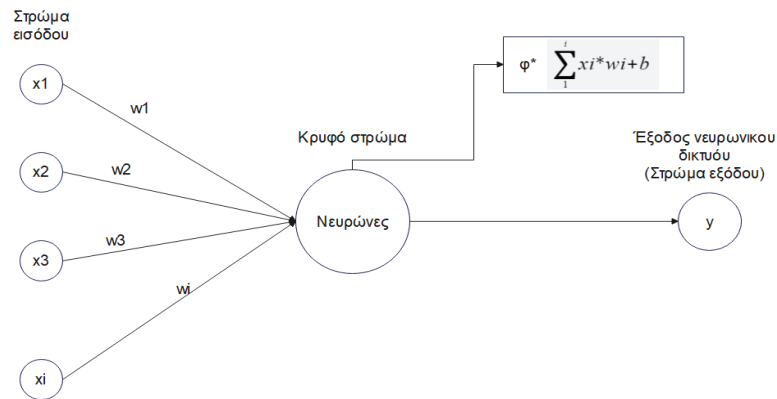
- 1) Μάθηση με επίβλεψη (Supervised learning): Σε αυτόν τον τύπο Μηχανικής Μάθησης, το μοντέλο εκπαιδεύεται σε επισημασμένα δεδομένα, όπου παρέχονται τόσο η είσοδος όσο και η αντίστοιχη έξοδος. Ο στόχος είναι το μοντέλο να μάθει την αντιστοίχιση μεταξύ εισόδου και εξόδου, ώστε να μπορεί να κάνει προβλέψεις σε νέα δεδομένα. Παραδείγματα αλγορίθμων μάθησης με επίβλεψη περιλαμβάνουν την γραμμική παλινδρόμηση, τις μηχανές διανυσμάτων υποστήριξης (SVM) και τα Τεχνητά Νευρωνικά Δίκτυα.
- 2) Μάθηση χωρίς επίβλεψη (Unsupervised learning): Η μάθηση χωρίς επίβλεψη ασχολείται με δεδομένα, για τα οποία το μοντέλο προσπαθεί να βρει μοτίβα και δομές. Οι τεχνικές ομαδοποίησης και η ανάλυση κύριων συνιστωσών (PCA), είναι κοινά παραδείγματα μάθησης χωρίς επίβλεψη.
- 3) Ενισχυτική μάθηση (Reinforcement Learning): Στην ενισχυτική μάθηση, ένας πράκτορας μαθαίνει να αλληλεπιδρά με ένα περιβάλλον για να επιτύχει έναν συγκεκριμένο στόχο. Ο πράκτορας λαμβάνει ανατροφοδότηση με την μορφή ανταμοιβών ή ποινών για τις ενέργειές του και μαθαίνει να λαμβάνει αποφάσεις που μεγιστοποιούν τις σωρευτικές ανταμοιβές.

2.4 ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Τα Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ/ANNs) είναι ένας συγκεκριμένος τύπος μοντέλου Μηχανικής Μάθησης. Με άλλα λόγια, τα ANNs είναι ένα υποσύνολο της Μηχανικής Μάθησης. Η Μηχανική Μάθηση είναι ένας ευρύτερος τομέας που περιλαμβάνει διάφορους αλγορίθμους και τεχνικές που επιτρέπουν στους υπολογιστές να μαθαίνουν από δεδομένα και να κάνουν προβλέψεις ή να λαμβάνουν αποφάσεις [26].

Τα ANNs είναι εμπνευσμένα από την δομή και την λειτουργία του ανθρώπινου εγκεφάλου. Αποτελούνται από διασυνδεδεμένους κόμβους (νευρώνες) οργανωμένους σε επίπεδα, όπου κάθε νευρώνας επεξεργάζεται πληροφορίες και τις μεταβιβάζει στο επόμενο επίπεδο. Τα ANNs μπορούν να μάθουν πολύπλοκα μοτίβα και σχέσεις στα δεδομένα, προσαρμόζοντας τα βάρη και τις πολώσεις των συνδέσεων μεταξύ των νευρώνων, κατά την διάρκεια της διαδικασίας εκπαίδευσης.

Συγκεκριμένα, όπως φαίνεται στο σχήμα 2.3, μέσα στους νευρώνες τα βάρη w_i πολλαπλασιάζονται με τις εισόδους x_i και σε αυτό το γινόμενο προστίθεται και μια παράμετρος πόλωσης. Αφού επαναληφθεί η διαδικασία για κάθε είσοδο, πολλαπλασιάζεται το τελικό άθροισμα με μια συνάρτηση ενεργοποίησης φ . Στα επόμενα Κεφάλαια θα επεξηγηθεί αναλυτικά η διαδικασία.



Σχήμα 2.3: Απλή μορφή ενός Τεχνητού Νευρωνικού Δικτύου

2.4.1 Τεχνητά Νευρωνικά Δίκτυα στην Πρόβλεψη Ηλιακής Ενέργειας

Τα ANNs χρησιμοποιούνται ευρέως στην πρόβλεψη της ηλιακής ενέργειας λόγω της ικανότητάς τους να συλλαμβάνουν πολύπλοκες σχέσεις και πρότυπα σε δεδομένα χρονοσειρών, καθιστώντας τα κατάλληλα για τον χειρισμό της μεταβλητότητας της παραγωγής ηλιακής ενέργειας.

Ο τρόπος με τον οποίο τα ANNs εφαρμόζονται στην πρόβλεψη της ηλιακής ενέργειας είναι αντίστοιχος με τον τρόπο εφαρμογής στον ευρύτερο κλάδο της μηχανικής μάθησης [22] και περιλαμβάνει τα παρακάτω βήματα:

- 1) Συλλογή δεδομένων: Συλλέγονται ιστορικά δεδομένα ηλιακής ακτινοβολίας, πληροφορίες για τις καιρικές συνθήκες και άλλες σχετικές μεταβλητές από εγκαταστάσεις ηλιακών συλλεκτών και μετεωρολογικούς σταθμούς.
- 2) Ανάλυση χαρακτηριστικών δεδομένων: Εξάγονται σχετικά χαρακτηριστικά από τα συλλεχθέντα δεδομένα, όπως η ώρα της ημέρας, η ημέρα της εβδομάδας και η εποχικότητα, για να καταγραφούν τα πρότυπα παραγωγής ηλιακής ενέργειας.
- 3) Προεπεξεργασία δεδομένων: Τα δεδομένα κανονικοποιούνται και χωρίζονται σε σύνολα εκπαίδευσης και ελέγχου. Οι ελλείπουσες τιμές και οι ακραίες τιμές αντιμετωπίζονται κατάλληλα.
- 4) Σχεδιασμός αρχιτεκτονικής ANN: Σχεδιάζεται η αρχιτεκτονική του ANN, η οποία αποτελείται από το στρώμα εισόδου, τα κρυφά στρώματα και το στρώμα εξόδου. Ο αριθμός των κρυφών στρωμάτων και των νευρώνων σε κάθε στρώμα μπορεί να καθοριστεί μέσω πειραματισμού.
- 5) Εκπαίδευση μοντέλου: Το ANN εκπαιδεύεται χρησιμοποιώντας τα ιστορικά δεδομένα παραγωγής ηλιακής ενέργειας και τα αντίστοιχα χαρακτηριστικά του καιρού. Τα βάρη και οι πλώσεις των νευρώνων ρυθμίζονται για την ελαχιστοποίηση των σφαλμάτων πρόβλεψης.
- 6) Επικύρωση μοντέλου: Το εκπαιδευμένο ANN αξιολογείται στο σύνολο ελέγχου για να εκτιμηθεί η απόδοσή του χρησιμοποιώντας μετρικές, όπως το μέσο τετραγωνικό σφάλμα (MSE) ή το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE).

- 7) Πρόβλεψη: Αφού επικυρωθεί το ANN, μπορεί να χρησιμοποιηθεί για την πρόβλεψη της μελλοντικής παραγωγής ηλιακής ενέργειας με βάση δεδομένα καιρού σε πραγματικό χρόνο.
- 8) Συνεχής παρακολούθηση και ενημέρωση: Το ANN πρόβλεψης παρακολουθείται συνεχώς και ενημερώνεται με νέα δεδομένα για να προσαρμόζεται στις μεταβαλλόμενες καιρικές συνθήκες και να βελτιώνεται η ακρίβειά του.

Τα οφέλη του ANN στην πρόβλεψη ηλιακής ενέργειας είναι τα ακόλουθα [22], [27]:

- Μη γραμμικές σχέσεις: Τα ANNs μπορούν να αποτυπώσουν μη γραμμικές σχέσεις μεταξύ της ηλιακής ακτινοβολίας, των καιρικών μεταβλητών και της παραγωγής ηλιακής ενέργειας, γεγονός που είναι απαραίτητο για την ακριβή πρόβλεψη.
- Πολύπλοκα μοτίβα: Τα ANNs μπορούν να χειριστούν πολύπλοκα πρότυπα στην παραγωγή ηλιακής ενέργειας, συμπεριλαμβανομένης της εποχικότητας, των ημερήσιων διακυμάνσεων και των διακυμάνσεων που προκαλούνται από τις καιρικές συνθήκες.
- Προσαρμοστικότητα: Τα ANNs μπορούν να προσαρμοστούν στις μεταβαλλόμενες καιρικές συνθήκες, καθιστώντας τα κατάλληλα για βραχυπρόθεσμες και μακροπρόθεσμες προβλέψεις ηλιακής ενέργειας.
- Ενσωμάτωση με το IoT (Internet of Things): Τα ANNs μπορούν να ενσωματωθούν με συσκευές του Διαδικτύου των Πραγμάτων (IoT), για να λαμβάνουν δεδομένα καιρού σε πραγματικό χρόνο, ώστε να βελτιώνεται η ακρίβεια της πρόβλεψης [28].
- Επεκτασιμότητα: Τα ANNs μπορούν να κλιμακωθούν για να χειριστούν μεγάλα σύνολα δεδομένων και πολλαπλές εγκαταστάσεις ηλιακών συλλεκτών.

Συνοψίζοντας, τα μοντέλα πρόβλεψης της ηλιακής ενέργειας που βασίζονται στα ANNs έχουν αποδείξει την αποτελεσματικότητά τους στην βέλτιστη αξιοποίηση της ηλιακής ενέργειας, στην βελτίωση της ευστάθειας του δικτύου και στην υποβοήθηση της λήψης αποφάσεων κατά την ενσωμάτωση των ανανεώσιμων πηγών ενέργειας στο δίκτυο ηλεκτρικής ενέργειας.

2.4.2 Δομή και Παράμετροι των Τεχνητών Νευρωνικών Δικτύων

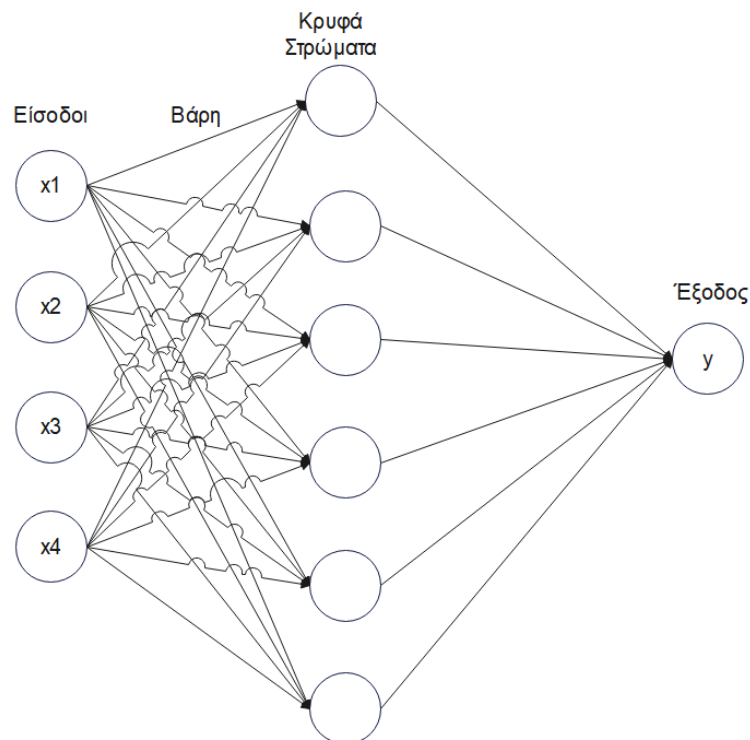
Η αρχιτεκτονική ενός ANN περιλαμβάνει την δομή και την οργάνωση των βασικών παραμέτρων και στοιχείων που το αποτελούν. Τα χαρακτηριστικά αυτά είναι σαφώς σχεδιασμένα για να μιμούνται την λειτουργία του ανθρώπινου εγκεφάλου [22], [29]. Έτσι, μια τυπική μορφή της αρχιτεκτονικής ενός ANN με τροφοδότηση περιλαμβάνει τα παρακάτω:

- Στρώμα εισόδου: Είναι το πρώτο στρώμα του ANN, μέσω του οποίου τα δεδομένα εισόδου τροφοδοτούνται στο δίκτυο. Κάθε νευρώνας στο στρώμα εισόδου αντιπροσωπεύει ένα χαρακτηριστικό ή μια ιδιότητα των δεδομένων εισόδου.
- Κρυφά στρώματα: Μεταξύ των στρωμάτων εισόδου και εξόδου, μπορεί να υπάρχουν ένα ή περισσότερα κρυφά στρώματα. Αυτά τα στρώματα περιέχουν κρυμμένους νευρώνες που επεξεργάζονται τα δεδομένα εισόδου και εκτελούν υπολογισμούς για να μάθουν μοτίβα και σχέσεις στα δεδομένα. Ο αριθμός των κρυφών στρωμάτων και ο αριθμός των νευρώνων σε κάθε στρώμα μπορεί να ποικίλλει ανάλογα με την πολυπλοκότητα του προβλήματος.

- Νευρώνες: Οι νευρώνες είναι οι βασικές υπολογιστικές μονάδες ενός ANN. Κάθε νευρώνας λαμβάνει το σταθμισμένο άθροισμα των εισόδων του, προσθέτει έναν όρο πόλωσης και στην συνέχεια περνά το αποτέλεσμα μέσω μιας συνάρτησης ενεργοποίησης, για να παράξει την έξοδο του νευρώνα.
- Βάρη και πολώσεις: Κάθε σύνδεση μεταξύ νευρώνων σε διαφορετικά επίπεδα έχει ένα σχετικό βάρος, το οποίο καθορίζει την ισχύ της σύνδεσης. Αυτά τα βάρη ορίζονται κατά την διαδικασία εκπαίδευσης και ρυθμίζουν τα βασικά χαρακτηριστικά για την δημιουργία προβλέψεων. Επιπλέον, κάθε νευρώνας έχει μία παράμετρο πόλωσης που βοηθά το δίκτυο να προσαρμόζεται καλύτερα στα δεδομένα εκπαίδευσης.
- Συνάρτηση ενεργοποίησης: Η συνάρτηση ενεργοποίησης εισάγει μη γραμμικότητα στο ANN, επιτρέποντάς του να μαθαίνει πολύπλοκες σχέσεις στα δεδομένα. Οι συνήθεις συναρτήσεις ενεργοποίησης περιλαμβάνουν την σιγμοειδή, την ReLU (Rectified Linear Unit) και την tanh (υπερβολική εφαπτομένη) [30].
- Στρώμα εξόδου: Το στρώμα εξόδου είναι το τελευταίο στρώμα ενός ANN, όπου γίνονται οι προβλέψεις. Ο αριθμός των νευρώνων στο στρώμα εξόδου εξαρτάται από την φύση του προβλήματος. Για παράδειγμα, για εργασίες παλινδρόμησης, υπάρχει συνήθως ένας νευρώνας για μία μόνο έξοδο, ενώ για ταξινόμηση πολλαπλών κλάσεων, υπάρχουν τόσοι νευρώνες όσες και οι διαφορετικές κλάσεις.

Όπως φαίνεται στο Σχήμα 2.4, η πραγματική δομή ενός Τεχνητού Νευρωνικού Δικτύου είναι πιο πολύπλοκη από αυτή που είχε παρουσιαστεί στο Σχήμα 2.3. Στην πραγματικότητα, ένα ANN έχει ένα ή περισσότερα κρυφά στρώματα, κάμποσους νευρώνες σε κάθε στρώμα και πολλαπλές συνδέσεις μεταξύ των νευρώνων των γειτονικών στρωμάτων.

Σε ένα ANN με εμπρόσθια τροφοδότηση, η ροή της πληροφορίας είναι μίας κατεύθυνσης, ξεκινώντας από το στρώμα εισόδου, περνώντας μέσα από τα κρυφά στρώματα και καταλήγοντας στο στρώμα εξόδου.



Σχήμα 2.4: Πολύπλοκη μορφή ενός Τεχνητού Νευρωνικού Δικτύου

Κατά την διάρκεια της διαδικασίας εκπαίδευσης, το ANN προσαρμόζει επαναληπτικά τα βάρη και τις πολώσεις χρησιμοποιώντας αλγορίθμους βελτιστοποίησης για να ελαχιστοποιήσει τα σφάλματα πρόβλεψης.

Είναι σημαντικό να σημειωθεί ότι υπάρχουν και άλλοι τύποι ANNs, όπως τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNNs) και τα νευρωνικά δίκτυα συνελίξεων (CNNs), τα οποία έχουν διαφορετικές αρχιτεκτονικές, σχεδιασμένες για να χειρίζονται συγκεκριμένους τύπους δεδομένων και εργασιών [22]. Η αρχιτεκτονική ενός ANN παίζει καθοριστικό ρόλο στην ικανότητά του να μαθαίνει σύνθετα μοτίβα και να κάνει ακριβείς προβλέψεις.

2.4.3 Συνάρτηση Ενεργοποίησης

Μία βασική παράμετρος της αρχιτεκτονικής ενός Τεχνητού Νευρωνικού Δικτύου είναι η συνάρτηση ενεργοποίησης. Υπάρχουν αρκετές και διαφορετικές συναρτήσεις και ανάλογα με την συνάρτηση που χρησιμοποιείται παρατηρούνται διαφορές ως προς τις απώλειες και την απόδοση του μοντέλου. Γενικώς, οι συναρτήσεις αυτές εισάγουν μη γραμμικότητα στο δίκτυο και του επιτρέπουν να μαθαίνει πολύπλοκα μοτίβα στα δεδομένα. Οι σημαντικότερες από αυτές είναι [30]:

Πίνακας 2.1. Συγκεντρωτικός πίνακας συναρτήσεων ενεργοποίησης

Sigmoid Activation: $f(x) = \frac{1}{1+e^{-x}}$	(2.1)
Hyperbolic Tangent Activation (tanh): $f(x) = \frac{2}{1+e^{-2x}} - 1$	(2.2)
Rectified Linear Unit (ReLU): $f(x) = \max(0, x)$	(2.3)
Leaky Rectified Linear Unit (Leaky ReLU): $f(x) = \max(\alpha x, x)$	(2.4)
Parametric Rectified Linear Unit (PReLU): $f(x) = \max(\alpha x, x)$	(2.5)
Exponential Linear Unit (ELU): $f(x) = \begin{cases} x, & x \geq 0 \\ \alpha * (\exp(x) - 1), & x < 0 \end{cases}$	(2.6)
Swish Activation: $f(x) = x * \text{sigmoid}(x)$	(2.7)
Softmax Activation: $f(x_i) = \frac{e^{x_i}}{\sum(e^{x_j})}$	(2.8)

Στον πίνακα 2.1, η συνάρτηση (2.1) έχει εύρος (0,1). Η συνάρτηση (2.2) έχει εύρος (-1,1) και η (2.3) $[0, +\infty)$. Αντίστοιχα, η εξίσωση (2.4) έχει εύρος: $(-\infty, +\infty)$ και θεωρεί συνήθως πως το a είναι μια μικρή θετική σταθερά περίπου ίση με 0,01. Η εξίσωση (2.5) περιλαμβάνει επίσης μία παράμετρο a που ορίζεται κατά την διάρκεια της εκπαίδευσης και το $f(x)$ κυμαίνεται σε εύρος: $(-\infty, +\infty)$. Στην εξίσωση (2.6) θεωρείται εύρος: $(-a, +\infty)$, όπου το a , που εμφανίζεται και στην εξίσωση του $f(x)$, είναι μια θετική σταθερά συνήθως ίση με 1,0. Η συνάρτηση (2.7) έχει εύρος: $(-\infty, +\infty)$. Για την συνάρτηση (2.8) η σχέση για το $f(x_i)$ έχει εύρος (0, 1), ορίζεται για κάθε κλάση i και έχει άθροισμα 1 για όλες τις κλάσεις.

Αυτές οι συναρτήσεις ενεργοποίησης εξυπηρετούν διαφορετικούς σκοπούς και μπορούν να επηρεάσουν την απόδοση και την σύγκλιση του νευρωνικού δικτύου κατά την διάρκεια της εκπαίδευσης. Η επιλογή της συνάρτησης ενεργοποίησης εξαρτάται από την συγκεκριμένη εργασία, την αρχιτεκτονική και τα χαρακτηριστικά των δεδομένων που υποβάλλονται σε επεξεργασία.

Στο πλαίσιο των συναρτήσεων ενεργοποίησης στα ANNs, ο όρος "εύρος" (Range) αναφέρεται στις πιθανές τιμές εξόδου που μπορεί να παράγει μια συνάρτηση ενεργοποίησης για μια δεδομένη είσοδο. Το εύρος μιας συνάρτησης ενεργοποίησης περιλαμβάνει το σύνολο των έγκυρων τιμών εξόδου που μπορεί να λάβει η συνάρτηση μετά την επεξεργασία της εισόδου της.

Το εύρος εκφράζεται συνήθως ως ένα διάστημα που εκτείνεται από την ελάχιστη τιμή έως την μέγιστη τιμή της εξόδου της συνάρτησης ενεργοποίησης. Το εύρος είναι σημαντικό επειδή καθορίζει τις πιθανές ενεργοποιήσεις των νευρώνων σε ένα νευρωνικό δίκτυο, οι οποίες με την σειρά τους επηρεάζουν την ροή πληροφοριών και τις δυνατότητες μάθησης του δικτύου. Για τον λόγο αυτό, η επιλογή της σωστής συνάρτησης ενεργοποίησης μπορεί να επηρεάσει σημαντικά την απόδοση του νευρωνικού δικτύου κατά την διάρκεια της εκπαίδευσης [30].

2.4.4 Είδη Τεχνητών Νευρωνικών Δικτύων

Τα Τεχνητά Νευρωνικά Δίκτυα ανάλογα με την δομή, τις παραμέτρους, την λειτουργία τους και την γενικότερη αρχιτεκτονική τους μπορούν να διακριθούν σε επιμέρους μοντέλα. Τα βασικότερα από αυτά είναι τα παρακάτω [26], [27]:

- FFNN (Feedforward Neural Network): Το FFNN είναι ένας ευρύτερος όρος που περιλαμβάνει κάθε νευρωνικό δίκτυο, όπου η πληροφορία ρέει προς μία κατεύθυνση, από την είσοδο προς την έξοδο, χωρίς βρόχους ανατροφοδότησης. Το MLP είναι ένας συγκεκριμένος τύπος FFNN.
- MLP (Multilayer Perceptron): Το MLP είναι ένας τύπος νευρωνικού δικτύου εμπρόσθιας τροφοδότησης που αποτελείται από πολλαπλά στρώματα νευρώνων. Διαθέτει ένα στρώμα εισόδου, ένα ή περισσότερα κρυφά στρώματα και ένα στρώμα εξόδου. Κάθε νευρώνας σε ένα στρώμα συνδέεται με όλους τους νευρώνες στα γειτονικά στρώματα. Τα MLP χρησιμοποιούνται συνήθως για εργασίες μάθησης με επίβλεψη, όπως η ταξινόμηση και η παλινδρόμηση.
- RBNN (Radial Basis Function Neural Network): Το RBNN χρησιμοποιεί συναρτήσεις ακτινικής βάσης ως συναρτήσεις ενεργοποίησης. Χρησιμοποιείται συνήθως για εργασίες προσέγγισης συναρτήσεων και αναγνώρισης προτύπων.
- RNN (Recurrent Neural Network): Το RNN είναι ένας τύπος νευρωνικού δικτύου που έχει σχεδιαστεί για να χειρίζεται διαδοχικά δεδομένα, διατηρώντας και αξιοποιώντας πληροφορίες από προηγούμενες εισόδους. Λόγω της ιδιαίτερης αρχιτεκτονικής τους

που περιέχει βρόχους, τα RNNs επιτρέπουν στις πληροφορίες να διατηρούνται και να χρησιμοποιούνται στην επεξεργασία μελλοντικών εισόδων. Έτσι, μπορούν να συλλαμβάνουν μοτίβα και εξαρτήσεις στις ακολουθίες, με συνέπεια να είναι αποτελεσματικά για εφαρμογές, όπως η ανάλυση χρονοσειρών και η μοντελοποίηση γλωσσών.

- **BPNN (Backpropagation Neural Network):** Το BPNN αναφέρεται στα νευρωνικά δίκτυα που εκπαιδεύονται με τον αλγόριθμο της προς τα πίσω διάδοσης σφάλματος. Αυτός είναι ένας αλγόριθμος βελτιστοποίησης, που χρησιμοποιείται για την προσαρμογή των βαρών του δικτύου με βάση το σφάλμα μεταξύ των προβλεπόμενων και των πραγματικών εξόδων.
- **GRNN (General Regression Neural Network):** Το GRNN είναι ένας τύπος νευρωνικού δικτύου που ειδικεύεται σε εργασίες παλινδρόμησης. Η εκπαίδευση του μοντέλου περιλαμβάνει την αποθήκευση προτύπων με την μορφή συναρτήσεων ακτινικής βάσης (RBF), που αντιπροσωπεύουν τα δεδομένα εκπαίδευσης. Κατά την διάρκεια της πρόβλεψης, το δίκτυο υπολογίζει την απόσταση μεταξύ των δεδομένων εισόδου και των αποθηκευμένων μοτίβων, χρησιμοποιώντας αυτές τις πληροφορίες για να κάνει προβλέψεις. Τα GRNN είναι γνωστά για την γρήγορη εκπαίδευση και τις αποτελεσματικές δυνατότητες γενίκευσης.
- **ANFIS (Adaptive Neuro-Fuzzy Inference System):** Το ANFIS είναι ένα υβριδικό σύστημα που συνδυάζει νευρωνικά δίκτυα και ασαφή λογική. Χρησιμοποιείται για την μοντελοποίηση πολύπλοκων συστημάτων και την προσέγγιση μη γραμμικών συναρτήσεων.
- **CNN (Convolutional Neural Network):** Το CNN είναι ένας τύπος νευρωνικού δικτύου που έχει σχεδιαστεί για να επεξεργάζεται δεδομένα που μοιάζουν με πλέγμα, όπως εικόνες και βίντεο. Χρησιμοποιεί στρώματα για την αυτόματη εκμάθηση χωρικών χαρακτηριστικών και χρησιμοποιείται ευρέως σε εργασίες όρασης υπολογιστών.
- **LSTM (Long Short-Term Memory):** Το LSTM είναι ένας τύπος RNN με ειδικά κύτταρα μνήμης που του επιτρέπουν να θυμάται και να μαθαίνει μακροχρόνιες εξαρτήσεις σε διαδοχικά δεδομένα. Το LSTM χρησιμοποιείται συνήθως σε εργασίες, όπως η επεξεργασία φυσικής γλώσσας, η αναγνώριση ομιλίας και η πρόβλεψη [14] και αποτελεί αντικείμενο της παρούσας διπλωματικής εργασίας.
- **GAN (Generative Adversarial Network):** Το GAN είναι ένας τύπος αρχιτεκτονικής νευρωνικού δικτύου που αποτελείται από δύο δίκτυα, έναν γεννήτορα και έναν διαχωριστή, τα οποία εκπαιδεύονται μαζί. Τα GAN χρησιμοποιούνται για εργασίες, όπως η παραγωγή ρεαλιστικών εικόνων και η σύνθεση δεδομένων.

Ανάλογα με τις απαιτήσεις του προβλήματος που εμφανίζεται κάθε φορά και την φύση των δεδομένων, επιλέγεται ο κατάλληλος τύπος ANN. Δηλαδή, κάθε μορφή ANN είναι προσαρμοσμένη για την αντιμετώπιση συγκεκριμένων προκλήσεων σε διαφορετικές εφαρμογές και τομείς.

2.4.5 Εξέλιξη των Τεχνητών Νευρωνικών Δικτύων στη Σημερινή τους Μορφή

Η πρώτη εφαρμογή των ANNs χρονολογείται στις δεκαετίες του 1950 και του 1960. Η ιδέα των νευρωνικών δικτύων εμπνεύστηκε από την δομή και την λειτουργία του ανθρώπινου εγκεφάλου, με στόχο την ανάπτυξη υπολογιστικών μοντέλων που θα μπορούσαν να μιμηθούν

την ικανότητα του εγκεφάλου να επεξεργάζεται πληροφορίες και να μαθαίνει από δεδομένα [18], [31].

Οι πρώτες εργασίες για τα ANNs μπορούν να εντοπιστούν στο έργο του νευροφυσιολόγου Warren McCulloch και του μαθηματικού Walter Pitts το 1943. Πρότειναν ένα απλό υπολογιστικό μοντέλο που ονομάστηκε "λογική μονάδα καταωφλίου", το οποίο αποτέλεσε την βάση για τους τεχνητούς νευρώνες στα σύγχρονα νευρωνικά δίκτυα.

Στα τέλη της δεκαετίας του 1950, ο Frank Rosenblatt ανέπτυξε το "Perceptron", ένα από τα πρώτα νευρωνικά δίκτυα ενός στρώματος, ικανό να μαθαίνει και να λαμβάνει δυαδικές αποφάσεις. Το Perceptron ήταν μια σημαντική ανακάλυψη, αλλά οι περιορισμοί του στον χειρισμό πολύπλοκων προβλημάτων με μη γραμμικά όρια αποφάσεων οδήγησαν σε μια περίοδο απογοήτευσης γνωστή ως "χειμώνας της τεχνητής νοημοσύνης" [27].

Η αναζωπύρωση του ενδιαφέροντος για τα νευρωνικά δίκτυα ήρθε την δεκαετία του 1980 με την ανάπτυξη του αλγορίθμου "backpropagation" (προς τα πίσω διάδοση του σφάλματος), ο οποίος επέτρεψε την αποτελεσματική εκπαίδευση νευρωνικών δικτύων πολλαπλών επιπέδων. Ο αλγόριθμος αυτός είναι μια μορφή επιβλεπόμενης μάθησης, που προσαρμόζει τα βάρη του δικτύου, ώστε να ελαχιστοποιήσει την διαφορά μεταξύ των προβλεπόμενων και των πραγματικών εξόδων [27]. Αυτή η ανακάλυψη επέτρεψε την εκπαίδευση βαθιών νευρωνικών δικτύων και έθεσε τις βάσεις για την ανάπτυξη των σύγχρονων Τεχνητών Νευρωνικών Δικτύων.

Στην δεκαετία του 1990 και στις αρχές της δεκαετίας του 2000, η έρευνα για τα ANNs συνέχισε να προχωρά, αλλά η πρόοδος περιορίστηκε από την υπολογιστική ισχύ και τη διαθεσιμότητα συνόλων δεδομένων μεγάλης κλίμακας. Κατά την διάρκεια αυτής της περιόδου, άλλοι αλγόριθμοι Μηχανικής Μάθησης, όπως οι Μηχανές Διανυσμάτων Υποστήριξης (SVM), απέκτησαν δημοτικότητα.

Η πραγματική επανάσταση για τα ANNs ήρθε την δεκαετία του 2010 με την έλευση των μεγάλων δεδομένων και των ισχυρών μονάδων επεξεργασίας γραφικών (GPU) που επιτάχυναν τις διαδικασίες εκπαίδευσης. Αυτό οδήγησε στην άνοδο της Βαθιάς Μάθησης, ενός υποπεδίου της Μηχανικής Μάθησης, που επικεντρώνεται στην εκπαίδευση Βαθιών Νευρωνικών Δικτύων με πολλά επίπεδα (Deep Neural Networks ή DNNs). Τα Μοντέλα Βαθιάς Μάθησης, ιδίως τα Νευρωνικά Δίκτυα Συνελκτικής Μάθησης (Convolutional Neural Networks - CNNs) και τα Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks - RNNs), επέδειξαν αξιοσημείωτες επιδόσεις σε εργασίες, όπως η αναγνώριση εικόνων και η επεξεργασία φυσικής γλώσσας [26], [27].

Τα τελευταία χρόνια, οι εξελίξεις στις αρχιτεκτονικές των ANNs, στις τεχνικές κανονικοποίησης, στους αλγόριθμους βελτιστοποίησης και στο υλικό οδήγησαν στην ευρεία υιοθέτησή τους σε διάφορους τομείς, όπως η όραση υπολογιστών, η επεξεργασία φυσικής γλώσσας, τα αυτόνομα οχήματα, η υγειονομική περίθαλψη και η χρηματοοικονομική.

Σήμερα, τα ANNs βρίσκονται στην πρώτη γραμμή της έρευνας και των εφαρμογών Τεχνητής Νοημοσύνης, διαδραματίζοντας καθοριστικό ρόλο στην επίλυση πολύπλοκων προβλημάτων και στην λήψη αποφάσεων με βάση τα διαθέσιμα δεδομένα. Ο τομέας των ANNs συνεχίζει να εξελίσσεται ραγδαία, με γνώμονα την συνεχή έρευνα και τις καινοτομίες, καθιστώντας τον ακρογωνιαίο λίθο της σύγχρονης Μηχανικής Μάθησης και της Τεχνητής Νοημοσύνης.

2.4.6 Εφαρμογές Τεχνητών Νευρωνικών Δικτύων

Τα Τεχνητά Νευρωνικά Δίκτυα ύστερα από χρόνια έρευνας και εξέλιξης που αναπτύχθηκε στην Ενότητα 2.4.5, έχουν φτάσει σε ένα σημείο να έχουν πολυάριθμες εφαρμογές σε διάφορους τομείς, λόγω της ικανότητάς τους να μαθαίνουν από δεδομένα, να κάνουν προβλέψεις ή να λαμβάνουν αποφάσεις με βάση πρότυπα και σχέσεις. Με την πάροδο των ετών εξελίσσονται, με αποτέλεσμα οι εφαρμογές τους να υπεισέρχονται σε ένα ακόμα ευρύτερο φάσμα δυνατοτήτων. Μερικές από τις πιο σημαντικές εφαρμογές τους είναι οι ακόλουθες [32], [33]:

- Αναγνώριση εικόνας και ομιλίας: Τα ANNs χρησιμοποιούνται ευρέως σε εργασίες αναγνώρισης εικόνας και ομιλίας. Ιδιαίτερα τα Συνελκτικά Νευρωνικά Δίκτυα (CNNs) έχουν φέρει επανάσταση στην αναγνώριση εικόνων, επιτυγχάνοντας κορυφαία αποτελέσματα στην ταξινόμηση εικόνων, την ανίχνευση αντικειμένων και την κατάτμηση. Τα αναδρομικά νευρωνικά δίκτυα (RNNs) χρησιμοποιούνται στην αναγνώριση ομιλίας για εργασίες, όπως η μετατροπή ομιλίας σε κείμενο.
- Επεξεργασία φυσικής γλώσσας (NLP): Τα ANNs διαδραματίζουν σημαντικό ρόλο σε εφαρμογές NLP, όπως η μηχανική μετάφραση, η ανάλυση συναισθήματος και η παραγωγή κειμένου. Τα RNNs και τα μοντέλα που βασίζονται σε μετασχηματιστές (όπως το BERT) χρησιμοποιούνται συνήθως για εργασίες NLP.
- Αυτόνομα οχήματα: Τα ANNs χρησιμοποιούνται σε αυτοκινούμενα αυτοκίνητα και αυτόνομα οχήματα για την ερμηνεία δεδομένων αισθητήρων, την αναγνώριση αντικειμένων και την λήψη αποφάσεων σε πραγματικό χρόνο για την ασφαλή πλοήγηση στους δρόμους.
- Υγειονομική περίθαλψη και ιατρική: Τα ANNs χρησιμοποιούνται για την διάγνωση ασθενειών, την ανάλυση ιατρικών απεικονίσεων (π.χ. ερμηνεία μαγνητικών τομογραφιών και αξονικών τομογραφιών), την ανακάλυψη φαρμάκων και την εξατομικευμένη ιατρική covid [29].
- Χρηματοοικονομική ανάλυση και διαπραγμάτευση: Τα ANNs χρησιμοποιούνται για την πρόβλεψη των τιμών των μετοχών, την πρόβλεψη των τάσεων της χρηματοπιστωτικής αγοράς, την αξιολόγηση του πιστωτικού κινδύνου και την ανίχνευση απάτης στον τραπεζικό και χρηματοπιστωτικό τομέα.
- Διαχείριση πελατειακών σχέσεων (CRM): Τα ANNs εφαρμόζονται στην πρόβλεψη της αποχώρησης πελατών, στην ομαδοποίηση πελατών και στο εξατομικευμένο μάρκετινγκ.
- Ρομποτική: Τα ANNs χρησιμοποιούνται σε συστήματα ελέγχου ρομπότ, αναγνώρισης αντικειμένων και πλοήγησης για διάφορες ρομποτικές εφαρμογές.
- Παιχνίδια και ψυχαγωγία: Τα ANNs χρησιμοποιούνται στην Τεχνητή Νοημοσύνη παιχνιδιών, στην μοντελοποίηση της συμπεριφοράς χαρακτήρων και στην δημιουργία ρεαλιστικών γραφικών και κινούμενων σχεδίων.
- Συστήματα συστάσεων: Τα ANNs χρησιμοποιούνται σε μηχανές συστάσεων, οι οποίες προτείνουν προϊόντα, ταινίες, μουσική ή περιεχόμενο με βάση τις προτιμήσεις και την συμπεριφορά του χρήστη.
- Παρακολούθηση περιβάλλοντος και πρόβλεψη: Τα ANNs εφαρμόζονται για την πρόβλεψη των καιρικών συνθηκών, της ποιότητας του αέρα και άλλων περιβαλλοντικών παραγόντων, για την περιβαλλοντική παρακολούθηση και την μοντελοποίηση του κλίματος.

- Διαδίκτυο των πραγμάτων (IoT-Internet of Things): Τα ANNs χρησιμοποιούνται σε εφαρμογές IoT για την ανάλυση δεδομένων αισθητήρων, την προληπτική συντήρηση και την ανίχνευση ανωμαλιών [28].
- Βιομηχανικός αυτοματισμός: Τα ANNs χρησιμοποιούνται στην βελτιστοποίηση διαδικασιών, στην ανίχνευση σφαλμάτων και στον έλεγχο ποιότητας σε βιομηχανικές και κατασκευαστικές εγκαταστάσεις.
- Σχεδιασμός και ανακάλυψη φαρμάκων: Τα ANNs χρησιμοποιούνται στην υπολογιστική ανακάλυψη φαρμάκων για την πρόβλεψη μοριακών ιδιοτήτων και τον εντοπισμό πιθανών υποψηφίων φαρμάκων.

Αυτά είναι μερικά μόνο από τα πιο βασικά παραδείγματα των ποικίλων εφαρμογών των ANNs. Καθώς ο τομέας της Τεχνητής Νοημοσύνης συνεχίζει να εξελίσσεται, τα ANNs αναμένεται να βρουν ακόμη περισσότερες εφαρμογές στην επίλυση πολύπλοκων προβλημάτων.

2.4.7 Εφαρμογές Τεχνητών Νευρωνικών Δικτύων στην Ηλιακή Πρόβλεψη

Τα Τεχνητά Νευρωνικά Δίκτυα έχουν εφαρμοστεί ευρέως στην πρόβλεψη και στην πρόγνωση της ηλιακής ενέργειας λόγω της ικανότητάς τους να μοντελοποιούν πολύπλοκες σχέσεις σε δεδομένα χρονοσειρών. Οι προβλέψεις για την ηλιακή ενέργεια είναι απαραίτητες για την αποτελεσματική χρήση της ηλιακής ενέργειας, την ενσωμάτωση στο δίκτυο και την λήψη αποφάσεων στον τομέα των ανανεώσιμων πηγών ενέργειας [27]. Ορισμένες βασικές εφαρμογές των ANNs στις προβλέψεις ηλιακής ενέργειας είναι:

- Πρόβλεψη παραγωγής ηλιακής ενέργειας: Τα ANNs χρησιμοποιούνται για την πρόβλεψη της παραγωγής ηλιακής ενέργειας από φωτοβολταϊκά πλαίσια, με βάση παράγοντες, όπως οι καιρικές συνθήκες και η ιστορική ηλιακή παραγωγή. Οι προβλέψεις αυτές βοηθούν τους διαχειριστές του δικτύου και τους παρόχους ενέργειας να σχεδιάζουν και να διαχειρίζονται την ενσωμάτωση της ηλιακής ενέργειας στο δίκτυο, εξασφαλίζοντας σταθερή και αξιόπιστη παροχή ενέργειας.
- Πρόβλεψη της ηλιακής ακτινοβολίας και του ηλιακού φωτός: Τα ANNs χρησιμοποιούνται για την πρόβλεψη της ηλιακής ακτινοβολίας και των επιπέδων ηλιακού φωτός σε συγκεκριμένες τοποθεσίες και σε διαφορετικά χρονικά διαστήματα. Οι ακριβείς προβλέψεις της ηλιακής ακτινοβολίας είναι ζωτικής σημασίας για την βελτιστοποίηση της απόδοσης των ηλιακών σταθμών παραγωγής ενέργειας και την μεγιστοποίηση της παραγωγής ενέργειας.
- Πρόβλεψη φορτίου για την ενσωμάτωση της ηλιακής ενέργειας: Τα ANNs μπορούν να χρησιμοποιηθούν για την πρόβλεψη της ζήτησης ηλεκτρικής ενέργειας και των προτύπων φορτίου, λαμβάνοντας υπόψη τον αντίκτυπο των διακυμάνσεων της ηλιακής ενέργειας. Αυτό επιτρέπει την καλύτερη εξισορρόπηση του φορτίου και την βελτιστοποίηση των συστημάτων αποθήκευσης ενέργειας κατά την ενσωμάτωση της ηλιακής ενέργειας στο δίκτυο.
- Παρακολούθηση της απόδοσης των ηλιακών πάνελ: Τα ANNs χρησιμοποιούνται για την πρόβλεψη της απόδοσης των ηλιακών συλλεκτών με βάση ιστορικά δεδομένα και περιβαλλοντικούς παράγοντες. Οι προβλέψεις αυτές βοηθούν στον εντοπισμό πιθανών προβλημάτων συντήρησης και διασφαλίζουν την βέλτιστη απόδοση των ηλιακών εγκαταστάσεων.

- Χαρτογράφηση του δυναμικού ηλιακής ενέργειας: Τα ANNs εφαρμόζονται για την αξιολόγηση του δυναμικού ηλιακής ενέργειας διαφόρων γεωγραφικών περιοχών. Με την ανάλυση των ιστορικών μετεωρολογικών δεδομένων και των επιπέδων ηλιακής ακτινοβολίας, τα ANNs μπορούν να εκτιμήσουν την καταλληλότητα και την σκοπιμότητα ανάπτυξης ηλιακών εγκαταστάσεων σε συγκεκριμένες περιοχές.
- Βραχυπρόθεσμες και μακροπρόθεσμες προβλέψεις ηλιακής ενέργειας: Τα ANNs μπορούν να παρέχουν βραχυπρόθεσμες (ώρες έως ημέρες) και μακροπρόθεσμες (εβδομάδες έως μήνες) προβλέψεις ηλιακής ισχύος. Αυτές οι προβλέψεις είναι ζωτικής σημασίας για τον ενεργειακό σχεδιασμό, την διαχείριση του δικτύου και τον καθορισμό στόχων για τις ανανεώσιμες πηγές ενέργειας.
- Εμπορία ηλιακής ενέργειας και ανάλυση αγοράς: Τα ANNs μπορούν να βοηθήσουν στην πρόβλεψη των τιμών της ηλιακής ενέργειας και των τάσεων της αγοράς. Οι έμποροι ενέργειας και οι επενδυτές μπορούν να χρησιμοποιήσουν αυτές τις προβλέψεις για να λάβουν τεκμηριωμένες αποφάσεις σχετικά με την αγορά και την πώληση ηλιακής ενέργειας.
- Βελτιστοποίηση μικροδικτύων: Τα ANNs μπορούν να βελτιστοποιήσουν την λειτουργία των μικροδικτύων που λειτουργούν με ηλιακή ενέργεια, προβλέποντας την παραγωγή, την ζήτηση και τις απαιτήσεις αποθήκευσης ηλιακής ενέργειας. Αυτό συμβάλλει στην επίτευξη ενεργειακής αυτόαρκειας και στην μείωση της εξάρτησης από το κύριο δίκτυο.
- Πρόβλεψη νεφοκάλυψης και καιρικών προτύπων που επηρεάζουν άμεσα την παραγωγή ηλιακής ενέργειας. Οι ακριβείς προβλέψεις για την νεφοκάλυψη επιτρέπουν στους φορείς εκμετάλλευσης ηλιακής ενέργειας να προσαρμόζουν ανάλογα τις δραστηριότητές τους.

Συμπερασματικά, τα ANNs προσφέρουν ισχυρά εργαλεία για ακριβείς προβλέψεις της ηλιακής ενέργειας και ισχύος, επιτρέποντας καλύτερο σχεδιασμό στη διαχείριση και ενσωμάτωση της ηλιακής ενέργειας στο ενεργειακό τοπίο. Καθώς ο τομέας της Τεχνητής Νοημοσύνης και της Μηχανικής Μάθησης συνεχίζει να εξελίσσεται, τα μοντέλα ANNs είναι πιθανό να γίνουν ακόμη πιο εξελιγμένα και αξιόπιστα, ενισχύοντας περαιτέρω την αποτελεσματικότητα των προβλέψεων για την ηλιακή ενέργεια. Στην παρούσα διπλωματική εργασία στόχος είναι η πρόβλεψη της ηλιακής ισχύος των φωτοβολταϊκών πάνελ που αποτελεί μια από τις πιο σημαντικές εφαρμογές.

ΑΛΓΟΡΙΘΜΟΙ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΚΑΙ ΜΕΘΟΔΟΙ ΒΕΛΤΙΩΣΗΣ ΤΟΥΣ

3.1 ΓΕΝΙΚΑ

Στο Κεφάλαιο 2 αναπτύχθηκε το ζήτημα της Μηχανικής Μάθησης και συγκεκριμένα των Τεχνητών Νευρωνικών Δικτύων και η συνεισφορά και αξία τους στην πρόβλεψη της ηλιακής ισχύος. Σε αυτό το κεφάλαιο θα παρουσιαστεί το βασικό μοντέλο-αλγόριθμος που αποτελεί κύριο εργαλείο της παρούσας εργασίας και στην συνέχεια θα προταθεί μια αποτελεσματική μέθοδος βελτίωσής του.

3.2 ΑΛΓΟΡΙΘΜΟΣ LSTM

Ο αλγόριθμος που θα μελετηθεί στο κεφάλαιο αυτό είναι ο LSTM, που αποτελεί υποκατηγορία των Τεχνητών Νευρωνικών Δικτύων. Συγκεκριμένα θα γίνει μια παρουσίαση των βασικών στοιχείων του μοντέλου, της δομής και των παραμέτρων του, ενώ στην συνέχεια θα επεξηγηθούν οι δύο μορφές του, δηλαδή το μονομεταβλητό και πολυμεταβλητό μοντέλο. Επίσης θα παρουσιαστεί το μοντέλο ARIMA, το οποίο θα χρησιμοποιηθεί, για να βελτιωθεί η ακρίβεια πρόβλεψης και κατά επέκταση η απόδοση του LSTM.

3.2.1 Γενικά Στοιχεία

Ο αλγόριθμος LSTM (Long Short-Term Memory) είναι ένας τύπος αρχιτεκτονικής Αναδρομικού Νευρωνικού Δικτύου (RNN), που έχει σχεδιαστεί για να καταγράφει εξαρτήσεις και μοτίβα μεγάλης εμβέλειας σε διαδοχικά δεδομένα. Εισήχθη για να ξεπεραστούν οι περιορισμοί των παραδοσιακών RNNs, τα οποία δυσκολεύονται να μάθουν και να διατηρήσουν πληροφορίες σε μεγάλες ακολουθίες λόγω του προβλήματος της εξαφανιζόμενης κλίσης [13], [14].

Τα δίκτυα LSTM είναι ιδιαίτερα κατάλληλα για εργασίες που αφορούν δεδομένα χρονοσειρών, όπως η επεξεργασία φυσικής γλώσσας και η αναγνώριση ομιλίας. Μερικές από τις πιο σημαντικές εφαρμογές των LSTM είναι [34]–[37]:

- Προβλέψεις Χρονοσειρών: Τα LSTM μπορούν να συλλάβουν πολύπλοκα χρονικά μοτίβα σε δεδομένα χρονοσειρών, καθιστώντας τα αποτελεσματικά για εργασίες, όπως η πρόβλεψη τιμών μετοχών, η πρόβλεψη καιρού και η πρόβλεψη της ζήτησης ενέργειας.
- Επεξεργασία φυσικής γλώσσας (NLP): Τα LSTM υπερέχουν στην μοντελοποίηση γλώσσας, την μηχανική μετάφραση, την ανάλυση συναισθήματος και την δημιουργία κειμένου, καθώς μπορούν να συλλάβουν εξαρτήσεις μεταξύ λέξεων και φράσεων.

- Αναγνώριση ομιλίας: Τα LSTM χρησιμοποιούνται σε συστήματα αναγνώρισης ομιλίας για την μοντελοποίηση διαδοχικών εξαρτήσεων σε δεδομένα ήχου, επιτρέποντας την ακριβή μετατροπή προφορικών λέξεων σε κείμενο.
- Ανάλυση βίντεο: Τα LSTM μπορούν να αναλύσουν ακολουθίες βίντεο για εργασίες όπως η αναγνώριση ενεργειών, οι λεζάντες βίντεο και ο εντοπισμός αντικειμένων.
- Αναγνώριση χειρονομιών: Τα LSTM μπορούν να αναγνωρίζουν χειρονομίες και ενέργειες από δεδομένα καταγραφής κίνησης, επιτρέποντας εφαρμογές στην αλληλεπίδραση ανθρώπου-υπολογιστή και την εικονική πραγματικότητα.

Γενικά, τα LSTM έχουν βελτιώσει σημαντικά τις δυνατότητες των εργασιών μάθησης που βασίζονται σε ακολουθίες, επιτρέποντας στα μοντέλα να διατηρούν σχετικές πληροφορίες σε μεγάλες ακολουθίες. Η αποτελεσματικότητα και η ευελιξία τους έχουν συμβάλει στην ευρεία υιοθέτησή τους σε διάφορους τομείς της Τεχνητής Νοημοσύνης και της Μηχανικής Μάθησης.


3.2.2 Δομή του Μοντέλου LSTM

Το LSTM είναι ουσιαστικά ένα Αναδρομικό Νευρωνικό Δίκτυο (RNN) που αποτελείται από μονάδες-στρώματα που συνδέονται μεταξύ τους. Κάθε μονάδα περιέχει πληροφορίες σχετικά με την προηγούμενη κατάσταση.

Τα δίκτυα αυτά αποτελούνται από πύλες, οι οποίες περιέχουν πληροφορίες σχετικά με την προηγούμενη κατάσταση. Αυτές οι πληροφορίες είτε καταγράφονται, είτε αποθηκεύονται, είτε απλώς διαβάζονται από ένα «κύτταρο (cell) – τμήμα του δικτύου» που δρα ως μνήμη. Αυτό το κύτταρο αποφασίζει αν θα αποθηκεύσει ή θα διαγράψει την πληροφορία κατά το άνοιγμα και κλείσιμο των πυλών [13], [14].

Ουσιαστικά δρουν με βάση τα σήματα που δέχονται και με τον τρόπο αυτό είτε μπλοκάρουν την πληροφορία, είτε την αφήνουν να περάσει.

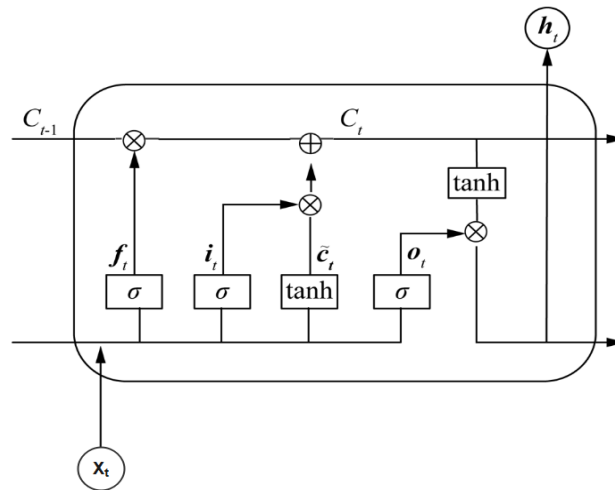
Το LSTM (Long-Short Memory System) αποτελείται από ένα στρώμα εισόδου (input layer), ένα ή περισσότερα κρυφά στρώματα (hidden layers) και ένα στρώμα εξόδου (output layer).



Σχήμα 3.1: Τυπική μορφή δομής LSTM με ενδιάμεσο κρυφό στρώμα

Η δομή του LSTM παρουσιάζεται στα σχήματα 3.1 και 3.2 και επεξηγείται διεξοδικά με έμφαση ξεχωριστά σε κάθε τμήμα, που αποτελεί συστατικό δομικό στοιχείο του μοντέλου:

- **Κατάσταση κυττάρου (cell state):** Το βασικό συστατικό ενός LSTM είναι η κατάσταση των κελιών του. Η κατάσταση κυττάρου διατρέπει ολόκληρη την ακολουθία δεδομένων, με ορισμένες λειτουργίες που βοηθούν το LSTM είτε να διατηρήσει, είτε να «ξεχάσει» πληροφορίες. Λειτουργεί ως μάντα μεταφοράς για να περάσει τις σχετικές πληροφορίες μέσα από τα χρονικά βήματα.
- **Πύλες (Gates):** Το βασικό κύτταρο LSTM χρησιμοποιεί τρεις πύλες για τον έλεγχο της ροής των πληροφοριών: την πύλη λήθης, την πύλη εισόδου και την πύλη εξόδου. Αυτές οι πύλες καθορίζουν ποιες πληροφορίες θα πρέπει να μεταβιβαστούν, να προστεθούν ή να αφαιρεθούν από την κατάσταση του κυττάρου.
 - **Πύλη λήθης (forget gate):** Αυτή η πύλη αποφασίζει ποιες πληροφορίες θα απορριφθούν από την κατάσταση του κυττάρου. Λαμβάνει την προηγούμενη κατάσταση κυττάρου και την τρέχουσα είσοδο και εξάγει μια τιμή μεταξύ 0 και 1 για κάθε στοιχείο στην κατάσταση κυττάρου. Η τιμή 0 σημαίνει "απόρριψη", ενώ η τιμή 1 σημαίνει "διατήρηση" της πληροφορίας.
 - **Πύλη εισόδου (input gate):** Η πύλη εισόδου αποφασίζει ποιες τιμές θα ενημερωθούν στην κατάσταση κυττάρου, υπολογίζοντας ποιες νέες πληροφορίες πρέπει να προστεθούν. Αποτελείται από δύο μέρη: ένα σιγμοειδές στρώμα, που καθορίζει ποιες τιμές πρέπει να ενημερωθούν και ένα στρώμα tanh που δημιουργεί ένα διάνυσμα νέων υποψήφιων τιμών.
 - **Πύλη εξόδου (output gate):** Η πύλη εξόδου καθορίζει ποια πρέπει να είναι η επόμενη κρυφή κατάσταση. Βασίζεται στην κατάσταση του κυττάρου, αλλά είναι μια φιλτραρισμένη έκδοση. Αποφασίζει ποια μέρη της κατάστασης του κυττάρου θα πρέπει να εξάγονται ως πραγματική πρόβλεψη.
- **Κρυφά στρώματα (hidden layers):** Το κρυφό στρώμα είναι η έξοδος του LSTM σε κάθε χρονικό βήμα. Επηρεάζεται από την τρέχουσα είσοδο και την προηγούμενη κρυφή κατάσταση. Συλλαμβάνει τις σχετικές πληροφορίες από την τρέχουσα είσοδο και από προηγούμενα χρονικά βήματα.
- **Κατάσταση υποψήφιου κυττάρου (candidate cell state):** Είναι μια ενδιάμεση τιμή που υπολογίζεται προκειμένου να ενημερωθεί η κατάσταση του κυττάρου με νέες πληροφορίες. Δημιουργείται με βάση την τρέχουσα είσοδο, αλλά και την προηγούμενη κρυφή κατάσταση του LSTM και αντιπροσωπεύει τις πιθανές νέες πληροφορίες που θα μπορούσαν να προστεθούν στην κατάσταση κυττάρου. Η κατάσταση του υποψήφιου κυττάρου συνδυάζεται στην συνέχεια με τις πληροφορίες που επιλέγονται από την πύλη εισόδου για την ενημέρωση της κατάστασης του κυττάρου. Αυτός ο μηχανισμός επιτρέπει στο LSTM να ενσωματώνει επιλεκτικά νέες πληροφορίες, λαμβάνοντας υπόψη την συνάφεια της εισόδου και το ιστορικό πλαίσιο, καθιστώντας το αποτελεσματικό για την σύλληψη μακροχρόνιων εξαρτήσεων σε διαδοχικά δεδομένα.



Σχήμα 3.2: Πύλες ροής πληροφοριών LSTM

Κάθε νευρωνικό δίκτυο LSTM περιλαμβάνει ορισμένες παραμέτρους και υπερπαραμέτρους που διέπουν την λειτουργία του και επηρεάζουν την απόδοσή του. Στις Ενότητες 3.2.3 και 3.2.4 αναπτύσσονται διεξοδικά αυτές οι παράμετροι και υπερπαραμέτροι.

3.2.3 Παράμετροι του Μοντέλου LSTM

Οι παράμετροι είναι οι τιμές που μαθαίνει το μοντέλο κατά την διαδικασία εκπαίδευσης. Ενημερώνονται επαναληπτικά μέσω αλγορίθμων βελτιστοποίησης, όπως η κάθοδος κλίσης για την ελαχιστοποίηση της συνάρτησης απώλειας. Για ένα LSTM, οι κύριες παράμετροι περιλαμβάνουν [14], [38]:

- Βάρη (weights): Τα βάρη ελέγχουν την ροή των πληροφοριών εντός της αρχιτεκτονικής LSTM. Το βάρος είναι ουσιαστικά η παράμετρος, που μετασχηματίζει τα δεδομένα εισόδου στα κρυφά στρώματα του δικτύου. Ένα νευρωνικό δίκτυο είναι μια σειρά από κόμβους ή νευρώνες. Μέσα σε κάθε κόμβο υπάρχει ένα σύνολο εισόδων, μία τιμή βάρους και μια τιμή πόλωσης (bias). Καθώς μια είσοδος εισέρχεται στον κόμβο, πολλαπλασιάζεται με μια τιμή βάρους και η προκύπτουσα έξοδος είτε παρατηρείται, είτε μεταβιβάζεται στο επόμενο επίπεδο του νευρωνικού δικτύου. Συχνά τα βάρη ενός νευρωνικού δικτύου περιέχονται στα κρυφά στρώματα του δικτύου.
- Πολώσεις (biases): Οι πολώσεις προστίθενται στις σταθμισμένες εισόδους προτού αυτές περάσουν από τις συναρτήσεις ενεργοποίησης. Βοηθούν στην μετατόπιση της συνάρτησης ενεργοποίησης και επιτρέπουν στο μοντέλο να μαθαίνει συγκεκριμένα μοτίβα.

Στο σημείο αυτό γίνεται σαφής επισκόπηση των διαφορών των δύο παραμέτρων και της συνεισφοράς κάθε μιας από αυτές συγκριτικά. Τα βάρη και οι πολώσεις είναι και οι δύο παράμετροι μέσα στο δίκτυο.

Ένα νευρωνικό δίκτυο θα θέσει τυχαίες τιμές τόσο στο βάρος, όσο και στην πόλωση πριν αρχίσει η εκπαίδευση του μοντέλου. Καθώς η εκπαίδευση συνεχίζεται, οι δύο παράμετροι προσαρμόζονται προς τις επιθυμητές τιμές και την σωστή έξοδο. Τα βάρη και οι πολώσεις διαφέρουν ως προς την έκταση της επιρροής τους στα δεδομένα εισόδου. Ουσιαστικά, η πόλωση αντιπροσωπεύει το πόσο απέχουν οι προβλέψεις από την αναμενόμενη τιμή τους.

Οι πολώσεις συνθέτουν την διαφορά μεταξύ της εξόδου, της συνάρτησης και της προβλεπόμενης εξόδου. Μια χαμηλή πόλωση υποδηλώνει ότι το δίκτυο κάνει περισσότερες υποθέσεις σχετικά με την μορφή της εξόδου, ενώ μια υψηλή τιμή πόλωσης υποδηλώνει πως γίνονται λιγότερες υποθέσεις σχετικά με την μορφή της εξόδου.

Από την άλλη πλευρά, τα βάρη μπορούν να θεωρηθούν ως η ισχύς της σύνδεσης. Το βάρος επηρεάζει το μέγεθος της επιρροής που θα έχει στην έξοδο, μια αλλαγή στην είσοδο. Μια χαμηλή τιμή βάρους δεν θα έχει καμία αλλαγή στην έξοδο, ενώ μια μεγαλύτερη τιμή βάρους θα αλλάξει σημαντικά την έξοδο.

3.2.4 Υπερπαράμετροι του Μοντέλου LSTM

Οι υπερπαράμετροι είναι οι ρυθμίσεις και οι διαμορφώσεις που ορίζονται πριν από την εκπαίδευση του μοντέλου. Δεν ορίζονται κατά την διάρκεια της εκπαίδευσης, αλλά επιλέγονται από τον χρήστη και μπορούν να επηρεάσουν σημαντικά την συμπεριφορά και την απόδοση του μοντέλου [39]. Οι συνήθεις υπερπαράμετροι του LSTM περιλαμβάνουν τα εξής:

- Αριθμός μονάδων LSTM (LSTM units): Αυτό καθορίζει το μέγεθος των διανυσμάτων της κρυφής κατάστασης και της κατάστασης των κελιών. Ένας μεγαλύτερος αριθμός μονάδων μπορεί να συλλάβει πιο σύνθετα μοτίβα, αλλά απαιτεί επίσης περισσότερους υπολογισμούς.
- Αριθμός επιπέδων (number of LSTM layers): Τα LSTM μπορούν να στοιβάζονται σε πολλαπλά στρώματα για την σύλληψη ιεραρχικών χαρακτηριστικών. Η προσθήκη περισσότερων στρωμάτων μπορεί να αυξήσει την ισχύ του μοντέλου, αλλά το καθιστά πιο πολύπλοκο και επιρρεπές στην υπερπροσαρμογή.
- Συναρτήσεις ενεργοποίησης (activation functions): Οι συναρτήσεις ενεργοποίησης που χρησιμοποιούνται στα κύτταρα LSTM, όπως η σιγμοειδής και η υπερβολική εφαπτομένη (tanh), καθορίζουν τον τρόπο με τον οποίο οι πληροφορίες ρέουν και μετασχηματίζονται εντός του κυττάρου.
- Ποσοστό εγκατάλειψης (Dropout rate): Είναι μια τεχνική κανονικοποίησης που απορρίπτει τυχαία ένα κλάσμα μονάδων (νευρώνων) κατά την διάρκεια της εκπαίδευσης, αποτρέποντας την υπερπροσαρμογή. Δηλαδή, αναφέρεται στο κλάσμα ή στο ποσοστό των νευρώνων, των οποίων οι έξοδοι αγνοούνται σκόπιμα ή "εγκαταλείπονται" κατά την διάρκεια της εκπαίδευσης, σε κάθε χρονικό βήμα. Αυτή η τεχνική βοηθά στην αποφυγή της υπερπροσαρμογής και ενθαρρύνει το μοντέλο να μάθει πιο ισχυρά και γενικευμένα χαρακτηριστικά.
- Ρυθμός μάθησης (learning rate): Ο ρυθμός μάθησης ελέγχει το μέγεθος του βήματος κατά την διάρκεια της βελτιστοποίησης. Επηρεάζει το πόσο γρήγορα το μοντέλο προσαρμόζει τις παραμέτρους του.
- Μέγεθος παρτίδας (batch size): Το μέγεθος παρτίδας καθορίζει τον αριθμό των δειγμάτων που χρησιμοποιούνται σε κάθε επανάληψη της εκπαίδευσης. Ένα μεγαλύτερο μέγεθος παρτίδας μπορεί να βελτιώσει την ταχύτητα εκπαίδευσης, αλλά μπορεί να απαιτεί περισσότερη μνήμη.
- Εποχές (number of epochs): Ο αριθμός των εποχών είναι ο αριθμός των φορών που το μοντέλο επαναλαμβάνει ολόκληρο το σύνολο δεδομένων εκπαίδευσης. Πολύ λίγες εποχές μπορούν να οδηγήσουν σε υποπροσαρμογή, ενώ πάρα πολλές εποχές μπορούν να οδηγήσουν σε υπερπροσαρμογή.

- Βελτιστοποιητής (optimizer): Ο αλγόριθμος βελτιστοποίησης, όπως ο Adam, ο RMSprop ή ο SGD, καθορίζει τον τρόπο με τον οποίο ενημερώνονται τα βάρη του μοντέλου, με βάση τις υπολογισμένες κλίσεις και τον ρυθμό μάθησης.
- Συνάρτηση απώλειας (loss function): Η συνάρτηση απώλειας μετρά την διαφορά μεταξύ των προβλεπόμενων και των πραγματικών τιμών. Καθοδηγεί την διαδικασία βελτιστοποίησης, υποδεικνύοντας πόσο καλά αποδίδει το μοντέλο.
- Μήκος ακολουθίας (sequence length): Το μήκος των ακολουθιών εισόδου που τροφοδοτούνται στο LSTM επηρεάζει την μνήμη και το πλαίσιο που μπορεί να συλλάβει το μοντέλο. Οι μακρύτερες ακολουθίες ενδέχεται να απαιτούν περισσότερη μνήμη και υπολογισμό.

Γενικά, η επιλογή των κατάλληλων υπερπαραμέτρων και η προσαρμογή τους μέσω πειραματισμού είναι απαραίτητη για την δημιουργία ενός αποτελεσματικού μοντέλου LSTM.

3.2.5 Ροή της Πληροφορίας σε κάθε Βαθμίδα LSTM

Η ροή της πληροφορίας σε ένα δίκτυο LSTM αφορά τον τρόπο και την κατεύθυνση που ρέει η πληροφορία αυτή, μέσω των αντίστοιχων πυλών που επεξηγήθηκαν στην Ενότητα 3.2.2. Κάθε πύλη επιτελεί μία συγκεκριμένη λειτουργία και διέπεται από μία μαθηματική εξίσωση.

Επομένως, οι πληροφορίες ρέουν μέσω μιας προσεκτικά σχεδιασμένης αρχιτεκτονικής για την καταγραφή σύνθετων μοτίβων και εξαρτήσεων σε διαδοχικά δεδομένα. Σε κάθε χρονικό βήμα, τα δεδομένα εισόδου συνδυάζονται πρώτα με την προηγούμενη κρυφή κατάσταση (hidden layer) για τον υπολογισμό της τιμής της πύλης λήθης (forget gate), η οποία αποφασίζει ποιες πληροφορίες θα απορριφθούν από την προηγούμενη κατάσταση του κυττάρου. Η πύλη εισόδου (input gate), επηρεαζόμενη από την τρέχουσα είσοδο και την προηγούμενη κρυφή κατάσταση, καθορίζει νέες υποψήφιες τιμές. Αυτές οι υποψήφιες τιμές συνδυάζονται με την έξοδο της πύλης εισόδου, για την ενημέρωση της κατάστασης του κυττάρου, καταγράφοντας τις σχετικές νέες πληροφορίες. Στην συνέχεια, η πύλη εξόδου (output gate) φιλτράρει την κατάσταση του κυττάρου, για να παράξει την επόμενη κρυφή κατάσταση, η οποία μπορεί να χρησιμοποιηθεί για προβλέψεις ή να περάσει στο επόμενο χρονικό βήμα [13], [14], [38].

Αυτός ο μηχανισμός πύλης επιτρέπει στα LSTM να διαχειρίζονται την ροή πληροφοριών διατηρώντας ή ενημερώνοντας επιλεκτικά τις πληροφορίες στην κατάσταση του κυττάρου. Έτσι, τα LSTM χειρίζονται αποτελεσματικά εξαρτήσεις μεγάλης εμβέλειας και διαδοχικά μοτίβα για εργασίες, όπως η πρόβλεψη χρονοσειρών και η παραγωγή κειμένου.

Στη συνέχεια, επεξηγείται η ροή αυτής της πληροφορίας μέσω των πυλών και αναπτύσσονται οι αντίστοιχες εξισώσεις που διέπουν τη λειτουργία τους. Η πληροφορία εισέρχεται στην forget gate που αποφασίζει ποια πληροφορία θα κρατήσει και ποια θα διαγράψει μέσω του κυττάρου C_t . Η συνάρτηση είναι η εξής [14]:

$$f_t = \sigma(W_f [h_{t-1}, x_t] + b_f) \quad (3.1)$$

Στην εξίσωση (3.1) σ είναι η συνάρτηση ενεργοποίησης, W_f το βάρος της πύλης λήθης, b_f ο όρος πόλωσης της πύλης λήθης, x_t η είσοδος την χρονική στιγμή t και h_{t-1} η έξοδος κρυφού στρώματος την χρονική στιγμή $t - 1$.

Στην συνέχεια, η πληροφορία που θα διατηρηθεί από την πύλη λήθης εισέρχεται στην πύλη εισόδου (input gate) και έπειτα περνά μέσα από την υποψήφια κατάσταση κυττάρου

(candidate cell state), που αποτελεί μέρος των εσωτερικών λειτουργιών του LSTM, για να καθοριστεί πόση και τι μορφής νέα πληροφορία θα πρέπει να προστεθεί στην κατάσταση του κυττάρου (cell state).

Ο υπολογισμός της υποψήφιας κατάστασης κυττάρου περιλαμβάνει την χρήση της πύλης εισόδου και μιας συνάρτησης ενεργοποίησης \tanh (υπερβολική εφαπτομένη). Η πύλη εισόδου καθορίζει ποιες τιμές από την κατάσταση του υποψήφιου κυττάρου θα πρέπει να ενσωματωθούν στην κατάσταση του κυττάρου. Η συνάρτηση ενεργοποίησης \tanh συμπιέζει τις τιμές εντός της κατάστασης του υποψήφιου κυττάρου ώστε να είναι μεταξύ -1 και $+1$, γεγονός που συμβάλλει στον έλεγχο της ροής των πληροφοριών και αποτρέπει τις υπερβολικές αλλαγές στην κατάσταση του κυττάρου. Οι εξισώσεις που περιγράφουν τα παραπάνω είναι οι (3.2) και (3.3) [14]:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (3.2)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (3.3)$$

Στις εξισώσεις (3.2), (3.3), σ είναι η συνάρτηση ενεργοποίησης, W_i το βάρος της πύλης εισόδου, b_i παράμετρος πόλωσης (bias) της πύλης εισόδου, x_t η είσοδος την χρονική στιγμή t , h_{t-1} η έξοδος κρυφού στρώματος την χρονική στιγμή $t - 1$, W_c το βάρος του κυττάρου (cell) και b_c η παράμετρος πόλωσης του κυττάρου cell.

Η εξίσωση για την πύλη εξόδου της κάθε βαθμίδας, καθώς και η έξοδος του κρυφού στρώματος την χρονική στιγμή t , που πιθανόν να μεταβιβαστεί ως είσοδος στην επόμενη βαθμίδα, εάν αυτή υπάρχει, δίνονται από τις εξισώσεις (3.4) και (3.5) [14]:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (3.4)$$

$$h_t = o_t + \tanh(C_t) \quad (3.5)$$

Για τις εξισώσεις (3.4), (3.5), σ είναι η συνάρτηση ενεργοποίησης, W_o το βάρος πύλης εξόδου και b_o η παράμετρος πόλωσης της πύλης εξόδου.

3.2.6 Μονομεταβλητό Μοντέλο LSTM

Το μονομεταβλητό LSTM (Univariate Long-Short-Term Memory) είναι ένας τύπος αρχιτεκτονικής Αναδρομικού Νευρωνικού Δικτύου (RNN) που έχει σχεδιαστεί ειδικά για τον χειρισμό δεδομένων χρονοσειρών με μία μόνο μεταβλητή ή χαρακτηριστικό [40], [41]. Με άλλα λόγια, χρησιμοποιείται με ένα σύνολο δεδομένων χρονοσειράς, όπου κάθε σημείο δεδομένων αποτελείται από μία μόνο αριθμητική τιμή. Το Univariate LSTM είναι ιδιαίτερα αποτελεσματικό για εργασίες, όπως η πρόβλεψη χρονοσειρών, η ανίχνευση ανωμαλιών και η αναγνώριση προτύπων μέσα σε ακολουθίες μίας μεταβλητής.

Τα βασικά χαρακτηριστικά της μονομεταβλητής μορφής LSTM περιλαμβάνουν [40], [41]:

- Ακολουθία εισόδου: Η είσοδος στο μονομεταβλητό LSTM αποτελείται από μια μόνο ακολουθία ιστορικών τιμών μίας μεταβλητής. Οι τιμές αυτές χρησιμοποιούνται για την εκμάθηση χρονικών μοτίβων και σχέσεων.
- Κρυφή κατάσταση: Τα LSTM διατηρούν μια κρυφή κατάσταση που καταγράφει πληροφορίες σχετικά με το πλαίσιο της ακολουθίας. Αυτή η κρυφή κατάσταση

ενημερώνεται με την πάροδο του χρόνου και φέρει πληροφορίες σχετικά με προηγούμενες παρατηρήσεις.

- Μηχανισμοί ελέγχου: Τα LSTM χρησιμοποιούν μηχανισμούς πύλης, όπως η πύλη λήθης, η πύλη εισόδου και η πύλη εξόδου, για να ρυθμίζουν την ροή των πληροφοριών και να ελέγχουν ποιες πληροφορίες διατηρούνται, ενημερώνονται και εξάγονται. Ο ακριβής μηχανισμός λειτουργίας αναπτύχθηκε διεξοδικά στην Ενότητα 3.2.5.
- Μακροπρόθεσμες εξαρτήσεις: Τα LSTM έχουν σχεδιαστεί για να συλλαμβάνουν τις μακροπρόθεσμες εξαρτήσεις στις ακολουθίες. Αντιμετωπίζουν ζητήματα, όπως το πρόβλημα της εξαφανιζόμενης κλίσης στα παραδοσιακά RNN, καθιστώντας τα ικανά να μαθαίνουν πρότυπα, που καλύπτουν σημαντικό αριθμό χρονικών βημάτων.
- Εκπαίδευση: Ο στόχος είναι συχνά η πρόβλεψη της επόμενης τιμής στην ακολουθία, με βάση τις προηγούμενες παρατηρήσεις. Η εκπαίδευση περιλαμβάνει την βελτιστοποίηση των παραμέτρων των βαρών του μοντέλου, για την ελαχιστοποίηση του σφάλματος πρόβλεψης.
- Πρόβλεψη: Μια συνηθισμένη εφαρμογή των μονομεταβλητών LSTM είναι η πρόβλεψη χρονοσειρών, όπου το μοντέλο μαθαίνει να προβλέπει μελλοντικές τιμές της ακολουθίας με βάση την ιστορική συμπεριφορά της.
- Υπερπαραμέτροι: Οι πιο σημαντικές υπερπαραμέτροι για τα μονομεταβλητά LSTM περιλαμβάνουν τον αριθμό των μονάδων LSTM (κόμβων), τον αριθμό των στρωμάτων, το μήκος της ακολουθίας που χρησιμοποιείται για την εκπαίδευση, το μέγεθος της δέσμης και τον αριθμό των εποχών για την εκπαίδευση.
- Αξιολόγηση: Τα μονομεταβλητά μοντέλα LSTM αξιολογούνται συνήθως με την χρήση μετρικών, όπως το μέσο τετραγωνικό σφάλμα (MSE), το μέσο τετραγωνικό σφάλμα ρίζας (RMSE), το μέσο απόλυτο σφάλμα (MAE) ή το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE) για εργασίες πρόβλεψης.

Συνολικά, τα μονομεταβλητά LSTM είναι ισχυρά εργαλεία για την μοντελοποίηση και την πρόβλεψη δεδομένων χρονοσειρών μίας μεταβλητής, με αποτέλεσμα να χρησιμοποιούνται ευρέως σε διάφορους τομείς, όπως η χρηματοοικονομική, η ενέργεια και η υγειονομική περίθαλψη.

Ειδικά όσον αφορά το θέμα της πρόβλεψης της ισχύος, που αποτελεί επίκεντρο της παρούσας διπλωματικής εργασίας, προκύπτει ένα πρόβλημα όσον αφορά την ακρίβεια. Οι προβλέψεις με το μονομεταβλητό μοντέλο εμφανίζουν σχετικά καλή ακρίβεια, όχι όμως την καλύτερη δυνατή. Αυτό συμβαίνει γιατί τα μοντέλα αυτά μπορούν να πάρουν ως είσοδο ένα μόνο μέγεθος, το οποίο είναι οι ιστορικές τιμές της ίδιας της ισχύος από διαφορετικές χρονικές στιγμές. Δηλαδή, η αδυναμία του μοντέλου έγκειται στο γεγονός ότι αδυνατεί να λάβει υπόψη και τους υπόλοιπους παράγοντες που μπορούν να επηρεάσουν την παραγωγή ισχύος του φωτοβολταϊκού, όπως η θερμοκρασία πλαισίου και περιβάλλοντος, η ακτινοβολία, η άεργος ισχύς και άλλοι.

Για τον λόγο αυτό, έχει εισαχθεί μια πιο σύνθετη μορφή του LSTM, που αφορά τον πολυμεταβλητό χαρακτήρα του μοντέλου.

3.2.7 Πολυμεταβλητό Μοντέλο LSTM

Το πολυμεταβλητό μοντέλο (multivariate) LSTM έχει σχεδιαστεί για να χειρίζεται δεδομένα χρονοσειρών με πολλαπλές μεταβλητές ή χαρακτηριστικά. Σε αντίθεση με το μονομεταβλητό LSTM, που ασχολείται με ακολουθίες μίας μεταβλητής, το πολυμεταβλητό

LSTM χρησιμοποιείται όταν κάθε σημείο δεδομένων σε μια χρονοσειρά αποτελείται από πολλαπλές αριθμητικές τιμές [42].

Τα βασικά χαρακτηριστικά αυτής της μορφής LSTM περιλαμβάνουν:

- Ακολουθία εισόδου: Στο πολυμεταβλητό LSTM, η ακολουθία εισόδου περιέχει τιμές από πολλαπλές μεταβλητές. Κάθε χρονικό βήμα περιλαμβάνει παρατηρήσεις από όλες τις μεταβλητές της ακολουθίας.
- Κρυφή κατάσταση: Το πολυμεταβλητό LSTM διατηρεί μια ή περισσότερες κρυφές καταστάσεις, κάθε μία από τις οποίες αποτυπώνει το χρονικό πλαίσιο της ακολουθίας. Η κρυφή κατάσταση εξελίσσεται καθώς το μοντέλο επεξεργάζεται τα διαδοχικά δεδομένα.
- Μηχανισμοί ελέγχου: Οι μηχανισμοί ελέγχου στο πολυμεταβλητό LSTM λειτουργούν παρόμοια με εκείνους στο μονομεταβλητό LSTM. Η πύλη λήθης, η πύλη εισόδου και η πύλη εξόδου ρυθμίζουν την ροή των πληροφοριών και βοηθούν το μοντέλο να διατηρήσει τις σχετικές πληροφορίες.
- Χειρισμός πολλαπλών μεταβλητών: Τα πολυμεταβλητά μοντέλα LSTM μπορούν να συλλάβουν σχέσεις και αλληλεπιδράσεις μεταξύ πολλαπλών μεταβλητών, επιτρέποντάς τους να διαχειριστούν πιο σύνθετα μοτίβα που υπάρχουν στα δεδομένα.
- Εφαρμογές: Τα πολυμεταβλητά LSTM είναι κατάλληλα για εργασίες, στις οποίες οι αλληλεπιδράσεις μεταξύ πολλαπλών μεταβλητών παίζουν σημαντικό ρόλο. Παραδείγματα περιλαμβάνουν την πρόβλεψη του καιρού (με μεταβλητές όπως η θερμοκρασία, η υγρασία και η ταχύτητα του ανέμου), την πρόβλεψη της ζήτησης ενέργειας (με μεταβλητές, όπως η ώρα της ημέρας, η θερμοκρασία και η προηγούμενη χρήση) και την πρόβλεψη της χρηματιστηριακής αγοράς (με μεταβλητές, όπως η τιμή και ο όγκος).
- Εκπαίδευση και αξιολόγηση: Η εκπαίδευση των πολυμεταβλητών LSTM περιλαμβάνει την παροχή ακολουθιών πολλαπλών μεταβλητών ως εισόδων και την πρόβλεψη μιας ή περισσότερων μεταβλητών-στόχων. Οι μετρικές αξιολόγησης για το πολυμεταβλητό LSTM είναι αντίστοιχες με αυτές που χρησιμοποιούνται για το μονομεταβλητό LSTM, δηλαδή οι MSE, RMSE, MAE και MAPE.
- Πολυπλοκότητα: Τα πολυμεταβλητά LSTM μπορεί να είναι πιο πολύπλοκα από τα μονομεταβλητά LSTM, λόγω του αυξημένου αριθμού μεταβλητών. Αυτή η πολυπλοκότητα μπορεί να παρέχει πλουσιότερη αναπαράσταση των υποκείμενων μοτίβων δεδομένων, αλλά απαιτεί περισσότερα δεδομένα και προσεκτική ρύθμιση των υπερπαραμέτρων.

Συνοψίζοντας, ενώ το μονομεταβλητό LSTM είναι κατάλληλο για χρονοσειρές μίας μεταβλητής, το πολυμεταβλητό LSTM έχει σχεδιαστεί για να χειρίζεται δεδομένα με πολλαπλές αλληλεπιδρώσες μεταβλητές. Τα πολυμεταβλητά LSTM έχουν την δυνατότητα να αποτυπώνουν περίπλοκες σχέσεις μεταξύ των μεταβλητών, καθιστώντας τα ισχυρά εργαλεία για την πρόβλεψη και την ανάλυση σύνθετων φαινομένων του πραγματικού κόσμου. Λόγω του ότι λαμβάνουν υπόψη περισσότερες μεταβλητές, έχουν και μικρότερο σφάλμα πρόβλεψης και κατά επέκταση καλύτερη απόδοση.

3.2.8 Προεπεξεργασία Δεδομένων Εισόδου LSTM

Η είσοδος ενός δικτύου μακράς βραχυπρόθεσμης μνήμης (LSTM) είναι ουσιαστικά μια ακολουθία δεδομένων που απαιτούν επεξεργασία και ανάλυση. Αποτελείται από πολλαπλά χρονικά βήματα, καθένα από τα οποία περιέχει ένα σύνολο χαρακτηριστικών [14], [42].

Ακολουθεί ο τρόπος με τον οποίο δομείται η είσοδος σε ένα LSTM:

- **Μήκος ακολουθίας (sequence length):** Το μήκος ακολουθίας αναφέρεται στον αριθμό των χρονικών βημάτων στην ακολουθία εισόδου. Κάθε χρονικό βήμα αντιστοιχεί σε ένα συγκεκριμένο χρονικό σημείο και το LSTM επεξεργάζεται τα δεδομένα διαδοχικά από το ένα χρονικό βήμα στο επόμενο.
- **Χαρακτηριστικά (features):** Σε κάθε χρονικό βήμα, υπάρχει ένα σύνολο χαρακτηριστικών ή μεταβλητών που παρέχεται ως είσοδο στο LSTM. Για παράδειγμα, στο πλαίσιο της πρόβλεψης χρονοσειρών, κάθε χαρακτηριστικό θα μπορούσε να αντιπροσωπεύει μια διαφορετική πτυχή των δεδομένων, όπως η θερμοκρασία, η υγρασία και η ταχύτητα του ανέμου.
- **Σχήμα εισόδου (input shape):** Το σχήμα εισόδου ενός LSTM είναι ένας τρισδιάστατος πίνακας με διαστάσεις (batch_size, sequence_length, num_features), όπου:
 - **Batch size:** Ο αριθμός των ακολουθιών που επεξεργάζονται παράλληλα. Αυτό είναι χρήσιμο για αποτελεσματική εκπαίδευση.
 - **Sequence length:** Ο αριθμός των χρονικών βημάτων σε κάθε ακολουθία.
 - **Number of features:** Ο αριθμός των χαρακτηριστικών ή των μεταβλητών σε κάθε χρονικό βήμα.
- **Προεπεξεργασία δεδομένων (preprocessing):** Πριν τροφοδοτηθούν τα δεδομένα στο LSTM, είναι σύνηθες να γίνεται μια προεπεξεργασία. Αυτό μπορεί να περιλαμβάνει βήματα όπως η κανονικοποίηση, η κλιμάκωση και ο χειρισμός των τιμών που είναι 0 ή nan, για να διασφαλιστεί ότι τα δεδομένα είναι κατάλληλα για εκπαίδευση. Τα βασικά βήματα προεπεξεργασίας που εφαρμόζονται είναι τα ακόλουθα δύο:
 - Το πρώτο βήμα της προεπεξεργασίας δεδομένων είναι η επιλογή χαρακτηριστικών. Σε ένα σύνολο δεδομένων, που διαθέτει πολλά σήματα, η επιλογή χαρακτηριστικών είναι η διαδικασία επιλογής του καλύτερου σήματος για την τροφοδοσία του LSTM. Η μέθοδος για την επιλογή του καλύτερου υποψήφιου σήματος είναι ο έλεγχος της συσχέτισης (correlation) μεταξύ των σημάτων.
 - Το δεύτερο βήμα είναι η κλιμάκωση των χαρακτηριστικών. Περιλαμβάνει δύο διαφορετικές προ-επεξεργασίες δεδομένων, οι οποίες είναι η κανονικοποίηση (normalization) και η τυποποίηση (standardization).

Κανονικοποίηση είναι η διαδικασία αναβάθμισης των δεδομένων από το αρχικό εύρος, έτσι ώστε όλες οι τιμές να βρίσκονται εντός του εύρους 0 και 1. Η κανονικοποίηση απαιτεί την γνώση ή την ακριβή εκτίμηση της ελάχιστης και της μέγιστης παρατηρήσιμης τιμής, η οποία μπορεί να γίνει με βάση τα διαθέσιμα καταγεγραμμένα δεδομένα. Στην περίπτωση της ηλιακής δραστηριότητας, οι ελάχιστες και οι μέγιστες τιμές μπορούν να βρεθούν εύκολα, δεδομένου ότι ο ηλιακός παλμός επαναλαμβάνεται καθημερινά.

Ως αποτέλεσμα, κάθε σήμα κανονικοποιείται σε μια τιμή μεταξύ 0 και 1, οι οποίες αντιστοιχούν στο ελάχιστο και το μέγιστο του συνόλου των δεδομένων. Η εξίσωση που περιγράφει την διαδικασία αυτή είναι η (3.6) [13]:

$$x_{norm}^{(i)} = \frac{x^{(i)}}{x_{max} - x_{min}} \quad (3.6)$$

Στην εξίσωση (3.6) $x^{(i)}$ είναι το δείγμα (sample), $x_{norm}^{(i)}$ είναι η νέα τιμή του $x^{(i)}$, x_{max} είναι η μεγαλύτερη τιμή σε μια στήλη ενός χαρακτηριστικού (feature) και x_{min} είναι η ελάχιστη τιμή σε μια στήλη ενός χαρακτηριστικού.

Στην συνέχεια, ακολουθεί η τυποποίηση. Η αρχή της τυποποίησης ενός συνόλου δεδομένων περιλαμβάνει την αναπροσαρμογή της κλίμακας της κατανομής των τιμών, έτσι ώστε ο μέσος όρος των παρατηρούμενων τιμών να είναι 0 και η τυπική απόκλιση να είναι 1.

Η τυποποίηση μπορεί να είναι χρήσιμη και μπορεί να απαιτείται σε ορισμένους αλγόριθμους Μηχανικής Μάθησης, όταν τα δεδομένα έχουν τιμές εισόδου με διαφορετικές κλίμακες.

Ωστόσο, προϋποθέτει ότι οι παρατηρήσεις ταιριάζουν σε μια γκαουσιανή κατανομή, με μια καλά προσαρμοσμένη μέση τιμή και μια τυπική απόκλιση.

Επιπλέον, η τυποποίηση απαιτεί την γνώση ή την ακριβή εκτίμηση της μέσης τιμής και της τυπικής απόκλισης των παρατηρήσιμων τιμών. Στην περίπτωση των δεδομένων ηλιακής ενέργειας, η εκτίμηση αυτή είναι δυνατή από το σύνολο των δεδομένων εκπαίδευσης.

Η εξίσωση που περιγράφει την διεργασία αυτή είναι η (3.7) [13]:

$$x_{std}^{(i)} = \frac{x^{(i)} - u_x}{\sigma_x} \quad (3.7)$$

Στην εξίσωση (3.7) $x^{(i)}$ είναι το δείγμα (sample), $x_{std}^{(i)}$ είναι η νέα τιμή του $x^{(i)}$, u_x είναι η μέση τιμή δείγματος (sample) ενός χαρακτηριστικού και σ_x η αντίστοιχη τυπική απόκλιση.

- Δεδομένα χρονοσειρών (time-series data): Για τα δεδομένα χρονοσειρών, η ακολουθία εισόδου θα πρέπει να αποτυπώνει την χρονική σειρά των δεδομένων. Κάθε χρονικό βήμα θα πρέπει να αντιστοιχεί σε ένα συγκεκριμένο χρονικό σημείο και η ακολουθία θα πρέπει να αναπαριστά την χρονολογική σειρά των γεγονότων.
- Δεδομένα κειμένων (text data): Αυτά αφορούν σε εργασίες επεξεργασίας φυσικής γλώσσας, όπου κάθε χρονικό βήμα θα μπορούσε να αντιπροσωπεύει μια λέξη ή ένα σύμβολο και η ακολουθία θα μπορούσε να είναι μια πρόταση ή μια παράγραφος.

3.2.9 Σύνολα Εκπαίδευσης, Ελέγχου και Επικύρωσης

Σε κάθε περίπτωση ενός Τεχνητού Νευρωνικού Δικτύου, τα δεδομένα που διατίθενται χωρίζονται σε δεδομένα που χρησιμοποιούνται για την εκπαίδευση (training), τον έλεγχο (testing) και την επικύρωση (validation) του μοντέλου [13], [14]. Τα δεδομένα εκπαίδευσης είναι τα δεδομένα από τα οποία «μαθαίνει» το μοντέλο για να κάνει τις προβλέψεις και τα

δεδομένα ελέγχου είναι οι πραγματικές τιμές που τίθενται προς πρόβλεψη. Τα δεδομένα επικύρωσης χρησιμοποιούνται για την επικύρωση της απόδοσης του μοντέλου.

Τα σύνολα εκπαίδευσης, ελέγχου και επικύρωσης χρησιμοποιούνται για την εκπαίδευση του μοντέλου, την ρύθμιση των υπερπαραμέτρων και την αξιολόγηση της γενίκευσής του σε νέα δεδομένα. Ακολουθεί μια επεξήγηση αυτών των συνόλων.

- **Σύνολο εκπαίδευσης:** Το σύνολο εκπαίδευσης είναι το τμήμα του συνόλου δεδομένων που χρησιμοποιείται για την εκπαίδευση και «εκμάθηση» του μοντέλου. Περιέχει μια ακολουθία ζευγών εισόδου-εξόδου, για την οποία το μοντέλο μαθαίνει να αντιστοιχίζει την ακολουθία εισόδου στην αντίστοιχη ακολουθία εξόδου. Κατά την διάρκεια της εκπαίδευσης, το μοντέλο ρυθμίζει τα βάρη και τις παραμέτρους του, μέσω του αλγορίθμου της προς τα πίσω διάδοσης του σφάλματος, για να ελαχιστοποιήσει την διαφορά μεταξύ των προβλέψεων του και των πραγματικών τιμών-στόχων. Ένα μεγαλύτερο σύνολο εκπαίδευσης οδηγεί γενικά σε καλύτερη απόδοση του μοντέλου, καθώς το μοντέλο έχει περισσότερα δεδομένα για να μάθει από αυτά και να γενικεύσει πρότυπα. Ωστόσο, είναι σημαντικό το σύνολο εκπαίδευσης να είναι αφενός μεν ποικιλόμορφο, ώστε ειδικά στο κομμάτι της πρόβλεψης να περιλαμβάνει κάθε παράγοντα που μπορεί να επηρεάσει την παραγωγή ισχύος του φωτοβολταϊκού, αφετέρου δε να είναι αντιπροσωπευτικό. Αυτό δεν σημαίνει απαραίτητα πολύ μεγάλο, αφού, αν το σύνολο εκπαίδευσης είναι υπερβολικά μεγάλο, μπορεί να προκύψουν προβλήματα υπερπροσαρμογής, αλλά και μεγάλης χρονικής καθυστέρησης για την εξαγωγή των προβλέψεων.
- **Σύνολο επικύρωσης:** Το σύνολο επικύρωσης είναι ένα ξεχωριστό υποσύνολο των δεδομένων που δεν χρησιμοποιείται κατά την εκπαίδευση. Χρησιμοποιείται για την ρύθμιση των υπερπαραμέτρων και την παρακολούθηση της απόδοσης του μοντέλου κατά την διάρκεια της εκπαίδευσης. Κατά την διάρκεια της εκπαίδευσης, η απόδοση του μοντέλου στο σύνολο επικύρωσης αξιολογείται περιοδικά. Αυτό βοηθά στην επιλογή των βέλτιστων υπερπαραμέτρων (όπως του ρυθμού μάθησης και του μεγέθους δέσμης), που οδηγούν στην βέλτιστη απόδοση του μοντέλου. Το σύνολο αυτό χρησιμεύει ως υποκατάστατο για την δοκιμή της απόδοσης του μοντέλου σε νέα δεδομένα. Βοηθά στην αποφυγή της υπερπροσαρμογής και παρέχει μια εκτίμηση του πόσο καλά γενικεύει το μοντέλο.
- **Σύνολο ελέγχου:** Το σύνολο ελέγχου είναι ένα άλλο ανεξάρτητο υποσύνολο δεδομένων που το μοντέλο δεν έχει δει ποτέ κατά την διάρκεια της εκπαίδευσης ή της επικύρωσης. Αφού το μοντέλο έχει εκπαιδευτεί πλήρως και οι υπερπαραμέτροι του έχουν ρυθμιστεί χρησιμοποιώντας το σύνολο επικύρωσης, αξιολογείται στο σύνολο ελέγχου για να εκτιμηθεί η ικανότητα γενίκευσής του. Η απόδοση του μοντέλου πρόβλεψης στο σύνολο ελέγχου, δίνει μια εκτίμηση για το πώς θα αποδώσει το μοντέλο σε νέα δεδομένα του πραγματικού κόσμου. Βοηθά στην παροχή μιας δίκαιης εκτίμησης της ακρίβειας και της αποτελεσματικότητας του μοντέλου πρόβλεψης.

Συνοπτικά, το σύνολο εκπαίδευσης χρησιμοποιείται για την εκπαίδευση του μοντέλου LSTM, το σύνολο επικύρωσης βοηθά στην λεπτομερή ρύθμιση των υπερπαραμέτρων και το σύνολο ελέγχου αξιολογεί την συνολική απόδοση του μοντέλου σε νέα δεδομένα. Ο σωστός διαχωρισμός των δεδομένων σε αυτά τα σύνολα είναι απαραίτητος για να διασφαλιστεί ότι το μοντέλο δεν είναι μόνο ακριβές στα δεδομένα εκπαίδευσης, αλλά και ικανό να κάνει σημαντικές προβλέψεις σε νέα δεδομένα. Οι τεχνικές διασταυρούμενης επικύρωσης και ο

προσεκτικός διαχωρισμός των δεδομένων μπορούν να βοηθήσουν στην εξασφάλιση ισχυρής απόδοσης του μοντέλου.

3.2.10 Συνοπτική Επεξήγηση Κώδικα LSTM σε Python

Στο πλαίσιο της παρούσας διπλωματικής εργασίας αναπτύχθηκε σε γλώσσα Python η σύνθετη πολυμεταβλητή μορφή του μοντέλου LSTM. Ουσιαστικά, είναι μια υλοποίηση ενός νευρωνικού δικτύου μακράς βραχυπρόθεσμης μνήμης (LSTM), για την πρόβλεψη της ηλιακής ενέργειας με χρήση δεδομένων χρονοσειρών [14]. Στην συνέχεια, επεξηγείται ο κώδικας σε Python.

- 1) Εισαγωγή βιβλιοθηκών (Importing libraries): Γίνεται εισαγωγή των απαραίτητων βιβλιοθηκών. Για παράδειγμα, η `pandas` χρησιμοποιείται για τον χειρισμό πλαισίων δεδομένων, η `numpy` για αριθμητικές πράξεις, η `matplotlib.pyplot` για την απεικόνιση, η `MinMaxScaler` για την κανονικοποίηση των δεδομένων, η `TimeseriesGenerator` για την δημιουργία ακολουθιών για την εκπαίδευση, η `Sequential` για τον ορισμό του μοντέλου, οι `LSTM` και `Dense` για τα επίπεδα του μοντέλου και η `seasonal_decompose` για την αποσύνθεση χρονοσειρών.
- 2) Διαχωρισμός δεδομένων (splitting data): Ορίζεται μια συνάρτηση διαχωρισμού που παίρνει το πλαίσιο δεδομένων και το χωρίζει σε σύνολα εκπαίδευσης και ελέγχου. Επιλέγει συγκεκριμένες περιοχές δεδομένων για κάθε σύνολο.
- 3) Φόρτωση και προεπεξεργασία δεδομένων: Η φόρτωση των δεδομένων γίνεται χρησιμοποιώντας την εντολή `pd.read_csv` της βιβλιοθήκης `pandas`. Η προεπεξεργασία περιλαμβάνει τα εξής βήματα :
 - Αρχικά βρίσκεται η συσχέτιση των μεγεθών που επηρεάζουν την παραγωγή ισχύος. Ο πίνακας συσχέτισης (`corr_matrix`) υπολογίζει τις συσχετίσεις μεταξύ των στηλών των δεδομένων. Οι συσχετίσεις αυτές υπολογίζονται με βάση τον συντελεστή συσχέτισης, ο οποίος μετρά την ισχύ και την κατεύθυνση της γραμμικής σχέσης μεταξύ δύο μεταβλητών. Οπότε, στην ουσία, ο πίνακας συσχέτισης είναι το αποτέλεσμα. Στη συνέχεια, χρησιμοποιείται η συνάρτηση `sns.heatmap()` από την βιβλιοθήκη `Seaborn` για την δημιουργία μιας απεικόνισης του πίνακα συσχέτισης σε χάρτη θερμότητας. Ο χάρτης θερμότητας παρέχει μια χρωματικά κωδικοποιημένη αναπαράσταση των συσχετίσεων, όπου οι υψηλότερες τιμές εμφανίζονται συνήθως με διαφορετικό χρώμα από τις χαμηλότερες τιμές.
 - Κλιμάκωση: Το `MinMaxScaler` κλιμακώνει τα δεδομένα μεταξύ 0 και 1, κάτι που είναι ζωτικής σημασίας για την εκπαίδευση των νευρωνικών δικτύων. Τόσο τα δεδομένα εκπαίδευσης, όσο και τα δεδομένα ελέγχου κλιμακώνονται.
- 4) Δημιουργία γεννητριών χρονοσειρών (Time-Series Generators): Χρησιμοποιείται για την δημιουργία ζευγών εισόδου-εξόδου για την εκπαίδευση του LSTM. Δημιουργεί παρτίδες ακολουθιών με μήκος ακολουθίας εισόδου (`input_seq_len`) και αντίστοιχη έξοδο. Το `input_seq_len` ορίζεται να είναι ίσο με πέντε (5) ώστε ο αλγόριθμος να διαβάζει δεδομένα ανά 5 λεπτά.
- 5) Ορισμός και μεταγλώττιση του μοντέλου LSTM (defining and compiling): Γίνεται ορισμός ενός διαδοχικού μοντέλου νευρωνικού δικτύου. Αυτό περιλαμβάνει ένα

επίπεδο LSTM με 2 μονάδες και μια συνάρτηση ενεργοποίησης ReLU. Το επόμενο πυκνό στρώμα έχει τόσες μονάδες όσες και ο αριθμός των στηλών στα δεδομένα εκπαίδευσης. Το μοντέλο καταρτίζεται χρησιμοποιώντας τον βελτιστοποιητή Adam και την συνάρτηση απώλειας του μέσου τετραγωνικού σφάλματος (MSE).

- 6) Εκπαίδευση του μοντέλου: Προσαρμόζεται το μοντέλο με την γεννήτρια εκπαίδευσης (train_gen). Η εκπαίδευση πραγματοποιείται σε πολλαπλές εποχές. Οι απώλειες εκπαίδευσης υπολογίζονται και παριστάνονται σε γράφημα με τον αριθμό των εποχών (epochs), χρησιμοποιώντας το αντικείμενο history.
- 7) Δημιουργία προβλέψεων: Οι προβλέψεις γίνονται με βάση προηγούμενες παρατηρήσεις. Η γεννήτρια δοκιμών (test_gen) διατρέχεται με βρόχο και με τον τρόπο αυτόν προβλέπεται η έξοδος της κάθε παρτίδας (batch).
- 8) Αντίστροφη κλιμάκωση και αξιολόγηση (inverse scaling and evaluation): Οι προβλέψεις κλιμακώνονται αντίστροφα χρησιμοποιώντας την εντολή scaler.inverse_transform. Στην συνέχεια, αποτυπώνονται σε γράφημα οι πραγματικές τιμές εκπαίδευσης, ελέγχου και πρόβλεψης για μια στήλη και υπολογίζονται και τυπώνονται μετρικές, όπως το MAPE, το RMSE και το NRMSE για κάθε στήλη.
- 9) Αποθήκευση προβλέψεων: Δημιουργείται ένα DataFrame που περιέχει τις προβλέψεις, τις πραγματικές τιμές και τις χρονοσφραγίδες. Αυτό το DataFrame αποθηκεύεται σε ένα αρχείο CSV.

Σε γενικές γραμμές, ο κώδικας αυτός ακολουθεί την τυπική ροή εργασίας για την πρόβλεψη χρονοσειρών με την χρήση ενός νευρωνικού δικτύου LSTM. Περιλαμβάνει την προεπεξεργασία δεδομένων, τον ορισμό του μοντέλου, την εκπαίδευση, την πρόβλεψη, την αξιολόγηση και την αποθήκευση των αποτελεσμάτων.

3.3 ΑΛΓΟΡΙΘΜΟΣ ARIMA

Για την βελτίωση της απόδοσης του μοντέλου LSTM διερευνήθηκαν και αναζητήθηκαν εναλλακτικές μέθοδοι, αλλά και συνδυασμοί του μοντέλου με άλλα μοντέλα πρόβλεψης. Ένας από τους αλγόριθμους που μελετήθηκε πιο διεξοδικά και εν τέλει χρησιμοποιήθηκε για τον σκοπό αυτό στην παρούσα εργασία είναι ο αλγόριθμος ARIMA.

3.3.1 Γενικά Στοιχεία

Ο αλγόριθμος ARIMA (AutoRegressive Integrated Moving Average) είναι μια δημοφιλής τεχνική πρόβλεψης χρονοσειρών, που χρησιμοποιείται για την μοντελοποίηση και την πρόβλεψη μελλοντικών τιμών ενός χρονικά εξαρτώμενου συνόλου δεδομένων. Είναι ιδιαίτερα αποτελεσματική για σύνολα δεδομένων, που παρουσιάζουν τάσεις, εποχικότητα και θόρυβο. Τα μοντέλα ARIMA χρησιμοποιούνται ευρέως σε διάφορους τομείς, συμπεριλαμβανομένων των οικονομικών, των χρηματοοικονομικών, της μετεωρολογίας και άλλων [40].

Τα μοντέλα ARIMA ανήκουν στην κατηγορία των στατιστικών μοντέλων χρονοσειρών. Τα μοντέλα αυτά βασίζονται σε στατιστικές μεθόδους και υποθέσεις για να αποτυπώσουν τα υποκείμενα πρότυπα και τις σχέσεις στα δεδομένα χρονοσειρών. Το μοντέλο ARIMA είναι μια ευρέως χρησιμοποιούμενη τεχνική για την πρόβλεψη δεδομένων χρονοσειρών με την μοντελοποίηση των ιδιοτήτων της αυτοσυσχέτισης και του κινητού μέσου όρου των δεδομένων [17], [40].

Σε ένα μοντέλο ARIMA, η μελλοντική τιμή μιας μεταβλητής υποτίθεται ότι είναι μια γραμμική συνάρτηση πολλών παρελθοντικών παρατηρήσεων και τυχαίων σφαλμάτων, δηλαδή η υποκείμενη διαδικασία που δημιουργεί την χρονοσειρά, έχει την μορφή [40]:

$$y_t = \theta_0 + \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + \varepsilon_t \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (3.8)$$

Όπου, για την εξίσωση (3.8) y_t είναι η πραγματική τιμή της χρονοσειράς την χρονική στιγμή t , ε_t το τυχαίο σφάλμα τη χρονική στιγμή t , $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ είναι οι καθυστερημένες τιμές της χρονοσειράς, $\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$ είναι τα σφάλματα των καθυστερημένων τιμών της χρονοσειράς, φ_i ($i=1,2,\dots,p$) είναι οι αυτοπαλίνδρομοι συντελεστές που αντιπροσωπεύουν τη σχέση μεταξύ των τρεχουσών και των προηγούμενων τιμών και θ_j ($j=0,1,2,\dots,q$) είναι οι συντελεστές κινητού μέσου όρου, που αντιπροσωπεύουν την σχέση μεταξύ των τρεχόντων και των παρελθόντων όρων σφάλματος.

Επιπλέον, εάν η χρονοσειρά πρέπει να διαφοριστεί για να καταστεί στάσιμη, η εξίσωση θα περιλαμβάνει έναν τελεστή διαφορίσης B^d που θα εφαρμόζεται d φορές, οπότε η εξίσωση θα γίνει [17], [40]:

$$(1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p)(1 - B)^d y_t = (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q) \varepsilon_t \quad (3.9)$$

Τα μοντέλα ARIMA είναι εξαιρετικά ευέλικτα και μπορούν να προσαρμοστούν σε διάφορα πρότυπα χρονοσειρών προσαρμόζοντας τις τιμές των (p, d, q) . Οι παράμετροι προσδιορίζονται με βάση την ανάλυση των συναρτήσεων αυτοσυσχέτισης και μερικής αυτοσυσχέτισης.

Με τις εξισώσεις (3.8) και (3.9) περιγράφεται το μοντέλο στην γενική του μορφή. Στην συνέχεια θα μελετηθούν ειδικές περιπτώσεις και θα γίνει αναλυτική περιγραφή της δομής του μοντέλου και της ροής της πληροφορίας μέσω αυτού. Επίσης, θα επεξηγηθεί ο κώδικας που αναπτύχθηκε και θα γίνει μια εισαγωγή στο υβριδικό μοντέλο.

3.3.2 Δομή και Παράμετροι του Μοντέλου ARIMA

Το μοντέλο ARIMA για πρόβλεψη χρονοσειρών συνδυάζει τρεις βασικές συνιστώσες που αποτελούν τα βασικά στοιχεία της δομής του μοντέλου. Αυτές είναι οι εξής [17], [40], [43]:

- 1) Αυτόματη παλινδρόμηση (Autoregression, AR): Αναφέρεται στην εξάρτηση της τρέχουσας παρατήρησης από προηγούμενες παρατηρήσεις.
- 2) Ολοκλήρωση (Integration, I): Περιλαμβάνει την διαφορίση των δεδομένων της χρονοσειράς για να τα καταστήσει στάσιμα.
- 3) Κινητός μέσος όρος (Moving Average, MA): Εξετάζει την σχέση μεταξύ μιας παρατήρησης και του σφάλματος. Συμβάλλει στην σύλληψη των τυχαίων διακυμάνσεων ή του θορύβου στα δεδομένα.

Τα μοντέλα ARIMA απαιτούν για την κατά το δυνατόν ελαχιστοποίηση του σφάλματος των προβλέψεων κατάλληλη επιλογή των παραμέτρων $order(p, d, q)$, όπου [17], [40]:

- p είναι η σειρά της αυτοπαλίνδρομης συνιστώσας (Autoregressive Order): αντιπροσωπεύει τον αριθμό των καθυστερημένων παρατηρήσεων (παρελθούσες τιμές) της χρονοσειράς, που χρησιμοποιούνται για την πρόβλεψη της τρέχουσας τιμής. Καθορίζει τον αριθμό των όρων AR στο μοντέλο ARIMA. Κάθε όρος AR πολλαπλασιάζεται με έναν συντελεστή φ_i που αντιπροσωπεύει την σχέση μεταξύ της τρέχουσας τιμής και των καθυστερημένων τιμών.
- d είναι ο βαθμός διαφορίσης (Differencing Order): υποδεικνύει τον αριθμό των διαφορίσεων της χρονοσειράς για να καταστεί στάσιμη. Η διαφορίση βοηθά στην αφαίρεση των τάσεων και της εποχικότητας. Εάν η αρχική χρονοσειρά είναι ήδη στάσιμη, τότε το $d = 0$. Εάν η διαφορίση απαιτείται μία φορά για να επιτευχθεί η στασιμότητα, τότε το d είναι 1, και ούτω καθεξής.
- q είναι η τάξη του κινητού μέσου όρου (Moving Average Order): αντιπροσωπεύει τον αριθμό των καθυστερημένων σφαλμάτων πρόβλεψης (υπόλοιπα) της χρονοσειράς, που χρησιμοποιούνται για την πρόβλεψη της τρέχουσας τιμής. Καθορίζει τον αριθμό των όρων MA στο μοντέλο ARIMA. Κάθε όρος MA πολλαπλασιάζεται με έναν συντελεστή θ_i , που αντιπροσωπεύει την σχέση μεταξύ της τρέχουσας τιμής και των σφαλμάτων πρόβλεψης του παρελθόντος.

Οι βέλτιστες τιμές αυτών των παραμέτρων μπορούν να προσδιοριστούν με διάφορες τεχνικές. Μία από αυτές είναι και ο αυτοματοποιημένος αλγόριθμος `auto_arima`, που αξιοποιήθηκε στο πλαίσιο της παρούσας διπλωματικής εργασίας και θα μελετηθεί διεξοδικά στην Ενότητα 3.3.4.

3.3.3 Ανάπτυξη Κώδικα σε Python για το Μοντέλο ARIMA

Στο πλαίσιο κατασκευής ενός κώδικα σε Python για το μοντέλο ARIMA τα βήματα που ακολουθήθηκαν ήταν τα ακόλουθα :

- 1) Εισαγωγές βιβλιοθηκών (`importing libraries`): Βιβλιοθήκες όπως η `numpy` για αριθμητικές πράξεις και η `matplotlib.pyplot` για την σχεδίαση.
- 2) Φόρτωση και προεπεξεργασία δεδομένων (`data loading and preprocessing`): Τα δεδομένα φορτώνονται από ένα αρχείο `csv` που περιέχει τα απαραίτητα δεδομένα για την παραγωγή ισχύος και τις αντίστοιχες χρονικές στιγμές σε λεπτά για κάθε λεπτό του έτους 2021. Τα δεδομένα αυτά φορτώνονται σε ένα `DataFrame (df)`. Στην συνέχεια, στο πλαίσιο της προεπεξεργασίας, τυχόν γραμμές με ελλείπουσες τιμές αφαιρούνται με την χρήση της `dropna()`. Δεν απαιτείται κάποια κλιμάκωση των δεδομένων όπως στον αντίστοιχο κώδικα για το LSTM.
- 3) Οπτικοποίηση δεδομένων (`visualization of data`): Κατασκευάζεται ένα γράφημα, το οποίο παριστάνει την διακύμανση της ισχύος "Power (kW)" με την πάροδο του χρόνου. Το κομμάτι αυτό του κώδικα υλοποιείται κυρίως για λόγους διάκρισης και επιβεβαίωσης των ημερών με ηλιοφάνεια, συννεφιά ή ήμι-συννεφιά, με βάση την μεθοδολογία της Ενότητας 2.1.4. Αν τεθεί ως είσοδος ένα μικρό σύνολο δεδομένων, ώστε να είναι διακριτή η διακύμανση της ισχύος για διαφορετικές ώρες, είναι αντιληπτό πως για συννεφιασμένες ημέρες η αιχμή της ισχύος είναι πολύ πιο χαμηλά σε σχέση με αυτή των ηλιόλουστων ημερών και για τις ημι-συννεφιασμένες ημέρες επικρατεί μια ενδιάμεση κατάσταση.
- 4) Ανίχνευση και χειρισμός ακραίων τιμών (`outlier detection and handling`): Υπολογίζεται το IQR (Interquartile Range) για την ανίχνευση ακραίων τιμών. Οι

ακραίες τιμές (outliers) εντοπίζονται χρησιμοποιώντας τα όρια του IQR και στην συνέχεια αφαιρούνται ή αντικαθίστανται με αντιπροσωπευτικές τιμές για τον καθαρισμό των δεδομένων.

- 5) Διαχωρισμός δεδομένων (data splitting): Τα σύνολα εκπαίδευσης και ελέγχου διαχωρίζονται, όπως και στον αντίστοιχο κώδικα του LSTM.
- 6) Μοντελοποίηση και πρόβλεψη ARIMA (ARIMA modeling and prediction) με την μέθοδο του κυλιόμενου παραθύρου.

Για κάθε χρονικό βήμα στα δεδομένα ελέγχου:

- Προστίθεται τυχαίος θόρυβος στα ιστορικά δεδομένα για την προσομοίωση των αλλαγών στην διαδικασία.
- Δημιουργείται ένα μοντέλο ARIMA με καθορισμένη τάξη (p, d, q) χρησιμοποιώντας ιστορικά δεδομένα (history).
- Το μοντέλο ARIMA προσαρμόζεται στα ιστορικά δεδομένα.
- Γίνεται πρόβλεψη ενός βήματος (*forecast()*) για την πρόβλεψη της επόμενης τιμής.
- Η προβλεπόμενη τιμή (*yhat*) προσαρτάται στην λίστα προβλέψεων.
- Η πραγματική τιμή (*obs_test*) από τα αρχικά δεδομένα αντλείται επίσης για σύγκριση.
- Η παλαιότερη τιμή στο ιστορικό αντικαθίσταται από την πραγματική τιμή (*obs_train*).
- Η παλαιότερη τιμή αφαιρείται για να διατηρηθεί το κυλιόμενο παράθυρο.
- Η προβλεπόμενη τιμή και η πραγματική τιμή εκτυπώνονται.

Πρώτη βασική παρατήρηση για το κομμάτι της πρόβλεψης είναι η χρήση και ενσωμάτωση του θορύβου. Τίθεται ερωτήματα, γιατί εισάγεται θόρυβος στο μοντέλο. Ο τυχαίος θόρυβος που προστίθεται στα ιστορικά δεδομένα χρησιμεύει ως ένας απλός τρόπος προσομοίωσης της φυσικής μεταβλητότητας και της απρόβλεπτης συμπεριφοράς, που συχνά υπάρχει στα δεδομένα χρονοσειρών του πραγματικού κόσμου. Αυτός ο προσομοιωμένος θόρυβος προστίθεται στα ιστορικά δεδομένα πριν από την πραγματοποίηση προβλέψεων με την χρήση του μοντέλου ARIMA. Ακολουθούν οι βασικοί λόγοι για τους οποίους χρησιμοποιείται ο θόρυβος [17], [40]:

- Εναρμόνιση με τα δεδομένα του πραγματικού κόσμου: Τα δεδομένα του πραγματικού κόσμου συχνά περιέχουν εγγενή μεταβλητότητα, τυχαιότητα και απρόβλεπτη συμπεριφορά. Προσθέτοντας τυχαίο θόρυβο στα ιστορικά δεδομένα, γίνεται από το μοντέλο μία προσπάθεια σύλληψης μέρους αυτής της πολυπλοκότητας του πραγματικού κόσμου.
- Ευστάθεια του μοντέλου: Ο θόρυβος βοηθά στην δημιουργία ενός πιο ανθεκτικού μοντέλου. Μπορεί να αποτρέψει το μοντέλο από το να γίνει υπερβολικά αιτιοκρατικό και να προσαρμόζεται υπερβολικά στα δεδομένα εκπαίδευσης. Αυτό μπορεί να οδηγήσει σε καλύτερη γενίκευση σε νέα δεδομένα.
- Αντιμετώπιση των περιορισμών: Τα μοντέλα ARIMA υποθέτουν ότι τα δεδομένα ακολουθούν ένα συγκεκριμένο μοτίβο. Στην πράξη, μπορεί να υπάρξουν αποκλίσεις από αυτό το πρότυπο λόγω διαφόρων παραγόντων. Η προσθήκη θορύβου μπορεί να βοηθήσει το μοντέλο να συλλάβει αυτές τις αποκλίσεις.
- Στοχαστική συνιστώσα: Πολλά φαινόμενα του πραγματικού κόσμου έχουν μια στοχαστική (τυχαία) συνιστώσα. Προσθέτοντας θόρυβο, γίνεται εισαγωγή ενός στοχαστικού στοιχείου στο μοντέλο, το οποίο μπορεί να το κάνει πιο αντιπροσωπευτικό της πραγματικής διαδικασίας.

- Ξεπερνώντας την υποπροσαρμογή: Αν τα ιστορικά δεδομένα είναι πολύ ομαλά ή δεν έχουν μεταβλητότητα, το μοντέλο ARIMA μπορεί να υποπροσαρμοστεί, αποτυγχάνοντας να συλλάβει την πολυπλοκότητα της διαδικασίας. Ο θόρυβος μπορεί να προσδώσει την απαραίτητη μεταβλητότητα για να αποφευχθεί η υποπροσαρμογή.

Σε συνέχεια των παραπάνω, είναι σημαντικό να σημειωθεί ότι η ποσότητα του θορύβου που προστίθεται θα πρέπει να εξεταστεί προσεκτικά. Ο υπερβολικά μεγάλος θόρυβος μπορεί να οδηγήσει σε υπερβολικά ασταθείς προβλέψεις, ενώ ο πολύ μικρός θόρυβος μπορεί να μην αποτυπώνει επαρκώς την μεταβλητότητα του πραγματικού κόσμου. Η επιλογή του επιπέδου θορύβου συχνά περιλαμβάνει πειραματισμό και δοκιμές.

Δεύτερη βασική παρατήρηση προς εξεζήγηση αποτελεί η έννοια του κυλιόμενου παραθύρου, που αναφέρθηκε στο βήμα 6 της παρούσας Ενότητας 3.3.3. Το κυλιόμενο παράθυρο (rolling window) αναφέρεται σε μια δυναμική προσέγγιση της ενημέρωσης και διατήρησης ενός ιστορικού συνόλου δεδομένων σταθερού μεγέθους, καθώς καθίστανται διαθέσιμα νέα δεδομένα. Ουσιαστικά, επιτρέπει να ενημερώνονται συνεχώς τα ιστορικά δεδομένα που χρησιμοποιούνται για την πρόβλεψη, διατηρώντας παράλληλα ένα παράθυρο σταθερού μεγέθους. Αυτό βοηθά το μοντέλο ARIMA να προσαρμόζεται στα μεταβαλλόμενα πρότυπα των δεδομένων και να κάνει προβλέψεις που επηρεάζονται από τις πιο πρόσφατες παρατηρήσεις. Είναι ένας τρόπος προσομοίωσης σεναρίων πρόβλεψης σε πραγματικό χρόνο, όπου νέα δεδομένα καθίστανται διαθέσιμα με την πάροδο του χρόνου και το μοντέλο ενημερώνει συνεχώς τις προβλέψεις του.

Τρίτη και βασική παρατήρηση αφορά τον τρόπο με τον οποίο έγινε η επιλογή των παραμέτρων (p,d,q) για το μοντέλο ARIMA. Στο πλαίσιο της παρούσας διπλωματικής εργασίας χρησιμοποιήθηκε ο αυτοματοποιημένος αλγόριθμος AUTO-ARIMA, η εξεζήγηση του οποίου θα πραγματοποιηθεί στην Ενότητα 3.3.4.

- 7) Μετρικές αξιολόγησης (evaluation metrics): Υπολογίζεται το μέσο τετραγωνικό σφάλμα (RMSE) μεταξύ των προβλεπόμενων τιμών και των πραγματικών δεδομένων ελέγχου. Στην συνέχεια, το κανονικοποιημένο RMSE (NRMSE) υπολογίζεται διαιρώντας το RMSE με το εύρος των πραγματικών τιμών. Έπειτα, γίνεται υπολογισμός του μέσου απόλυτου ποσοστιαίου σφάλματος (MAPE) για την αξιολόγηση της ακρίβειας πρόβλεψης.
- 8) Οπτικοποίηση των προβλέψεων (predictions visualization): Οι πραγματικές και οι προβλεπόμενες τιμές απεικονίζονται με την χρήση του matplotlib, με το «Time Step» στον άξονα x και την «Power (kW)» στον άξονα y .

3.3.4 Επιλογή Βασικών Παραμέτρων Μοντέλου με AUTO-ARIMA

Η `auto_arima` είναι μια συνάρτηση που παρέχεται από την βιβλιοθήκη `pmdarima` στην Python και αυτοματοποιεί την διαδικασία επιλογής των βέλτιστων παραμέτρων (p, d, q) για ένα μοντέλο ARIMA [44]. Το ARIMA είναι ένα μοντέλο πρόβλεψης χρονοσειρών που περιλαμβάνει τρία βασικά στοιχεία: Auto Regressive (AR), Integration (I) και Moving Average (MA). Η επιλογή αυτών των παραμέτρων επηρεάζει σημαντικά την απόδοση του μοντέλου.

Ακολουθεί αναλυτικά ο τρόπος λειτουργίας του `auto_arima`:

- Αναζήτηση παραμέτρων: Το `auto_arima` χρησιμοποιεί έναν αλγόριθμο αναζήτησης για να διερευνήσει ένα εύρος πιθανών συνδυασμών παραμέτρων για το μοντέλο ARIMA.

Δοκιμάζει διαφορετικούς συνδυασμούς τιμών (p , d , q) για να βρει αυτόν που οδηγεί στην καλύτερη προσαρμογή του μοντέλου.

- Κριτήρια επιλογής: Χρησιμοποιείται ένα κριτήριο βελτιστοποίησης, όπως το AIC (Akaike Information Criterion) ή το BIC (Bayesian Information Criterion), για να αξιολογήσει την καλή προσαρμογή για διαφορετικούς συνδυασμούς παραμέτρων. Αυτά τα κριτήρια μετρούν τον συμβιβασμό μεταξύ της πολυπλοκότητας του μοντέλου και της καλής προσαρμογής.
- Εποχικότητα: Εάν τα δεδομένα της χρονοσειράς παρουσιάζουν εποχικότητα (επαναλαμβανόμενα μοτίβα σε τακτά χρονικά διαστήματα), το `auto_arima` μπορεί επίσης να αναζητήσει τις εποχικές παραμέτρους (P , D , Q) και την εποχική περίοδο (m) χρησιμοποιώντας τα ίδια κριτήρια βελτιστοποίησης.
- Εξωγενείς μεταβλητές: Το `auto_arima` μπορεί επίσης να χειριστεί χρονοσειρές με εξωγενείς μεταβλητές, οι οποίες είναι εξωτερικοί παράγοντες που μπορούν να επηρεάσουν την μεταβλητή-στόχο. Οι εξωγενείς μεταβλητές μπορούν να συμπεριληφθούν για την βελτίωση της ακρίβειας πρόβλεψης του μοντέλου.
- Βηματική επιλογή: Ο αλγόριθμος αναζήτησης εκτελεί μια διαδικασία σταδιακής επιλογής, ξεκινώντας με ένα απλό μοντέλο και προσθέτοντας σταδιακά πολυπλοκότητα. Σταματά όταν βρει έναν συνδυασμό παραμέτρων που βελτιστοποιεί το επιλεγμένο κριτήριο.
- Καλύτερο μοντέλο: Μόλις ολοκληρωθεί η αναζήτηση, το `auto_arima` επιστρέφει το μοντέλο ARIMA που ταιριάζει καλύτερα με βάση το επιλεγμένο κριτήριο. Αυτό το μοντέλο μπορεί στην συνέχεια να χρησιμοποιηθεί για την πραγματοποίηση προβλέψεων και την πρόβλεψη μελλοντικών τιμών.

Με βάση τα παραπάνω, ο αντίστοιχος κώδικας που χρησιμοποιήθηκε για την συγκεκριμένη εργασία, αφού εισάγει (`import`) τις απαραίτητες βιβλιοθήκες και χωρίζει, κατά τα γνωστά τα δεδομένα με `data splitting`, χρησιμοποιεί για τον ορισμό του μοντέλου την συνάρτηση `auto_arima`.

3.4 ΣΥΓΚΡΙΣΗ ΑΛΓΟΡΙΘΜΩΝ ARIMA ΚΑΙ LSTM

Στην ενότητα αυτή θα μελετηθεί η επίδραση του μοντέλου ARIMA στο LSTM και ο τρόπος με τον οποίο ο συνδυασμός των δύο μοντέλων θα μπορέσει ενδεχομένως να βελτιώσει την ακρίβεια των προβλέψεων. Ουσιαστικά, θα γίνει μια εισαγωγή στο θεωρητικό υπόβαθρο, ξεκινώντας από τις διαφορές των δύο μοντέλων. Η μελέτη των διαφορών τους είναι σημαντική για να διαπιστωθεί η ανάγκη συνδυασμού τους με στόχο τον συνδυασμό των πλεονεκτημάτων τους.

3.4.1 Διαφοροποίηση Μοντέλων

Το ARIMA και το LSTM είναι και τα δύο δημοφιλείς μέθοδοι για την πρόβλεψη χρονοσειρών, αλλά έχουν διαφορετικές βασικές προσεγγίσεις και χαρακτηριστικά. Ακολουθούν ορισμένες γενικές διαφορές μεταξύ των μοντέλων ARIMA και LSTM [43], [44]:

- Τύπος μοντέλου:
 - ARIMA: Το ARIMA είναι ένα στατιστικό μοντέλο, που επικεντρώνεται στην σύλληψη των σχέσεων αυτοπαλίνδρομου (AR) και κινητού μέσου

- (MA) μέσα σε μια χρονοσειρά με την διαφορίση των δεδομένων για να τα καταστήσει στάσιμα.
- LSTM: Το LSTM είναι ένας τύπος αναδρομικού νευρωνικού δικτύου, που έχει σχεδιαστεί για να χειρίζεται ακολουθίες δεδομένων, διατηρώντας μια εσωτερική κατάσταση μνήμης που μπορεί να συλλάβει εξαρτήσεις μεγάλης εμβέλειας στα δεδομένα.
- Εξάρτηση δεδομένων:
 - ARIMA: Τα μοντέλα ARIMA εξαρτώνται από την υπόθεση ότι η σχέση μεταξύ παρελθουσών και τρεχουσών παρατηρήσεων μπορεί να περιγραφεί από μερικές τιμές υστέρησης και κινητούς μέσους όρους.
 - LSTM: Τα μοντέλα LSTM μπορούν να συλλάβουν πολύπλοκες χρονικές εξαρτήσεις στα δεδομένα, καθιστώντας τα κατάλληλα για ακολουθίες με αλληλεπιδράσεις και μοτίβα μεγάλης εμβέλειας.
 - Χειρισμός εποχικότητας:
 - ARIMA: Τα μοντέλα ARIMA μπορούν να επεκταθούν για να χειριστούν εποχικά πρότυπα μέσω εποχικής διαφορίσης, εποχικών αυτοπαλίνδρομων όρων και κινητού μέσου όρου.
 - LSTM: Τα LSTM είναι ικανά να συλλάβουν την εποχικότητα και άλλα πολύπλοκα χρονικά πρότυπα χωρίς ρητή μηχανική χαρακτηριστικών.
 - Μηχανική χαρακτηριστικών:
 - ARIMA: Τα μοντέλα ARIMA απαιτούν συνήθως χειροκίνητη επιλογή της τάξης του μοντέλου (p, d, q) με βάση τα διαγράμματα αυτοσυσχέτισης και μερικής αυτοσυσχέτισης, η οποία περιλαμβάνει κάποιο βαθμό δοκιμής και σφάλματος.
 - LSTM: Τα LSTM μαθαίνουν τα χαρακτηριστικά αυτόματα από τα δεδομένα, μειώνοντας την ανάγκη για χειροκίνητη μηχανική των χαρακτηριστικών.
 - Προεπεξεργασία δεδομένων:
 - ARIMA: Το ARIMA προϋποθέτει ότι τα δεδομένα είναι στάσιμα ή μπορούν να γίνουν στάσιμα. Συχνά απαιτείται σταθεροποίηση της διακύμανσης και απομάκρυνση των τάσεων.
 - LSTM: Τα LSTM μπορούν να χειριστούν μη στάσιμα δεδομένα με εφαρμογή συνήθως κανονικοποίησης και κλιμάκωσης.
 - Πολυπλοκότητα:
 - ARIMA: Τα μοντέλα ARIMA αποτυπώνουν γραμμικές σχέσεις στα δεδομένα και είναι περιορισμένα στην ικανότητά τους να αποτυπώνουν μη γραμμικά πρότυπα.

- LSTM: Τα LSTM έχουν την ικανότητα να συλλαμβάνουν πολύπλοκες μη γραμμικές σχέσεις στα δεδομένα, καθιστώντας τα κατάλληλα για εργασίες με περίπλοκα μοτίβα.
- Χρόνος εκπαίδευσης:
 - ARIMA: Τα μοντέλα ARIMA εκπαιδεύονται σχετικά γρήγορα, ιδίως για σύνολα δεδομένων μικρού έως μέτριου μεγέθους.
 - LSTM: Τα LSTM, ως νευρωνικά δίκτυα, μπορεί να είναι υπολογιστικά απαιτητικά και ενδέχεται να απαιτούν μεγαλύτερους χρόνους εκπαίδευσης, ιδίως για μεγαλύτερα σύνολα δεδομένων ή πολύπλοκες αρχιτεκτονικές.
- Ορίζοντας πρόβλεψη:
 - ARIMA: Τα μοντέλα ARIMA είναι κατάλληλα για βραχυπρόθεσμες προβλέψεις με σχετικά μικρό αριθμό χρονικών βημάτων.
 - LSTM: Τα LSTM μπορούν να χειριστούν τόσο την βραχυπρόθεσμη, όσο και την μακροπρόθεσμη πρόβλεψη, καθιστώντας τα πιο ευέλικτα για διάφορους ορίζοντες πρόβλεψης.

Συνοπτικά, το ARIMA είναι μια κλασική στατιστική μέθοδος που βασίζεται σε αυτοπαλίνδρομες σχέσεις και κινητούς μέσους όρους, ενώ το LSTM είναι μια σύγχρονη προσέγγιση βασισμένη σε νευρωνικά δίκτυα, που μπορεί να συλλάβει περίπλοκα χρονικά πρότυπα.

3.4.2 Σημασία Συνδυασμού των δυο Μοντέλων

Παρατηρώντας τις διαφορές που εξετάστηκαν στην Ενότητα 3.4.1, είναι αντιληπτό γιατί είναι απαραίτητη η συνεισφορά του ARIMA στο LSTM για την βελτίωση της απόδοσης των προβλέψεων. Τα βασικά στοιχεία, που οδήγησαν στην ανάγκη αξιοποίησης του ARIMA, μπορούν να συνοψιστούν στα παρακάτω [43], [45]:

- Τα μοντέλα ARIMA είναι κατάλληλα για την σύλληψη γραμμικών τάσεων, εποχικότητας (ιδιαίτερα χρήσιμο όταν πρόκειται για δεδομένα που παρουσιάζουν επαναλαμβανόμενα μοτίβα σε συγκεκριμένα χρονικά διαστήματα) και αυτοσυσχέτισης σε δεδομένα χρονοσειρών, ενώ το LSTM μπορεί να συλλάβει τα μη γραμμικά και πολύπλοκα πρότυπα. Οπότε, έτσι συνδυάζονται τα πλεονεκτήματα των δύο μοντέλων.
- Ο συνδυασμός και των δύο μοντέλων μπορεί να οδηγήσει σε βελτιωμένη συνολική απόδοση και σταθερότητα πρόβλεψης.

3.4.3 Αναφορά στην Δημιουργία Υβριδικού Μοντέλου

Για την αξιοποίηση των πλεονεκτημάτων των δύο μοντέλων στο πλαίσιο της παρούσας διπλωματικής εργασίας διερευνήθηκε η κατασκευή ενός υβριδικού μοντέλου, δηλαδή ενός μοντέλου που συνδυάζει τις προβλέψεις από τα δύο μοντέλα ξεχωριστά (LSTM και ARIMA) και δημιουργεί νέες προβλέψεις με διαφορετική απόδοση. Για τον σκοπό αυτό μελετήθηκαν δύο βασικές μέθοδοι [43], [45].

- 1) Η πρώτη μέθοδος αφορά την εξαγωγή των προβλέψεων από κάθε μοντέλο ξεχωριστά και στην συνέχεια την δημιουργία προβλέψεων ως αποτέλεσμα του μέσου όρου των προβλέψεων των δύο μοντέλων.
- 2) Η δεύτερη μέθοδος αφορά την εξαγωγή προβλέψεων από το μοντέλο ARIMA και στην συνέχεια την τοποθέτηση αυτών των προβλέψεων ως είσοδο στο LSTM μαζί φυσικά και με τις υπόλοιπες εισόδους, που εξ αρχής είχε από το δοθέν αρχείο δεδομένων.

Πιο αναλυτικά η μεθοδολογία του υβριδικού μοντέλου θα μελετηθεί στο Κεφάλαιο 4.

ΥΒΡΙΔΙΚΟ ΜΟΝΤΕΛΟ LSTM ΚΑΙ ARIMA

4.1 ΓΕΝΙΚΑ

Στο πλαίσιο της βελτίωσης του μοντέλου LSTM αναζητήθηκαν μέθοδοι που θα οδηγούσαν στην ελάττωση των σφαλμάτων πρόβλεψης και, κατά επέκταση, στην βελτίωση της απόδοσης του μοντέλου. Ως μέθοδος βελτίωσης, επιλέχθηκε η δημιουργία ενός υβριδικού μοντέλου που θα συνδυάζε το αρχικό μοντέλο LSTM με ένα άλλο μοντέλο.

Η βελτίωση των μοντέλων LSTM με υβριδικές προσεγγίσεις μπορεί να είναι ιδιαίτερα επωφελής σε ορισμένα σενάρια και εξαρτάται από το συγκεκριμένο πρόβλημα και τα χαρακτηριστικά των δεδομένων. Ακολουθούν ορισμένοι λόγοι για τους οποίους η βελτίωση των LSTM με ένα υβριδικό μοντέλο είναι σημαντική [19], [23], [24], [46]:

- **Βελτιωμένη απόδοση:** Τα υβριδικά μοντέλα συνδυάζουν τα πλεονεκτήματα διαφορετικών τεχνικών μοντελοποίησης. Ενσωματώνοντας το LSTM με ένα άλλο μοντέλο, όπως ένα στατιστικό μοντέλο (όπως το ARIMA) ή ένα παραδοσιακό μοντέλο Μηχανικής Μάθησης, μπορεί δυναμικά να επιτευχθεί καλύτερη ακρίβεια πρόβλεψης. Αυτό ισχύει ιδιαίτερα όταν τα επιμέρους μοντέλα συμπληρώνουν, το ένα τις αδυναμίες του άλλου. Για παράδειγμα, το ARIMA μπορεί να χειρίζεται καλά τα βραχυπρόθεσμα πρότυπα, ενώ το LSTM συλλαμβάνει και τις μακροπρόθεσμες εξαρτήσεις.
- **Βελτιωμένη ανθεκτικότητα:** Τα υβριδικά μοντέλα μπορεί να είναι πιο ανθεκτικά από τα μεμονωμένα μοντέλα. Μπορεί να αποδίδουν καλά σε ένα ευρύτερο φάσμα μοτίβων δεδομένων και είναι λιγότερο πιθανό να προσαρμόζονται υπερβολικά σε συγκεκριμένα σύνολα δεδομένων. Αυτό το χαρακτηριστικό τους μπορεί να είναι απαραίτητο όταν πρόκειται για δεδομένα του πραγματικού κόσμου, τα οποία συχνά παρουσιάζουν διάφορες πολυπλοκότητες.
- **Ερμηνευσιμότητα:** Τα μοντέλα LSTM μπορεί να είναι δύσκολο να ερμηνευθούν λόγω της πολύπλοκης αρχιτεκτονικής τους. Τα υβριδικά μοντέλα μπορούν να ενσωματώσουν ερμηνεύσιμα στοιχεία, όπως γραμμικά μοντέλα ή δέντρα αποφάσεων, ώστε να παρέχουν πιο κατανοητές πληροφορίες για τις σχέσεις μέσα στα δεδομένα.
- **Μειωμένη υπολογιστική πολυπλοκότητα:** Τα μοντέλα LSTM, ιδίως όταν χρησιμοποιούνται σε αρχιτεκτονικές βαθιάς μάθησης, μπορεί να είναι υπολογιστικά απαιτητικά και να θέλουν σημαντικούς υπολογιστικούς πόρους. Τα υβριδικά μοντέλα μπορούν να μειώσουν την υπολογιστική επιβάρυνση με την προεπεξεργασία δεδομένων με απλούστερα μοντέλα, γεγονός που μπορεί να είναι ιδιαίτερα σημαντικό.

- Αντιμετώπιση περιορισμών: Τα μοντέλα LSTM έχουν περιορισμούς, όπως δυσκολία χειρισμού μεγάλων ακολουθιών ή απαίτηση μεγάλων ποσοτήτων δεδομένων για εκπαίδευση. Τα υβριδικά μοντέλα μπορούν να ενσωματώσουν τεχνικές που αντιμετωπίζουν αυτούς τους περιορισμούς, όπως είναι τα δίκτυα με ενισχυμένη μνήμη.

Είναι σημαντικό να σημειωθεί ότι η απόφαση για την χρήση ενός υβριδικού μοντέλου θα πρέπει να καθοδηγείται από μια λεπτομερή κατανόηση του συγκεκριμένου προβλήματος, των δεδομένων και των περιορισμών κάθε τεχνικής μοντελοποίησης.

4.2 ΔΕΔΟΜΕΝΑ ΕΙΣΟΔΟΥ

Τα δεδομένα εισόδου για τα υβριδικά μοντέλα είναι αντίστοιχα με αυτά των απλών μοντέλων. Επομένως, γίνεται εισαγωγή δεδομένων από ένα αρχείο δεδομένων (csv), που περιέχει ιστορικά δεδομένα για την παραγωγή ισχύος και για τους παράγοντες που την επηρεάζουν για κάθε λεπτό για όλο το έτος 2021. Υπάρχει βέβαια μια διαφοροποίηση.

Στην πρώτη περίπτωση υβριδικού μοντέλου, που λαμβάνονται υπόψη οι μέσες τιμές των προβλέψεων, οι εισοδοί είναι ακριβώς οι ίδιες που χρησιμοποιήθηκαν ξεχωριστά για τα απλά μοντέλα ARIMA και LSTM.

Αντίθετα, στην περίπτωση του δεύτερου υβριδικού μοντέλου οι προβλέψεις του ARIMA χρησιμοποιούνται ως είσοδος στο LSTM. Επομένως, στην περίπτωση αυτή, στο αρχικό αρχείο δεδομένων (csv), που περιέχει όλα τα δεδομένα για το έτος 2021, για κάθε λεπτό, κάθε ημέρας και για κάθε μέγεθος που μπορεί να επηρεάσει την παραγωγή ισχύος των ΦΒ, προστίθεται ακόμα μία στήλη. Η στήλη αυτή περιέχει τις προβλέψεις του ARIMA.

4.3 ΜΕΘΟΔΟΙ ΑΝΑΠΤΥΞΗΣ ΥΒΡΙΔΙΚΟΥ ΜΟΝΤΕΛΟΥ

Η δημιουργία υβριδικών μοντέλων χρησιμοποιώντας τις μέσες τιμές των προβλέψεων από δύο ή περισσότερα μοντέλα, όπως το ARIMA και το LSTM, είναι μια απλή και αποτελεσματική τεχνική. Η προσέγγιση αυτή αξιοποιεί την ποικιλομορφία των προβλέψεων που παράγονται από διαφορετικά μοντέλα, για να βελτιώσει την συνολική ακρίβεια πρόβλεψης.

Η μέθοδος, κατά την οποία οι προβλέψεις ενός μοντέλου χρησιμοποιούνται ως είσοδος σε ένα άλλο μοντέλο, είναι γνωστή ως *stacking* ή *stacked ensemble learning* [39]. Είναι μια προηγμένη τεχνική μάθησης συνόλου, που συνδυάζει τις προβλέψεις πολλαπλών βασικών μοντέλων (συνχά διαφορετικών τύπων) για την δημιουργία ενός μετα-μοντέλου που παρέχει ακριβέστερες προβλέψεις.

4.3.1 Μέθοδος Εξαγωγής Μέσης Τιμής Προβλέψεων

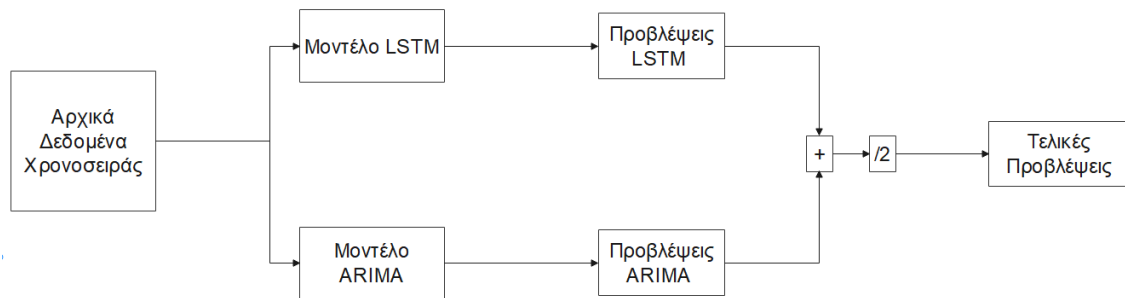
Στην ενότητα αυτή θα μελετηθεί η πρώτη μέθοδος δημιουργίας υβριδικού μοντέλου, που αφορά στην εξαγωγή μέσης τιμής των προβλέψεων. Αυτή είναι και η πιο απλή μέθοδος. Θα διερευνηθούν τα οφέλη της μεθόδου, τα σημεία που απαιτούν προσοχή, αλλά και η διαδικασία που ακολουθήθηκε για την υλοποίηση της μεθόδου.

Τα βασικά οφέλη των υβριδικών μοντέλων που χρησιμοποιούν μέσες προβλέψεις είναι τα εξής τρία [17], [39], [46]:

- Βελτιωμένη ανθεκτικότητα: Ο συνδυασμός προβλέψεων από διαφορετικά μοντέλα μπορεί να μειώσει τον αντίκτυπο των σφαλμάτων από οποιοδήποτε μεμονωμένο μοντέλο, καθιστώντας το υβριδικό μοντέλο πιο ανθεκτικό.
- Βελτιωμένη ακρίβεια: Τα υβριδικά μοντέλα παρέχουν συχνά ακριβέστερες προβλέψεις, επειδή καταγράφουν ένα ευρύτερο φάσμα προτύπων και εξαρτήσεων στα δεδομένα.
- Μείωση της υπερπροσαρμογής: Με τον μέσο όρο των προβλέψεων, μετριάζεται ο κίνδυνος υπερπροσαρμογής που μπορεί να προκύψει σε μεμονωμένα μοντέλα.

Τα βασικά βήματα αυτής της μεθόδου είναι τα ακόλουθα:

- Βήμα 1: Εκπαίδευση μοντέλων ARIMA και LSTM:
 - Εκπαιδύεται ένα μοντέλο ARIMA στα δεδομένα της χρονοσειράς. Αυτό μπορεί να γίνει, χρησιμοποιώντας την συνάρτηση `auto_arima` ή ρυθμίζοντας χειροκίνητα τις υπερπαραμέτρους με στόχο την εύρεση του καλύτερου μοντέλου ARIMA, για τα δεδομένα που παρέχονται.
 - Εκπαιδύεται ένα μοντέλο LSTM στα ίδια δεδομένα. Αυτό περιλαμβάνει τον ορισμό της αρχιτεκτονικής του δικτύου LSTM, την προεπεξεργασία των δεδομένων και την εκπαίδευση του μοντέλου. Συνήθως, για τον σκοπό αυτό χρησιμοποιούνται βιβλιοθήκες, όπως η `keras`, η `TensorFlow` ή η `PyTorch`.
- Βήμα 2: Δημιουργία προβλέψεων:
 - Χρησιμοποιείται το εκπαιδευμένο μοντέλο ARIMA για την δημιουργία προβλέψεων. Στην συνέχεια αυτές οι προβλέψεις αποθηκεύονται σε έναν ξεχωριστό πίνακα ή `DataFrame`.
 - Χρησιμοποιείται το εκπαιδευμένο μοντέλο LSTM για την υλοποίηση προβλέψεων για την ίδια χρονική περίοδο. Στην συνέχεια, αποθηκεύονται αυτές οι προβλέψεις σε ξεχωριστό πίνακα ή `DataFrame`.
- Βήμα 3: Δημιουργία υβριδικού μοντέλου
 - Υπολογίζεται ο μέσος όρος των προβλέψεων από το μοντέλο ARIMA και το LSTM για κάθε χρονικό βήμα στον ορίζοντα πρόβλεψης. Ο μέσος όρος μπορεί να υπολογιστεί χρησιμοποιώντας απλές πράξεις της Python, όπως η `np.mean()`.
- Βήμα 4: Αξιολόγηση και χρήση του υβριδικού μοντέλου
 - Για την αξιολόγηση του υβριδικού μοντέλου μπορούν να χρησιμοποιηθούν κατάλληλες μετρικές, όπως το μέσο τετραγωνικό σφάλμα (MSE) και το μέσο απόλυτο σφάλμα (MAE). Αυτό το βήμα βοηθά στην εξακρίβωση, ότι το υβριδικό μοντέλο βελτιώνει πράγματι την ακρίβεια των αποτελεσμάτων, σε σύγκριση με τα μεμονωμένα μοντέλα.



Σχήμα 4.1 Μέθοδος υβριδικού μοντέλου με εξαγωγή μέσης τιμής προβλέψεων

Με βάση τα παραπάνω βασικά βήματα, αναπτύχθηκε ο κώδικας σε Python που χρησιμοποιήθηκε στην παρούσα διπλωματική εργασία. Στην ουσία, πρόκειται για δύο βασικά κομμάτια κώδικα, εκ των οποίων το πρώτο αφορά την δημιουργία ενός νέου αρχείου (csv), που περιέχει τις μέσες τιμές των προβλέψεων και το δεύτερο αφορά την εξαγωγή κατάλληλων γραφημάτων προς σύγκριση και σφαλμάτων για την αξιολόγηση της απόδοσης. Η γενική μορφή αυτής της μεθοδολογίας παρουσιάζεται στο Σχήμα 4.1, στο οποίο παρατίθεται ένα διάγραμμα ροής για την μέθοδο πρόβλεψης, μέσω εξαγωγής της μέσης τιμής των προβλέψεων. Ουσιαστικά, τα αρχικά δεδομένα επεξεργάζονται από τα μοντέλα LSTM και ARIMA και αφού γίνει η εξαγωγή των προβλέψεών τους ξεχωριστά, υπολογίζεται η μέση τιμή τους.

Όσον αφορά το πρώτο βασικό υβριδικό μοντέλο εξαγωγής της μέσης τιμής των προβλέψεων, η μεθοδολογία είναι η ακόλουθη:

Ο κώδικας ξεκινά με την ανάγνωση δύο αρχείων (csv): `lstm_preds.csv` και `arima_preds_updated.csv`. Αυτά τα αρχεία περιέχουν προβλέψεις που έγιναν από τα μοντέλα LSTM και ARIMA, αντίστοιχα. Στην συνέχεια, ο κώδικας ελέγχει τα μήκη των δύο DataFrames (`lstm_length` και `arima_length`) για να διασφαλίσει ότι ταιριάζουν. Έπειτα, συγχωνεύει τα δύο DataFrames με βάση την στήλη 'timestep', δημιουργώντας ένα νέο DataFrame με όνομα `merged_df`. Έπειτα, αποθηκεύει το συγχωνευμένο DataFrame πίσω στο `lstm_preds.csv`.

Στην συνέχεια, διαβάζει εκ νέου το αρχείο `lstm_preds.csv`, το οποίο τώρα περιέχει τις συγχωνευμένες προβλέψεις και από τα δύο μοντέλα. Στην συνέχεια, αναδιατάσσει τις στήλες, έτσι ώστε οι στήλες 'timestep' και 'test_data' να έρχονται πρώτες, ακολουθούμενες από τις προβλέψεις από το μοντέλο LSTM και το μοντέλο ARIMA. Το αναδιατεταγμένο πλαίσιο δεδομένων αποθηκεύεται ξανά στο αρχείο `lstm_preds.csv`.

Για το νέο `lstm_preds.csv`, υπολογίζεται ο μέσος όρος των δύο τελευταίων στηλών "`lstm_power (kW)`" και "`arima_power (kW)`" κατά μήκος των γραμμών. Έπειτα, αναθέτονται αυτές οι μέσες τιμές σε μια νέα στήλη με όνομα "`mean_preds (kW)`". Έπειτα, το ενημερωμένο πλαίσιο δεδομένων αποθηκεύεται στο αρχείο `lstm_preds.csv`. Αυτή η νέα στήλη αντιπροσωπεύει τον μέσο όρο των προβλέψεων που έγιναν από τα μοντέλα LSTM και ARIMA για κάθε χρονικό βήμα, παρέχοντας μια υβριδική προσέγγιση πρόβλεψης.

Στην συνέχεια, ακολουθεί η οπτικοποίηση των αποτελεσμάτων σε γράφημα, που περιλαμβάνει τα ακόλουθα βήματα: Ο κώδικας διαβάζει αρχικά τα δεδομένα από το αρχείο `lstm_preds.csv`, το οποίο περιέχει τις προβλέψεις που έγιναν από το μοντέλο LSTM, το μοντέλο ARIMA και τις μέσες προβλέψεις.

Στην συνέχεια, μετατρέπει τις στήλες του DataFrame σε πίνακες NumPy για ευκολία στην σχεδίαση και τους υπολογισμούς. Συγκεκριμένα, οι στήλες που μετατρέπονται σε πίνακες numpy είναι οι ακόλουθες:

- `timestep`: Περιέχει χρονοσφραγίδες που έχουν μετατραπεί σε αντικείμενα NumPy
- `actual_power`: Αντιπροσωπεύει τις πραγματικές τιμές ισχύος σε kW.
- `lstm_power`: Περιέχει τις προβλεπόμενες τιμές ισχύος από το μοντέλο LSTM σε kW.
- `arima_power`: Περιέχει τις προβλεπόμενες τιμές ισχύος από το μοντέλο ARIMA σε kW.
- `mean_preds`: Περιέχει τις μέσες προβλέψεις, οι οποίες είναι ο μέσος όρος των προβλέψεων LSTM και ARIMA σε kW.

Ακολούθως, ο κώδικας απεικονίζει όλες τις στήλες στο ίδιο γράφημα χρησιμοποιώντας τις χρονοσφραγίδες ως άξονα x . Κάθε γραμμή αντιπροσωπεύει διαφορετικές σειρές δεδομένων, συμπεριλαμβανομένης της πραγματικής ισχύος, των προβλέψεων LSTM, των προβλέψεων ARIMA και των μέσων προβλέψεων. Αυτή η απεικόνιση επιτρέπει την σύγκριση προβλέψεων από διαφορετικά μοντέλα με τις πραγματικές τιμές ισχύος. Βέβαια, δεν είναι απόλυτα ευκρινές το αποτέλεσμα, λόγω του ότι όλες οι γραμμές εμφανίζονται σε κοινό γράφημα και η σύγκριση βασίζεται στην οπτική και μόνο παρατήρηση.

Για τον λόγο αυτό, επιλέχθηκε να γίνεται και συγκριτική αναπαράσταση μόνο των προβλέψεων του υβριδικού μοντέλου μαζί με τις πραγματικές τιμές της ισχύος σε ξεχωριστό γράφημα, επιτρέποντας μια πιο προσεκτική εξέταση του πόσο καλά ευθυγραμμίζονται οι μέσες προβλέψεις με την πραγματική ισχύ.

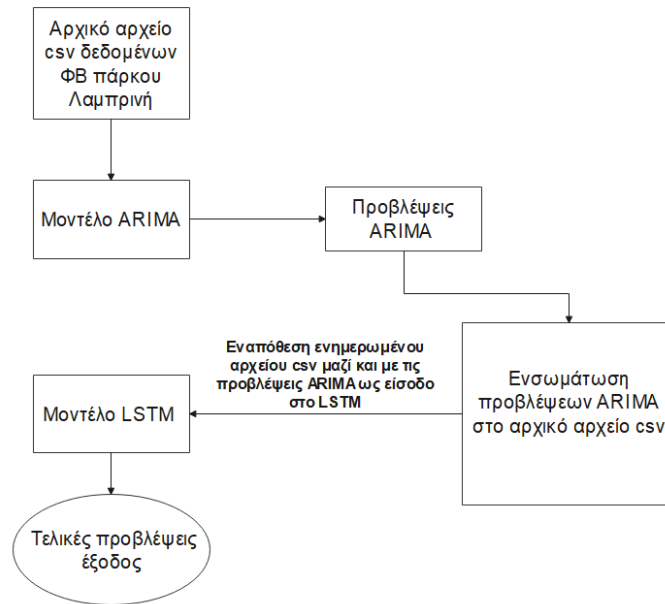
Για την πιο ακριβή αξιολόγηση της απόδοσης, γίνεται υπολογισμός μετρικών απόδοσης. Συγκεκριμένα, υπολογίζονται και εκτυπώνονται τρεις μετρικές επιδόσεων για τις μέσες προβλέψεις σε σύγκριση με την πραγματική ισχύ. Αυτές είναι οι εξής:

- Μέσο τετραγωνικό σφάλμα (RMSE): Αποτελεί ένα μέτρο των διαφορών μεταξύ των προβλεπόμενων και των πραγματικών τιμών.
- Κανονικοποιημένο RMSE (NRMSE): Πρόκειται για κανονικοποιημένο RMSE με βάση το εύρος των πραγματικών τιμών ισχύος.
- Μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE): Είναι ένα ποσοστιαίο μέτρο της ακρίβειας των μέσων προβλέψεων σε σύγκριση με τις πραγματικές τιμές.

Αυτές οι μετρικές επιδόσεων παρέχουν πληροφορίες σχετικά με το πόσο καλά το υβριδικό μοντέλο, που αποτελείται από προβλέψεις LSTM και ARIMA, ευθυγραμμίζεται με τις πραγματικές τιμές ισχύος. Ο λόγος που έχει επιλεγεί να υπολογίζονται τα σφάλματα και για τα υβριδικά μοντέλα, είναι για να γίνει μετέπειτα σύγκριση με τις αντίστοιχες μετρικές που υπολογίστηκαν ξεχωριστά για τα απλά μοντέλα LSTM και ARIMA.

4.3.2 Μέθοδος Χρήσης Προβλέψεων ARIMA ως Είσοδος στο LSTM

Η χρήση προβλέψεων ARIMA ως είσοδο σε ένα μοντέλο LSTM (Long Short-Term Memory) είναι μια κοινή τεχνική στην πρόβλεψη χρονοσειρών. Γενικά, ο συνδυασμός διαφορετικών μοντέλων πρόβλεψης είναι συχνά πιο ισχυρός από το αντίστοιχο απλό μεμονωμένο μοντέλο.



Σχήμα 4.2. Μέθοδος εισαγωγής προβλέψεων ARIMA ως είσοδο στο LSTM

Χρησιμοποιώντας τις προβλέψεις ARIMA ως είσοδο σε ένα μοντέλο LSTM, γίνεται αξιοποίηση των πλεονεκτημάτων και των δύο μοντέλων. Το ARIMA είναι καλό στην σύλληψη γραμμικών τάσεων και εποχικότητας, ενώ το LSTM μπορεί να συλλάβει σύνθετα, μη γραμμικά πρότυπα [47], [48].

Στην γενική μορφή, προτού γίνει η τροφοδότηση του LSTM με τις προβλέψεις ARIMA είναι σημαντικό τα δεδομένα χρονοσειράς να έχουν υποστεί κατάλληλη προεπεξεργασία. Αυτό περιλαμβάνει τον χειρισμό των δεδομένων που λείπουν, την κλιμάκωση των δεδομένων και την ευθυγράμμιση των χρονοσφραγίδων μεταξύ των δύο μοντέλων.

Αυτός ο συνδυασμός ARIMA και LSTM αποτελεί μια μορφή μοντελοποίησης, όπου συνδυάζονται πολλαπλά μοντέλα για την βελτίωση της ακρίβειας. Αυτό μπορεί να οδηγήσει σε βελτιωμένες προβλέψεις, ιδίως όταν τα μεμονωμένα μοντέλα έχουν συμπληρωματικά πλεονεκτήματα, όπως συμβαίνει σε αυτή την περίπτωση.

Κατά την δημιουργία του μοντέλου είναι σημαντικό να αποφασίζεται ο ορίζοντας πρόβλεψης. Το ARIMA παράγει συνήθως βραχυπρόθεσμες προβλέψεις, ενώ το LSTM μπορεί να χειριστεί και πιο μακροπρόθεσμες προβλέψεις. Οπότε, το υβριδικό μοντέλο πρέπει να προσαρμόζεται κατάλληλα. Στην παρούσα εργασία έχει επιλεγεί πρόβλεψη για μία ημέρα, που καλύπτει τις προϋποθέσεις και των δύο μοντέλων.

Επιπλέον, θα πρέπει να γίνεται σωστή ρύθμιση των υπερπαραμέτρων. Η λεπτομερής ρύθμιση των υπερπαραμέτρων τόσο για το μοντέλο ARIMA, όσο και για το μοντέλο LSTM είναι απαραίτητη. Για το ARIMA, αυτό περιλαμβάνει την επιλογή της τάξης (p , d , q), ενώ για το LSTM, περιλαμβάνει την αρχιτεκτονική (αριθμός στρωμάτων και μονάδων) και τον ρυθμό μάθησης. Το βήμα αυτό έχει ήδη πραγματοποιηθεί από την υλοποίηση των απλών μοντέλων ξεχωριστά, οπότε στο στάδιο αυτό δεν απαιτείται κάποια επιπλέον αλλαγή.

Σε όλη την διάρκεια υλοποίησης του μοντέλου θα πρέπει να γίνεται παρακολούθηση και ενημέρωση των δεδομένων, αν κριθεί απαραίτητο. Τα δεδομένα χρονοσειρών μπορούν να αλλάξουν με την πάροδο του χρόνου, λόγω διαφόρων παραγόντων. Οπότε, παίζει βασικό ρόλο η παρακολούθηση και διαρκής ενημέρωση του υβριδικού μοντέλου για να διατηρείται η ακρίβειά του.

Γενικά, η συγκεκριμένη μέθοδος υλοποίησης του υβριδικού μοντέλου έχει ποικίλες εφαρμογές. Ενδεικτικά αναφέρονται διάφορες εργασίες, για τις οποίες η συνεισφορά του καθίσταται πολύτιμη, όπως για την πρόβλεψη χρονοσειρών, για την πρόβλεψη κατανάλωσης ενέργειας, για χρηματοοικονομικές προβλέψεις και για προβλέψεις ζήτησης.

Επομένως, το ερώτημα εδώ είναι το εξής: Γιατί επιλέγεται αυτή η μέθοδος; Η απάντηση βρίσκεται στην ποικιλία πλεονεκτημάτων που προσφέρει. Τα βασικά του πλεονεκτήματα είναι τα εξής [17], [39]:

- Βελτιωμένη ακρίβεια: Ένα από τα κύρια πλεονεκτήματα ενός υβριδικού μοντέλου είναι η βελτιωμένη ακρίβεια πρόβλεψης. Τα μοντέλα ARIMA είναι αποτελεσματικά στην σύλληψη γραμμικών τάσεων και εποχικότητας, ενώ τα LSTM υπερέρχουν στην σύλληψη σύνθετων, μη γραμμικών προτύπων. Συνδυάζοντας τα πλεονεκτήματα και των δύο μοντέλων, μπορούν να γίνουν πιο ακριβείς προβλέψεις.
- Ανθεκτικότητα: Τα υβριδικά μοντέλα είναι συχνά πιο ανθεκτικά από τα μεμονωμένα μοντέλα. Μπορούν να χειριστούν καλύτερα θορυβώδη ή ακανόνιστα δεδομένα, επειδή κάθε μοντέλο αντισταθμίζει τις αδυναμίες του άλλου.
- Προσαρμοστικότητα: Τα δεδομένα χρονοσειρών μπορεί να παρουσιάζουν διαφορετικά χαρακτηριστικά με την πάροδο του χρόνου. Τα μοντέλα ARIMA μπορεί να αποδίδουν καλά σε μια περίοδο, ενώ τα LSTM να υπερέρχουν σε μια άλλη. Τα υβριδικά μοντέλα μπορούν να προσαρμόζονται στα μεταβαλλόμενα πρότυπα δεδομένων χρησιμοποιώντας τις ιδιότητες του κατάλληλου μοντέλου σε κάθε περίπτωση.
- Χειρισμός μακροχρόνιων εξαρτήσεων: Τα LSTM είναι ιδιαίτερα καλά στην καταγραφή των μακροπρόθεσμων εξαρτήσεων σε δεδομένα χρονοσειρών. Συνδυάζοντάς τα με ARIMA, μπορεί να βελτιωθεί η ικανότητα του ARIMA και για πιο ακριβείς μακροπρόθεσμες προβλέψεις.

Στο σημείο αυτό μελετάται η μέθοδος που ακολουθήθηκε για την εισαγωγή των προβλέψεων ARIMA ως είσοδο στο LSTM. Η υλοποίηση έγινε και πάλι σε γλώσσα Python και αναπαρίσταται στο Σχήμα 4.2. Ουσιαστικά, οι προβλέψεις που εξάγονται ξεχωριστά από την υλοποίηση του μοντέλου ARIMA εισάγονται στο μοντέλο LSTM και στην συνέχεια το LSTM, έχοντας μία επιπλέον είσοδο (που αντιστοιχεί στις προβλέψεις του ARIMA), παράγει νέες προβλέψεις. Πιο αναλυτικά, η υλοποίηση που ακολουθήθηκε αναπτύσσεται ακολούθως:

Αρχικά με τη βοήθεια του κώδικα ARIMA, που επεξηγήθηκε αναλυτικά στην Ενότητα 3.3, εξάγονται προβλέψεις για την ημέρα-στόχο που έχει επιλεγεί για πρόβλεψη. Οι προβλέψεις αυτές αποθηκεύονται σε ένα ξεχωριστό αρχείο (csv), που περιέχει δύο στήλες, εκ των οποίων η πρώτη αφορά τις αντίστοιχες χρονικές στιγμές (χρονοσφραγίδες) και η δεύτερη τις αντίστοιχες προβλέψεις. Στην συνέχεια, στόχος είναι οι τιμές αυτές για τις προβλέψεις να ενσωματωθούν στο αρχικό αρχείο (csv) που εισάγεται στο LSTM και το οποίο περιλαμβάνει τα δεδομένα του πάρκου της Λαμπρινής. Ο κώδικας που υλοποιεί αυτόν τον στόχο περιλαμβάνει τα εξής βήματα:

- Φόρτωση δεδομένων από το αρχικό σύνολο δεδομένων (initial_dataset): Πρόκειται για ένα αρχείο CSV με όνομα data_2021_PV_with_zeros.csv. Αυτό το σύνολο δεδομένων περιέχει τα πραγματικά δεδομένα παραγωγής ενέργειας.
- Προετοιμασία δεδομένων:

- `new_dataset`: Δημιουργείται ένα αντίγραφο του αρχικού συνόλου δεδομένων ως `new_dataset`. Αυτό το αντίγραφο τροποποιείται, ώστε να περιλαμβάνει προβλέψεις ARIMA.
- Φόρτωση προβλέψεων ARIMA από ένα σύνολο (`predictions_dataset`): Φορτώνει ένα δεύτερο σύνολο δεδομένων από ένα αρχείο CSV με όνομα `arima_preds.csv`. Αυτό το σύνολο δεδομένων περιέχει τις προβλέψεις ARIMA για τα ίδια δεδομένα χρονοσειράς.
- Προσθήκη στηλών: Στο `new_dataset` προστίθεται μια νέα στήλη με όνομα "`arima_power (kW)`". Αρχικά, αυτή η στήλη συμπληρώνεται με τις πραγματικές τιμές κατανάλωσης ισχύος από το αρχικό σύνολο δεδομένων. Ο σκοπός είναι να υπάρχει μια συνεπής δομή για το νέο σύνολο δεδομένων με τις αρχικές τιμές σε αυτή την στήλη.
- Στην συνέχεια χρησιμοποιείται η μεταβλητή `common_indices`: Αυτή η μεταβλητή περιέχει τους κοινούς δείκτες (χρονοσφραγίδες) μεταξύ του `new_dataset` και του `predictions_dataset`. Εξασφαλίζει ότι οι προβλέψεις ARIMA προστίθενται μόνο στις αντίστοιχες χρονοσφραγίδες στο νέο σύνολο δεδομένων.
- Ενημέρωση των προβλέψεων ARIMA: Ο κώδικας ενημερώνει την στήλη "`arima_power (kW)`" στο `new_dataset`, με τις προβλέψεις ARIMA από το `predictions_dataset`. Αυτό γίνεται για τις χρονοσφραγίδες που υπάρχουν στο `common_indices`. Ουσιαστικά, αντικαθιστά τις αρχικές πραγματικές τιμές, με τις προβλέψεις ARIMA όπου είναι διαθέσιμες. Έτσι, το τελικό αρχείο CSV θα περιέχει μια επιπλέον στήλη, η οποία για τα δεδομένα που αντιστοιχούν στις χρονοσφραγίδες για το σύνολο ελέγχου, θα έχει τοποθετήσει τις προβλέψεις του ARIMA.
- Αποθήκευση του νέου συνόλου δεδομένων: Το τροποποιημένο `new_dataset`, που περιλαμβάνει τώρα τις προβλέψεις ARIMA, αποθηκεύεται σε ένα νέο αρχείο CSV με όνομα `new_multi.csv`.
- Εκτύπωση επιβεβαίωσης: Εκτυπώνεται ένα μήνυμα για να επιβεβαιωθεί ότι το νέο αρχείο CSV έχει δημιουργηθεί επιτυχώς.

4.4 ΣΗΜΑΣΙΑ ΔΗΜΙΟΥΡΓΙΑΣ ΥΒΡΙΔΙΚΟΥ ΜΟΝΤΕΛΟΥ

Σε γενικές γραμμές, η σημασία αξιοποίησης του υβριδικού μοντέλου αναλύθηκε διεξοδικά στις Ενότητες 4.1, 4.2 και 4.3. Συνοπτικά, το βασικό πλεονέκτημα είναι ο συνδυασμός των πλεονεκτημάτων των δύο μοντέλων, αφενός μεν για την εξάλειψη ή συρρίκνωση των αντίστοιχων δυσλειτουργιών τους, αφετέρου δε για την βελτίωση της απόδοσης των τελικών προβλέψεων. Στο σημείο αυτό κάτι τέτοιο έχει κυρίως θεωρητική υπόσταση. Στο Κεφάλαιο 5, που θα παρουσιαστούν τα αποτελέσματα των προβλέψεων για κάθε περίπτωση, ο ισχυρισμός αυτός θα παγιωθεί και θα τεκμηριωθεί με αριθμούς.

ΑΠΟΤΕΛΕΣΜΑΤΑ

5.1 ΥΛΟΠΟΙΗΣΗ ΑΛΓΟΡΙΘΜΩΝ ΚΑΙ ΕΞΑΓΩΓΗ ΔΙΑΓΡΑΜΜΑΤΩΝ

Στο Κεφάλαιο 3 έγινε η ανάπτυξη, βήμα προς βήμα, των μοντέλων LSTM και ARIMA, που υλοποιήθηκαν σε γλώσσα Python, για την παρούσα διπλωματική εργασία. Συνοπτικά, ο κώδικας για το μοντέλο LSTM περιλαμβάνει την διαδικασία φόρτωσης δεδομένων χρονοσειρών, την προεπεξεργασία τους, την δημιουργία ενός μοντέλου LSTM, την εκπαίδευση του μοντέλου, την πραγματοποίηση προβλέψεων και την αξιολόγηση της απόδοσης του μοντέλου [13], [49]. Περιλαμβάνει επίσης οπτικοποίηση, μέσω διαγραμμάτων, για την καλύτερη κατανόηση των δεδομένων και των αποτελεσμάτων.

Αντίστοιχα, ο κώδικας του μοντέλου ARIMA σε Python φορτώνει ένα σύνολο δεδομένων χρονοσειρών, το προεπεξεργάζεται με τον χειρισμό των ακραίων τιμών και χρησιμοποιεί την μοντελοποίηση ARIMA για να κάνει προβλέψεις για έναν καθορισμένο χρονικό ορίζοντα. Στην συνέχεια, αξιολογεί την απόδοση του μοντέλου, ως προς τα RMSE, NRMSE και MAPE και οπτικοποιεί τα αποτελέσματα [13], [49]. Τέλος, αποθηκεύει τις προβλέψεις, με τις αντίστοιχες χρονοσφραγίδες σε ένα νέο αρχείο CSV.

Επομένως, για κάθε ένα μοντέλο ξεχωριστά θα παρουσιαστούν τα αντίστοιχα σφάλματα και διαγράμματα. Με βάση την διαδικασία που περιγράφηκε στην Ενότητα 2.1.4, επιλέχθηκαν για αρχή μια ηλιόλουστη (24/08/2021), μία συννεφιασμένη (28/11/2021) και μία ημι-συννεφιασμένη ημέρα (29/12/2021). Επίσης, ύστερα από δοκιμές επιλέχθηκε εύρος συνόλου εκπαίδευσης ενός μηνός. Η επιλογή αυτή έγινε, αφού για μεγαλύτερο περιθώριο δεδομένων εκπαίδευσης τα αντίστοιχα σφάλματα δεν επέφεραν κάποια ουσιαστική βελτίωση. Στην συνέχεια, για σύνολο εκπαίδευσης κάθε μήνα για όλο το έτος 2021, μέχρι και την εβδομάδα πρόβλεψης, υπολογίστηκαν τα αντίστοιχα σφάλματα.

Επόμενο βήμα ήταν ο υπολογισμός των αντίστοιχων σφαλμάτων, επιλέγοντας μια ηλιόλουστη, μία συννεφιασμένη και μία ημι-συννεφιασμένη ημέρα από κάθε εποχή του χρόνου. Δηλαδή, έγινε αναζήτηση των ημερών αυτών, μέσω της διαδικασίας που περιγράφηκε στην Ενότητα 2.1.4. Έτσι, έγινε επιλογή τριών ημερών, για κάθε μία από τις εποχές (Χειμώνας, Άνοιξη, Καλοκαίρι και Φθινόπωρο). Στην συνέχεια, υπολογίστηκαν τα αντίστοιχα σφάλματα, λαμβάνοντας ως σύνολο δεδομένων ένα μήνα πίσω.

Όλες οι παραπάνω προβλέψεις έγιναν με τα μοντέλα LSTM και ARIMA ξεχωριστά, αλλά και με τα υβριδικά τους μοντέλα. Με βάση τα αποτελέσματα των προβλέψεων αυτών, θα παρουσιαστούν τα σφάλματα και τα διαγράμματα που προέκυψαν.

5.1.1 Διαγράμματα Αλγορίθμου LSTM

Στην Ενότητα αυτή θα μελετηθούν και θα επεξηγηθούν όλα τα διαγράμματα που προέκυψαν από την υλοποίηση του κώδικα για το LSTM. Θα γίνει μια ενδελεχής ανάπτυξη της σημασίας που έχουν τα αποτελέσματα των γραφημάτων αυτών για την κατανόηση του

αλγόριθμου και την αξιολόγηση της απόδοσής του. Οπότε, επεξηγείται ένα προς ένα κάθε διάγραμμα:


- Χάρτης θερμότητας-πίνακας συσχέτισης: Η συσχέτιση είναι ένα στατιστικό μέτρο που ποσοτικοποιεί την σχέση μεταξύ δύο μεταβλητών [5], [14]. Το πιο συχνά χρησιμοποιούμενο μέτρο συσχέτισης είναι ο συντελεστής συσχέτισης Pearson (r) που κυμαίνεται μεταξύ -1 και 1, όπου:
 - 1 υποδηλώνει τέλεια θετική γραμμική σχέση, που σημαίνει ότι καθώς αυξάνεται η μία μεταβλητή, αυξάνεται αναλογικά και η άλλη.
 - -1 υποδηλώνει μια τέλεια αρνητική γραμμική σχέση, που σημαίνει ότι καθώς αυξάνεται η μία μεταβλητή, η άλλη μεταβλητή μειώνεται αναλογικά.
 - 0 υποδηλώνει ότι δεν υπάρχει γραμμική σχέση μεταξύ των μεταβλητών.

Η σχέση που εκφράζει τον συντελεστή αυτόν είναι η εξής:

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (5.1)$$

Όπου x_i , y_i δύο μεταβλητές μεταξύ των οποίων θέλουμε να υπολογίσουμε τη συσχέτιση και \bar{x} , \bar{y} οι αντίστοιχες μέσες τιμές των μεταβλητών x , y .

Η συνάρτηση `corr()` υπολογίζει τη συσχέτιση (correlation), κατά ζεύγη μεταξύ των στηλών του DataFrame. Υπολογίζει τον συντελεστή συσχέτισης, ο οποίος μετρά την ισχύ και την κατεύθυνση της γραμμικής σχέσης μεταξύ δύο μεταβλητών. Το αποτέλεσμα είναι ένας πίνακας συσχέτισης.

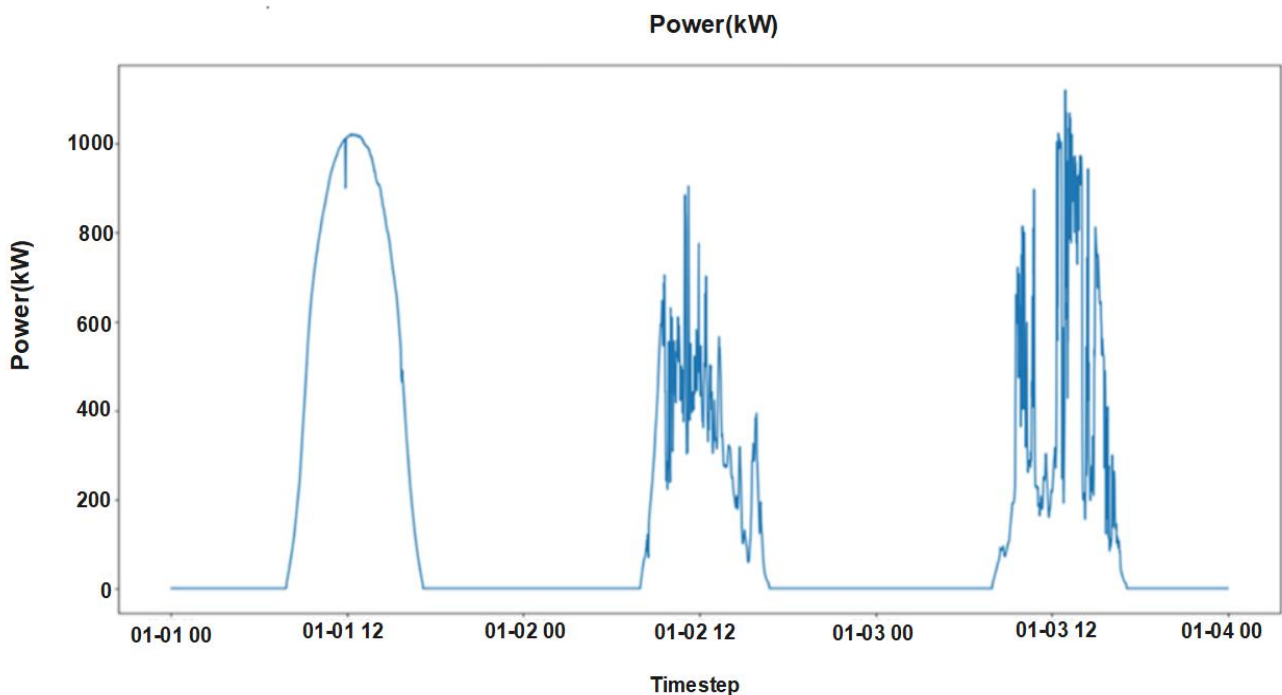


Σχήμα 5.1: Correlation matrix για πρόβλεψη ηλιόλουστης ημέρας

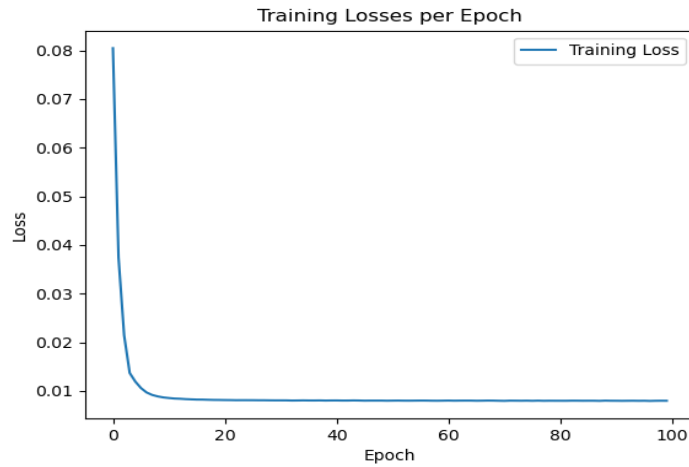
Στην συνέχεια, χρησιμοποιείται η συνάρτηση `sns.heatmap()` από την βιβλιοθήκη Seaborn για την δημιουργία μιας απεικόνισης του πίνακα συσχέτισης σε χάρτη θερμότητας. Ο χάρτης θερμότητας παρέχει μια χρωματικά κωδικοποιημένη αναπαράσταση των συσχετίσεων, όπου οι υψηλότερες τιμές εμφανίζονται συνήθως με διαφορετικό χρώμα από τις χαμηλότερες τιμές.

Στο σχήμα 5.1 διακρίνονται όλα τα μεγέθη που επηρεάζουν την παραγωγή ισχύος. Σε κάθε κουτάκι παριστάνεται ο συντελεστής Pearson. Όπου ο συντελεστής αυτός πλησιάζει κατά απόλυτη τιμή το 1, είτε είναι και ίσος κατά απόλυτη τιμή με 1, σημαίνει ότι τα δύο μεγέθη, κατακόρυφα και οριζόντια, που αντιστοιχούν στο κουτάκι αυτό έχουν «ισχυρή» σχέση μεταξύ τους, οπότε η εξέλιξη του ενός επηρεάζει σε μεγάλο βαθμό το άλλο.

- Απεικόνιση δεδομένων με τον χρόνο: Για ευρύτερη κατανόηση της μεταβολής των δεδομένων σε σχέση με τον χρόνο, δημιουργήθηκαν τα αντίστοιχα διαγράμματα. Από αυτά, ιδιαίτερο ενδιαφέρον παρουσιάζει αυτό της παραγωγής ισχύος, που είναι και το μέγεθος-στόχος για πρόβλεψη. Στο Σχήμα 5.2 επιλέγεται η αναπαράσταση της παραγωγής ισχύος για τρεις ημέρες μέσα στο έτος, εκ των οποίων η μία έχει περισσότερη ηλιοφάνεια και οι υπόλοιπες έχουν και ώρες συννεφιάς. Δεν έχει νόημα η απεικόνιση να γίνει για περισσότερες ημέρες, γιατί δεν θα είναι ευκρινής η μεταβλητότητα του μοντέλου. Φυσικά, όπως ήταν αναμενόμενο το μέγιστο του γραφήματος για τις ηλιόλουστες ημέρες είναι σαφώς πιο ψηλά από το αντίστοιχο των συννεφιασμένων ημερών, αφού όσο περισσότερο ηλιοφάνεια έχει μία ημέρα, τόσο μεγαλύτερη είναι και η παραγωγή ισχύος για τα φωτοβολταϊκά πάνελ. Επίσης και στις δύο περιπτώσεις, πιο υψηλές τιμές εμφανίζονται τις ώρες κοντά στο μεσημέρι, δηλαδή περίπου από 12 το μεσημέρι μέχρι 4μ.μ., πράγμα επίσης αναμενόμενο, δεδομένου ότι εκείνες τις ώρες ο ήλιος είναι πιο έντονος.




Σχήμα 5.2: Παραγωγή ισχύος για 3 ημέρες σε (kW)




Σχήμα 5.3: Απώλειες εκπαίδευσης σε σχέση με τον αριθμό των εποχών

- Διάγραμμα απωλειών: Στο σημείο του κώδικα που τίθεται `loss='mse'`, καθορίζεται η συνάρτηση απώλειας ως 'mse', που σημαίνει μέσο τετραγωνικό σφάλμα. Αυτή η συνάρτηση απώλειας είναι κατάλληλη για εργασίες παλινδρόμησης, όπου στόχος είναι η πρόβλεψη αριθμητικών τιμών. Το MSE μετρά τον μέσο όρο των τετραγωνικών διαφορών μεταξύ των προβλεπόμενων τιμών και των πραγματικών τιμών. Ο στόχος του μοντέλου κατά την εκπαίδευση, είναι να ελαχιστοποιήσει αυτή την απώλεια, πράγμα που σημαίνει, ότι οι προβλεπόμενες τιμές πρέπει να είναι όσο το δυνατόν πιο κοντά στις πραγματικές τιμές. Έτσι, στο μοντέλο LSTM, η συνάρτηση απώλειας (MSE) ποσοτικοποιεί πόσο καλά οι προβλεπόμενες τιμές "Power (kW)" ταιριάζουν με τις πραγματικές τιμές στα δεδομένα εκπαίδευσης. Το μοντέλο προσαρμόζει τα βάρη και τις πολώσεις του, για να ελαχιστοποιήσει αυτή την απώλεια, καθιστώντας τις προβλέψεις του πιο ακριβείς καθώς η εκπαίδευση προχωράει. Επομένως, υπολογίζει τις απώλειες εκπαίδευσης (training losses). Οι απώλειες εκπαίδευσης είναι ένα μέτρο, που υποδηλώνει το πόσο καλά αποδίδει το μοντέλο στην διάρκεια της διαδικασίας εκπαίδευσης. Επομένως, όσο μικρότερες είναι αυτές οι απώλειες, τόσο καλύτερα «μαθαίνει» το μοντέλο μοτίβα για τις σχέσεις ανάμεσα στα δεδομένα. Δεδομένου ότι επιζητείται ελαχιστοποίηση των απωλειών, είναι λογικό πως σε κάθε επανάληψη εποχής (epoch) θα πρέπει οι απώλειες να είναι όλο και μικρότερες με συνέπεια το γράφημα που τις αναπαριστά σε σχέση με τον αριθμό των εποχών να είναι μία φθίνουσα συνάρτηση, όπως φαίνεται στο Σχήμα 5.3.
- Διάγραμμα προβλέψεων: Για την οπτικοποίηση των προβλέψεων και την κατανόηση της ακρίβειας των αποτελεσμάτων, επιλέχθηκε να γίνει μια αναπαράστασή τους σε σχέση με τις πραγματικές τιμές της ημέρας αυτής. Στα Σχήματα 5.4 και 5.5 παρουσιάζονται σε μορφή γραφήματος οι προβλέψεις και οι πραγματικές τιμές για μία καλή πρόβλεψη για τα μοντέλα LSTM και ARIMA αντίστοιχα. Οι ημέρες πρόβλεψης επιλέχθηκαν ύστερα από δοκιμές, ώστε το σφάλμα πρόβλεψης να είναι μικρό. Το ερώτημα επομένως που τίθεται είναι, τι σημαίνει «καλή» και «κακή» πρόβλεψη και πόσο περίπου πρέπει να είναι το σφάλμα, για να θεωρηθεί μία πρόβλεψη ακριβής. Στο πλαίσιο των δοκιμών έχει επιλεγεί ως σύνολο εκπαίδευσης ένας μήνας. Αν ο στόχος είναι η πρόβλεψη για μια ηλιόλουστη ημέρα του καλοκαιριού και ως σύνολο

εκπαίδευσης οριστεί κάποιος καλοκαιρινός μήνας, οι προβλέψεις θα εμφανίζουν πολύ καλή ακρίβεια, ενώ, αν αντίθετα τεθεί ως σύνολο εκπαίδευσης κάποιος χειμερινός μήνας (ο οποίος εκ των πραγμάτων θα περιέχει πολλές συννεφιασμένες ή ημισυννεφιασμένες ημέρες), τότε οι προβλέψεις για την ηλιόλουστη μέρα προφανώς και θα παρουσιάζουν μεγαλύτερο σφάλμα. Το ίδιο ισχύει αντίστροφα και για πρόβλεψη μια συννεφιασμένης ημέρας. Τα ακριβή όρια σφάλματος για καλή πρόβλεψη θα αναλυθούν στην Ενότητα 5.2.



Σχήμα 5.4: Προβλέψεις και πραγματικές τιμές για μία καλή πρόβλεψη με LSTM



Σχήμα 5.5: Προβλέψεις και πραγματικές τιμές για μία καλή πρόβλεψη με ARIMA

5.1.2 Διαγράμματα Αλγορίθμου ARIMA

Ο κώδικας ARIMA αξιοποιείται για την βελτίωση του LSTM . Πρώτα όμως πρέπει να αξιολογηθεί η δική του απόδοση, δηλαδή να μελετηθεί το πόσο ακριβείς είναι προβλέψεις. Για τον λόγο αυτό παρουσιάζεται το Διάγραμμα του Σχήματος 5.5, των προβλέψεων σε σχέση με τις πραγματικές τιμές ισχύος για μία καλή πρόβλεψη.


5.1.3 Διαγράμματα Υβριδικού Μέσης Τιμής LSTM και ARIMA

Στην Ενότητα αυτή θα γίνει μια οπτική σύγκριση των προβλέψεων για τα μοντέλα ARIMA, LSTM και για το υβριδικό τους, που χρησιμοποιεί την μέση τιμή των προβλέψεων. Επομένως, για το σκοπό αυτό θα παρουσιαστούν δύο διαγράμματα. Το πρώτο θα περιλαμβάνει τέσσερις γραφικές παραστάσεις: μία για τις προβλέψεις του LSTM, μία για τις προβλέψεις του μοντέλου ARIMA, μία για τις προβλέψεις της πρώτης μεθόδου του υβριδικού μοντέλου (που υπολογίζει τις μέσες τιμές των προβλέψεων) και μία για τις πραγματικές τιμές. Το δεύτερο διάγραμμα θα περιλαμβάνει μόνο τις προβλέψεις του υβριδικού και τις αντίστοιχες πραγματικές τιμές για πιο ευκρινές αποτέλεσμα.

Όπως είναι αντιληπτό από το Σχήμα 5.6 δεν είναι απολύτως διακριτές οι προβλέψεις. Αυτό συμβαίνει, γιατί πράγματι πρόκειται για πολύ καλές προβλέψεις, με σχετικά μικρό σφάλμα. Επίσης, με λίγη παρατηρητικότητα, διακρίνεται η μέση τιμή των προβλέψεων των δύο μοντέλων με το κόκκινο χρώμα, η οποία βρίσκεται ανάμεσα στα δύο μοντέλα που αναπαρίστανται με την πορτοκαλί και πράσινη γραμμή.


Για μεγαλύτερη ευκρίνεια και αποτύπωση των προβλέψεων του υβριδικού μοντέλου σε σχέση με τις πραγματικές τιμές δημιουργήθηκε και το Σχήμα 5.7.

Predictions of Power(kW) with LSTM, ARIMA and Hybrid model of mean predictions vs Actual Values



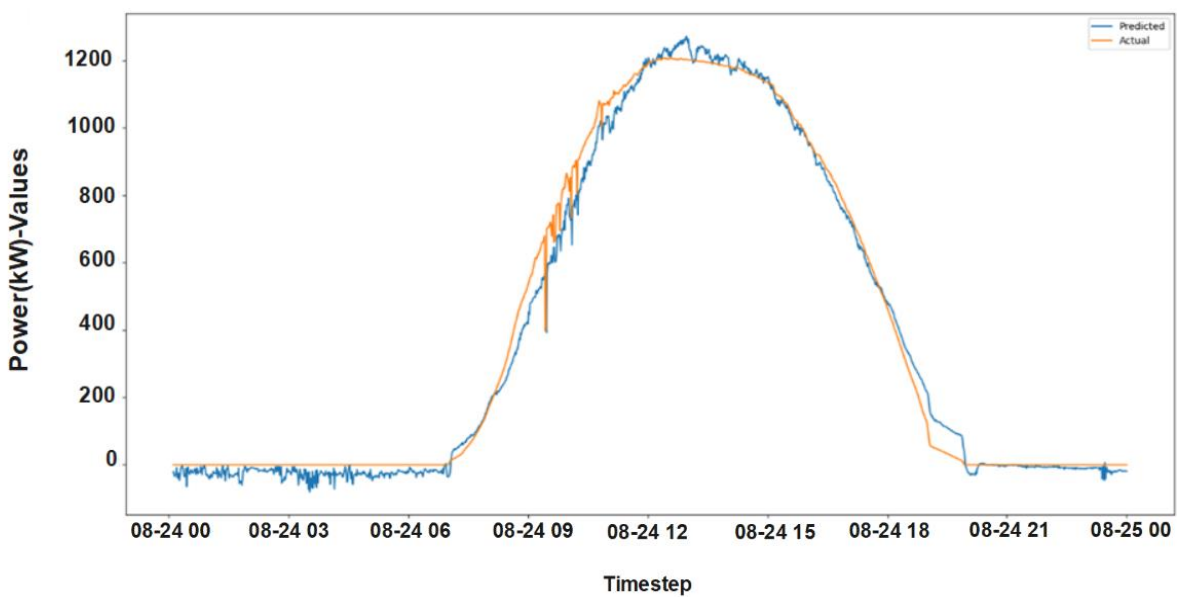
Σχήμα 5.6: Συγκεντρωτικό διάγραμμα προβλέψεων μοντέλων LSTM,ARIMA και πρώτης μεθόδου υβριδικού τους σε σχέση με τις αντίστοιχες πραγματικές τιμές

Predictions of Power(kW) with Hybrid model of mean predictions vs Actual Values



Σχήμα 5.7: Γραφική αναπαράσταση υβριδικού μοντέλου μέσης τιμής των προβλέψεων σε σχέση με τις πραγματικές τιμές.

Power(kW)- Predicted vs Actual values of Hybrid model ARIMA as input to LSTM



Σχήμα 5.8: Σύγκριση προβλέψεων υβριδικού μοντέλου ARIMA ως είσοδος στο LSTM με τις πραγματικές τιμές

5.1.4 Διαγράμματα Υβριδικού ARIMA ως Είσοδος στο LSTM

Στην Ενότητα αυτή επεξηγούνται τα αποτελέσματα από την υλοποίηση της δεύτερης μεθόδου υβριδικού μοντέλου που χρησιμοποιήθηκε και η οποία αφορά την εξαγωγή προβλέψεων από το μοντέλο ARIMA και την εισαγωγή των προβλέψεων αυτών ως είσοδο στο

αντίστοιχο μοντέλο LSTM, για την εξαγωγή νέων προβλέψεων. Για το μοντέλο αυτό παρουσιάζεται το αντίστοιχο Σχήμα 5.8 σύγκρισης των τελικών τιμών πρόβλεψης του υβριδικού μοντέλου σε σχέση με τις πραγματικές τιμές.

Όπως διαφαίνεται από το Σχήμα 5.8 οι προβλέψεις είναι πολύ κοντά στις πραγματικές τιμές, δηλαδή πρόκειται για μία καλή πρόβλεψη.

5.2 ΣΦΑΛΜΑΤΑ ΑΛΓΟΡΙΘΜΩΝ ΓΙΑ ΚΑΘΕ ΜΗΝΑ

Στην Ενότητα αυτή θα μελετηθούν οι μετρικές που χρησιμοποιούνται για την αξιολόγηση της απόδοσης των προβλέψεων. Για τον σκοπό αυτό, υπολογίζονται τα αντίστοιχα σφάλματα. Ο υπολογισμός γίνεται με τους εξής τρόπους :

- **RMSE (Root Mean Squared Error):** Αντιπροσωπεύει την τετραγωνική ρίζα του μέσου όρου των τετραγωνικών διαφορών, μεταξύ των προβλεπόμενων και των πραγματικών τιμών (Μέσο Τετραγωνικό Σφάλμα). Είναι μια ευρέως χρησιμοποιούμενη μετρική για την αξιολόγηση της ακρίβειας ενός προγνωστικού μοντέλου. Μετρά το μέσο μέγεθος του σφάλματος μεταξύ των προβλεπόμενων και των πραγματικών τιμών. Ο ακριβής υπολογισμός έγινε μέσω της σχέσης (5.2), όπου *predicted*, *actual* οι προβλεπόμενες και πραγματικές τιμές αντίστοιχα [5], [14], [50]:

$$RMSE = \sqrt{\frac{1}{n} * \sum (predicted - actual)^2} \quad (5.2)$$

- **NRMSE (Normalized Root Mean Squared Error):** Είναι μια κανονικοποιημένη έκδοση του RMSE (Κανονικοποιημένο Μέσο Τετραγωνικό σφάλμα). Ουσιαστικά, επιτρέπει την σύγκριση τιμών RMSE σε διαφορετικά σύνολα δεδομένων με διαφορετικές κλίμακες. Ο υπολογισμός του γίνεται διαιρώντας το *RMSE* με το εύρος των πραγματικών δεδομένων (*max - min*). Δηλαδή η διαφορά αυτή είναι το εύρος της μεταβλητής στόχου στο σύνολο ελέγχου. Οπότε, η αντίστοιχη εξίσωση που προκύπτει είναι:

$$NRMSE = \frac{RMSE}{(max-min)} \quad (5.3)$$

- **MAPE (Mean Absolute Percentage Error):** Το MAPE (Μέσο Απόλυτο Ποσοστιαίο Σφάλμα) χρησιμοποιείται για την αξιολόγηση της ακρίβειας ενός μοντέλου πρόβλεψης και μετρά την μέση ποσοστιαία διαφορά μεταξύ των προβλεπόμενων τιμών και των πραγματικών τιμών. Υπολογίζεται γενικά από την σχέση (5.4) στην οποία A_i είναι η εκάστοτε πραγματική τιμή, F_i η εκάστοτε προβλεπόμενη τιμή και n ο αριθμός των παρατηρήσεων [5]:

$$MAPE = \frac{1}{n} * \sum_{i=1}^n \frac{|A_i - F_i|}{A_i} \quad (5.4)$$

- Στην περίπτωση βέβαια του σφάλματος MAPE και επειδή πολλές από τις πραγματικές τιμές είναι μηδενικές, υπάρχει το πρόβλημα του απειρισμού. Για να αποφευχθεί αυτό, επιλέχθηκε στον παρονομαστή να χρησιμοποιηθεί η ονομαστική τιμή του πάρκου, η οποία για το πάρκο της Λαμπρινής είναι 1550,78 kW. Στην περίπτωση αυτή η σχέση (5.4) μετασχηματίζεται στην (5.5), όπου A_i είναι η εκάστοτε πραγματική τιμή, F_i η εκάστοτε προβλεπόμενη τιμή, n ο αριθμός των παρατηρήσεων και *nominal* η ονομαστική τιμή του πάρκου:

$$MAPE = \frac{1}{n} * \sum_{i=1}^n \frac{|A_i - F_i|}{nominal} \quad (5.5)$$

Το ερώτημα που τίθεται στο σημείο αυτό είναι, ποια είναι τα αντίστοιχα όρια που κάνουν μία πρόβλεψη καλή, κακή ή μέτρια. Παρακάτω αναλύονται τα όρια για τα NRMSE και MAPE επί τοις εκατό (%) [5], [51]:

- Καλή πρόβλεψη: Στην περίπτωση αυτή οι προβλέψεις του μοντέλου είναι πολύ κοντά στις πραγματικές τιμές. Ωστόσο, το τι θεωρείται "καλή" πρόβλεψη μπορεί να διαφέρει ανάλογα με την κλίμακα των δεδομένων. Γενικά, ισχύουν τα παρακάτω όρια:
 - NRMSE: Μια καλή πρόβλεψη έχει συνήθως $NRMSE < 10\%$. Αυτό σημαίνει ότι τα σφάλματα του μοντέλου είναι μικρά σε σχέση με το εύρος των δεδομένων και οι προβλέψεις είναι καλά κλιμακωμένες στα δεδομένα.
 - MAPE: Μια καλή πρόβλεψη έχει συχνά χαμηλό MAPE, συνήθως μικρότερο από 10% ή ακόμη και 5% . Αυτό δείχνει ότι οι προβλέψεις του μοντέλου είναι πολύ κοντά στις πραγματικές τιμές, ως ποσοστό των πραγματικών τιμών. Γενικά, ένα MAPE κάτω του 5% μπορεί να θεωρηθεί εξαιρετικό.
- Μέτρια πρόβλεψη: Στην περίπτωση αυτή, οι προβλέψεις του μοντέλου έχουν κάποιο επίπεδο σφάλματος, αλλά εξακολουθούν να είναι αποδεκτές για μία συγκεκριμένη εφαρμογή.
 - NRMSE: Μια μέτρια πρόβλεψη θα μπορούσε να έχει $10\% \leq NRMSE \leq 20\%$, αλλά να είναι κατά προτίμηση πιο κοντά στο κατώτερο άκρο. Αυτό σημαίνει ότι τα σφάλματα του μοντέλου είναι κάπως μεγαλύτερα σε σύγκριση με το εύρος των δεδομένων, αλλά βρίσκονται εντός ενός αποδεκτού εύρους για την εφαρμογή.
 - MAPE: Μια ημι-καλή πρόβλεψη μπορεί να έχει MAPE μεταξύ 10% και 20% . Ένα τέτοιο ποσοστό μπορεί να θεωρηθεί αποδεκτό για ορισμένες εφαρμογές, όπου η ακρίβεια δεν είναι κρίσιμη.
- Κακή πρόβλεψη: Στην περίπτωση αυτή οι προβλέψεις του μοντέλου έχουν μεγάλη διασπορά σφαλμάτων σε σύγκριση με τις πραγματικές τιμές. Το τι θεωρείται "κακή" πρόβλεψη εξαρτάται από το συγκεκριμένο πρόβλημα, αλλά σε γενικές γραμμές ισχύουν τα εξής:
 - NRMSE: Μια κακή πρόβλεψη έχει συνήθως $NRMSE$ σημαντικά μεγαλύτερο από 10% και συνήθως $NRMSE > 20\%$. Αυτό σημαίνει ότι τα σφάλματα του μοντέλου είναι μεγάλα σε σύγκριση με το εύρος των δεδομένων και οι προβλέψεις δεν είναι καλά κλιμακωμένες με τα δεδομένα.
 - MAPE: Μια πολύ κακή πρόβλεψη έχει συχνά MAPE μεγαλύτερο από 20% ή ακόμη και 50% . Αυτό υποδηλώνει ότι οι προβλέψεις του μοντέλου έχουν μεγάλο ποσοστιαίο σφάλμα σε σύγκριση με τις πραγματικές τιμές και διαφέρουν σημαντικά από την πραγματικότητα.

Είναι ζωτικής σημασίας να τονιστεί, ότι αυτά τα όρια αποτελούν γενικές κατευθυντήριες γραμμές και μπορεί να διαφέρουν σημαντικά μεταξύ διαφορετικών εφαρμογών. Αυτό που είναι αποδεκτό σε ένα πλαίσιο, μπορεί να μην είναι σε ένα άλλο.

Με βάση τα παραπάνω όρια σφάλματων, υπολογίστηκαν τα σφάλματα και για τα δύο μοντέλα πρόβλεψης, αλλά και για τα υβριδικά τους και κατασκευάστηκαν και τα αντίστοιχα ραβδογράμματα αναπαράστασής τους.


5.2.1 Σφάλματα LSTM για Δεδομένα Εκπαίδευσης κάθε Μήνα του Έτους

Στην Ενότητα αυτή μελετώνται τα σφάλματα που προέκυψαν από την υλοποίηση του κώδικα για το μοντέλο LSTM. Ο κώδικας υλοποιήθηκε, με σύνολο δεδομένων ελέγχου μία ηλιόλουστη, μια ημι-ηλιόλουστη και μία συννεφιασμένη ημέρα αντίστοιχα, ενώ ως σύνολο δεδομένων εκπαίδευσης θεωρήθηκε ένας μήνας. Η διαδικασία επαναλήφθηκε για δεδομένα εκπαίδευσης κάθε μήνα του έτους 2021 και τα αποτελέσματα καταγράφηκαν σε μορφή πίνακα, αλλά και σε κατάλληλο ραβδόγραμμα. Ο λόγος που επιλέχθηκε η αναπαράσταση και σε ραβδόγραμμα είναι για την πιο σωστή παρατήρηση της ακρίβειας του μοντέλου σε διαφορετικές συνθήκες. Η ακρίβεια είναι κάτι σχετικό και επηρεάζει άμεσα την ποιότητα της πρόβλεψης. Αν για παράδειγμα θεωρηθεί πρόβλεψη για μία ηλιόλουστη ημέρα του καλοκαιριού, τότε είναι προφανές, ότι για σύνολο εκπαίδευσης κάποιον καλοκαιρινό μήνα, η ακρίβεια θα είναι μεγαλύτερη, λόγω της περισσότερης ηλιοφάνειας. Αντίθετα, για σύνολο δεδομένων εκπαίδευσης χειμερινό και φθινοπωρινό μήνα (που θα περιλαμβάνει αρκετές συννεφιασμένες ημέρες) αναμένεται μικρότερη ακρίβεια και επομένως μεγαλύτερο σφάλμα.

Με βάση τον πίνακα 5.1, κατασκευάστηκε και το ραβδόγραμμα του Σχήματος 5.9, που αναπαριστά τα σφάλματα σε μορφή ραβδογράμματος. Όπως ήταν αναμενόμενο, παρατηρούνται μικρότερα σφάλματα προς το κέντρο του γραφήματος που αφορούν τους καλοκαιρινούς μήνες με περισσότερη ηλιοφάνεια, ενώ για τους χειμερινούς μήνες παρατηρούνται ακόμα και σφάλματα εκτός ορίων, δηλαδή κοντά στο 20% ή σε μερικές περιπτώσεις και μεγαλύτερα από αυτό.

Πίνακας 5.1: Σφάλματα κώδικα LSTM για πρόβλεψη ηλιόλουστης ημέρας (24/08/2021)

ΜΗΝΕΣ	MAPE (%)	NRMSE (%)
Ιανουάριος	26,42%	18,97%
Φεβρουάριος	4,23%	5,21%
Μάρτιος	11,98%	7,29%
Απρίλιος	5,71%	5,06%
Μάιος	3,86%	3,91%
Ιούνιος	3,66%	3,37%
Ιούλιος	3,79%	2,61%
Αύγουστος	2,09%	2,31%



Σχήμα 5.9: Ραβδόγραμμα σφαλμάτων μοντέλου LSTM για ηλιόλουστη ημέρα (24/08/2021)

Κατά αντιστοιχία, παρουσιάζονται οι πίνακες 5.2 και 5.3, αλλά και τα αντίστοιχα ραβδογράμματα στα Σχήματα 5.10 και 5.11 για μια ημι-ηλιόλουστη και για μια συννεφιασμένη ημέρα αντίστοιχα. Όπως είναι λογικό, σε μία συννεφιασμένη ημέρα, τα σφάλματα που θα πλησιάζουν τα όρια ή θα είναι εκτός ορίων θα αφορούν κυρίως δεδομένα εκπαίδευσης καλοκαιρινών μηνών, ενώ αντίθετα μικρότερα και καλύτερα σφάλματα θα προκύπτουν για δεδομένα εκπαίδευσης χειμερινών ή και φθινοπωρινών μηνών.


Στην ημι-ηλιόλουστη ημέρα θα επικρατεί μία ενδιάμεση κατάσταση, που έχει ως αποτέλεσμα, τα περισσότερα σφάλματα να βρίσκονται εντός ορίων. Αυτό συμβαίνει, γιατί στους περισσότερους μήνες του έτους, υπάρχουν και ηλιόλουστες και συννεφιασμένες ημέρες, αλλά και ημέρες στις οποίες επικρατεί μία ενδιάμεση κατάσταση ηλιοφάνειας και συννεφιάς. Επομένως το αποτέλεσμα κατά μέσο όρο καλύπτει την περίπτωση των ημι-ηλιόλουστων ημερών.

Πίνακας 5.2: Σφάλματα LSTM για πρόβλεψη ημι-ηλιόλουστης ημέρας (29/12/2021)

ΜΗΝΕΣ	MAPE (%)	NRMSE (%)
Ιανουάριος	4.32%	7.87%
Φεβρουάριος	1.34%	4.82%
Μάρτιος	1.96%	4.26%
Απρίλιος	2.32%	4.67%
Μάιος	8.53%	10.76%
Ιούνιος	4.83%	8.02%
Ιούλιος	5.82%	8.98%

Πίνακας 5.2: Σφάλματα LSTM για πρόβλεψη ημι-ηλιόλουστης ημέρας (29/12/2021) (συνέχεια)

ΜΗΝΕΣ	MAPE (%)	NRMSE(%)
Αύγουστος	6.52%	12.31%
Σεπτέμβριος	7.85%	9.85%
Οκτώβριος	3.60%	5.63%
Νοέμβριος	2.47%	4.51%
Δεκέμβριος	2.43%	4.97%




Σχήμα 5.10: Ραβδόγραμμα σφαλμάτων μοντέλου LSTM για ημι-ηλιόλουστη ημέρα (29/12/2021)

Πίνακας 5.3: Σφάλματα LSTM για πρόβλεψη συννεφιασμένης ημέρας (28/11/2021)

ΜΗΝΕΣ	MAPE (%)	NRMSE(%)
Ιανουάριος	2.09%	3.21%
Φεβρουάριος	2.19%	3.44%
Μάρτιος	2.89%	3.72%
Απρίλιος	3.99%	4.25%
Μάιος	7.26%	6.83%

Πίνακας 5.3: Σφάλματα LSTM για πρόβλεψη συννεφιασμένης ημέρας (28/11/2021) (συνέχεια)

ΜΗΝΕΣ	MAPE (%)	NRMSE(%)
Ιούνιος	3.35%	4.97%
Ιούλιος	8.06%	7.24%
Αύγουστος	8.73%	8.46%
Σεπτέμβριος	14.45%	11.90%
Οκτώβριος	4.62%	5.39%
Νοέμβριος	3.61%	3.94%




Σχήμα 5.11: Ραβδόγραμμα σφαλμάτων μοντέλου LSTM για συννεφιασμένη ημέρα (28/11/2021)

5.2.2 Σφάλματα ARIMA για Δεδομένα Εκπαίδευσης κάθε Μήνα του Έτους

Με βάση όσα αναφέρθηκαν στην Ενότητα 5.2.1, τα γενικά στοιχεία για τα όρια των σφαλμάτων και την ακρίβεια της πρόβλεψης ισχύουν σε κάθε περίπτωση. Επομένως, στην Ενότητα αυτή, θα παρουσιαστούν οι αντίστοιχοι πίνακες και τα αντίστοιχα ραβδογράμματα που προέκυψαν από την υλοποίηση του κώδικα ARIMA.

Πίνακας 5.4: Σφάλματα κώδικα ARIMA για πρόβλεψη ηλιόλουστης ημέρας (24/08/2021)

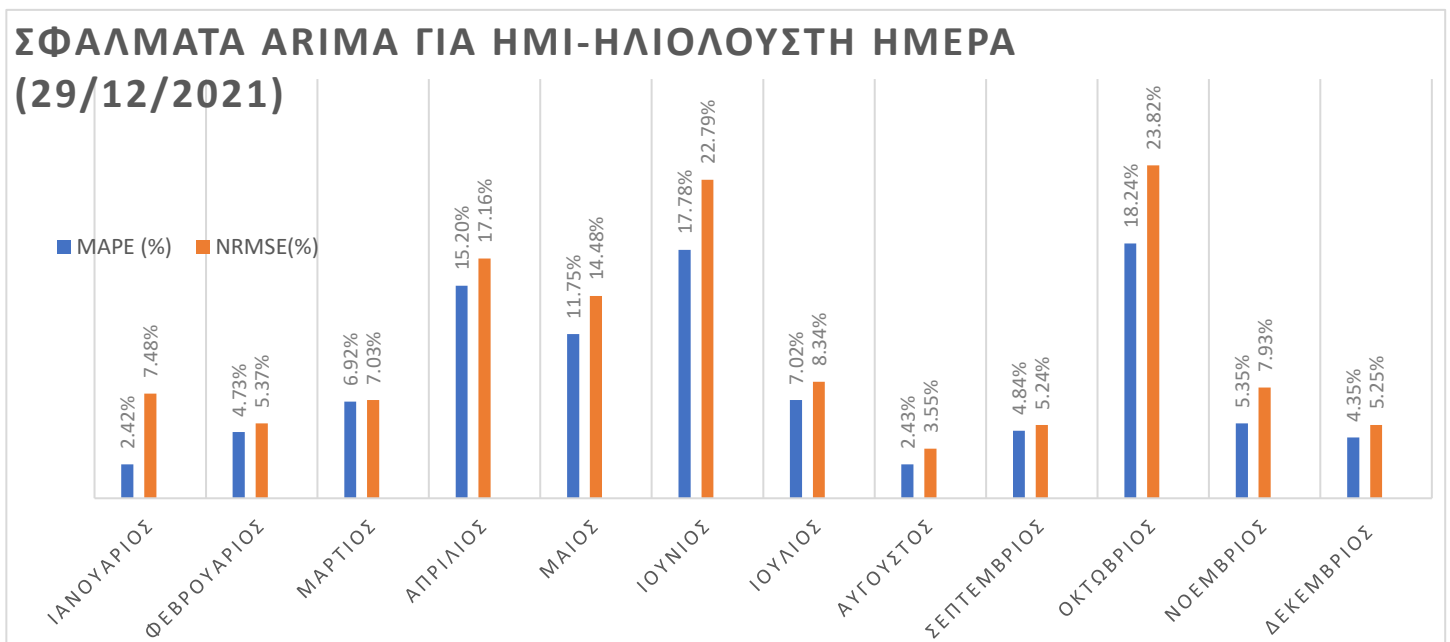
ΜΗΝΕΣ	MAPE(%)	NRMSE(%)
Ιανουάριος	19.84%	15.12%
Φεβρουάριος	25.70%	17.60%
Μάρτιος	26.70%	17.05%
Απρίλιος	13.88%	11.34%
Μάιος	6.66%	6.32%
Ιούνιος	3.82%	4.25%
Ιούλιος	3.02%	5.03%
Αύγουστος	3.91%	5.32%



Σχήμα 5.12: Ραβδόγραμμα σφαλμάτων μοντέλου ARIMA για ηλιόλουστη ημέρα (24/08/2021)

Πίνακας 5.5: Σφάλματα κώδικα ARIMA για πρόβλεψη ημι-ηλιόλουστης ημέρας (29/12/2021)

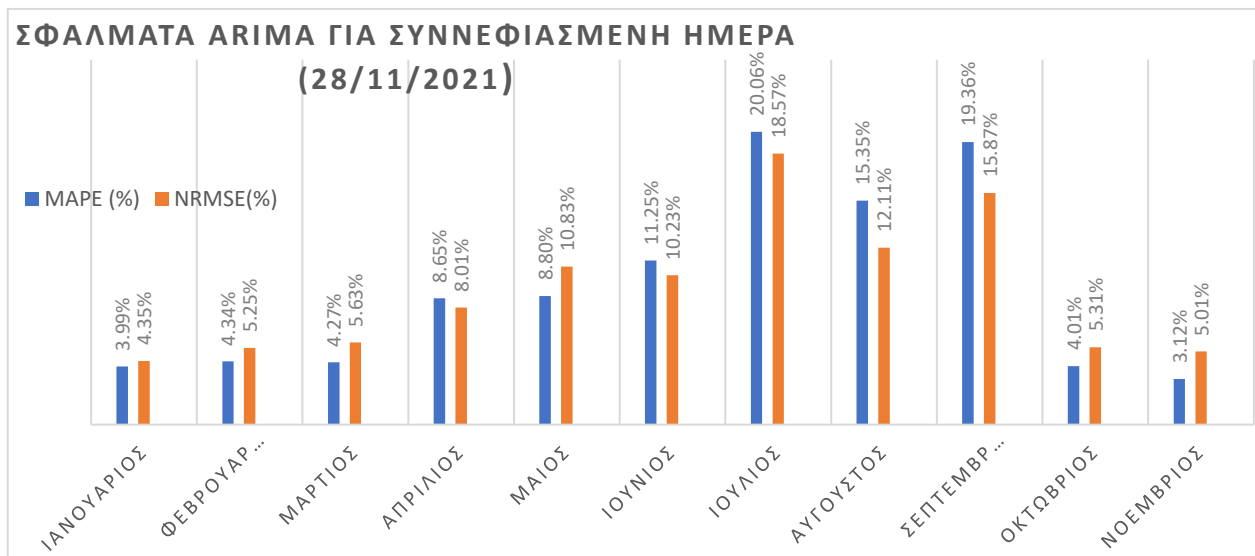
ΜΗΝΕΣ	MAPE(%)	NRMSE(%)
Ιανουάριος	2.42%	7.48%
Φεβρουάριος	4.73%	5.37%
Μάρτιος	6.92%	7.03%
Απρίλιος	15.20%	17.16%
Μάιος	11.75%	14.48%
Ιούνιος	17.78%	22.79%
Ιούλιος	7.02%	8.34%
Αύγουστος	2.43%	3.55%
Σεπτέμβριος	4.84%	5.24%
Οκτώβριος	18.24%	23.82%
Νοέμβριος	5.35%	7.93%
Δεκέμβριος	4.35%	5.25%



Σχήμα 5.13: Ραβδόγραμμα σφαλμάτων ARIMA για ημι-ηλιόλουστη ημέρα (29/12/2021)

Πίνακας 5.6: Σφάλματα κώδικα ARIMA για πρόβλεψη συννεφιασμένης ημέρας (28/11/2021)

ΜΗΝΕΣ	MAPE(%)	NRMSE(%)
Ιανουάριος	3.99%	4.35%
Φεβρουάριος	4.34%	5.25%
Μάρτιος	4.27%	5.63%
Απρίλιος	8.65%	8.01%
Μάιος	8.80%	10.83%
Ιούνιος	11.25%	10.23%
Ιούλιος	20.06%	18.57%
Αύγουστος	15.35%	12.11%
Σεπτέμβριος	19.36%	15.87%
Οκτώβριος	4.01%	5.31%
Νοέμβριος	3.12%	5.01%




Σχήμα 5.14: Ραβδόγραμμα σφαλμάτων μοντέλου ARIMA για συννεφιασμένη ημέρα (28/11/2021)

5.2.3 Σφάλματα Υβριδικού Μέσης Τιμής Προβλέψεων LSTM και ARIMA

Στην Ενότητα αυτή θα παρατεθούν οι αντίστοιχοι πίνακες και τα αντίστοιχα ραβδογράμματα σφαλμάτων για την πρώτη περίπτωση υβριδικού μοντέλου, κατά την οποία λαμβάνεται η μέση τιμή των προβλέψεων των δύο μοντέλων. Ο σχολιασμός θα πραγματοποιηθεί στην Ενότητα 5.3.2.

Πίνακας 5.7: Σφάλματα κώδικα 1^{ης} μεθόδου υβριδικού για πρόβλεψη ηλιόλουστης ημέρας (24/08/2021)


ΜΗΝΕΣ	MAPE(%)	NRMSE(%)
Ιανουάριος	22.73%	18.35%
Φεβρουάριος	13.86%	11.25%
Μάρτιος	14.37%	12.32%
Απρίλιος	9.61%	8.23%
Μάιος	4.65%	5.03%
Ιούνιος	3.28%	4.55%
Ιούλιος	3.39%	4.97%
Αύγουστος	2.74%	3.23%



Σχήμα 5.15: Ραβδόγραμμα 1ης μεθόδου υβριδικού για ηλιόλουστη ημέρα (24/08/2021)


Πίνακας 5.8: Σφάλματα 1^{ης} μεθόδου υβριδικού για πρόβλεψη ημι-ηλιόλουστης ημέρας (29/12/2021)

ΜΗΝΕΣ	MAPE(%)	NRMSE(%)
Ιανουάριος	3.35%	3.55%
Φεβρουάριος	2.85%	2.01%
Μάρτιος	4.91%	5.04%
Απρίλιος	11.25%	10.34%
Μάιος	10.03%	9.03%
Ιούνιος	12.37%	11.99%
Ιούλιος	6.53%	5.09%
Αύγουστος	4.87%	5.01%
Σεπτέμβριος	6.33%	5.44%
Οκτώβριος	7.25%	6.98%
Νοέμβριος	3.99%	2.03%
Δεκέμβριος	3.02%	2.01%

Σχήμα 5.16: Ραβδόγραμμα 1^{ης} μεθόδου υβριδικού για ημι-ηλιόλουστη ημέρα (29/12/2021)

Πίνακας 5.9: Σφάλματα 1^{ης} μεθόδου υβριδικού για πρόβλεψη συννεφιασμένης ημέρας (28/11/2021)

ΜΗΝΕΣ	MAPE (%)	NRMSE (%)
Ιανουάριος	2.97%	2.03%
Φεβρουάριος	4.03%	3.98%
Μάρτιος	3.95%	3.09%
Απρίλιος	6.54%	5.98%
Μάιος	7.06%	6.99%
Ιούνιος	10.35%	10.67%
Ιούλιος	18.25%	16.09%
Αύγουστος	10.22%	11.09%
Σεπτέμβριος	16.35%	15.98%
Οκτώβριος	4.02%	3.99%
Νοέμβριος	3.54%	3.06%


Σχήμα 5.17: Ραβδόγραμμα 1^{ης} μεθόδου υβριδικού για συννεφιασμένη ημέρα (28/11/2021)

5.2.4 Σφάλματα Υβριδικού Μοντέλου ARIMA ως Είσοδος στο LSTM

Αντίστοιχα με την Ενότητα 5.2.3, έτσι και σε αυτήν την Ενότητα, παρουσιάζονται οι πίνακες και τα αντίστοιχα ραβδογράμματα σφαλμάτων για την δεύτερη μέθοδο υβριδικού μοντέλου που αφορά την εισαγωγή των προβλέψεων του μοντέλου ARIMA ως είσοδο στο LSTM. Ο σχολιασμός των αποτελεσμάτων και η σύγκριση θα πραγματοποιηθεί στην Ενότητα 5.3.2.


Πίνακας 5.10: Σφάλματα 2^{ης} μεθόδου υβριδικού για πρόβλεψη ηλιόλουστης ημέρας (24/08/2021)

ΜΗΝΕΣ	MAPE(%)	NRMSE(%)
Ιανουάριος	10.98%	9.95%
Φεβρουάριος	9.92%	11.96%
Μάρτιος	14.01%	11.77%
Απρίλιος	9.68%	6.68%
Μάιος	3.68%	3.65%
Ιούνιος	3.59%	2.68%
Ιούλιος	3.09%	2.87%
Αύγουστος	2.07%	2.70%

Σχήμα 5.18: Ραβδόγραμμα 2^{ης} μεθόδου υβριδικού για ηλιόλουστης ημέρας (24/08/2021)


Πίνακας 5.11: Σφάλματα 2^{ης} μεθόδου υβριδικού για πρόβλεψη ημι-ηλιόλουστης ημέρας (29/12/2021)

ΜΗΝΕΣ	MAPE(%)	NRMSE(%)
Ιανουάριος	3.35%	3.55%
Φεβρουάριος	2.87%	2.01%
Μάρτιος	2.03%	2.04%
Απρίλιος	1.96%	2.35%
Μάιος	8.03%	7.03%
Ιούνιος	3.57%	3.99%
Ιούλιος	6.53%	5.09%
Αύγουστος	5.87%	5.01%
Σεπτέμβριος	6.33%	5.44%
Οκτώβριος	3.25%	4.98%
Νοέμβριος	3.99%	2.03%
Δεκέμβριος	2.02%	2.01%

Σχήμα 5.19: Ραβδόγραμμα 2^{ης} μεθόδου υβριδικού για ημι-ηλιόλουστη ημέρα (29/12/2021)

Πίνακας 5.12: Σφάλματα 2^{ης} μεθόδου υβριδικού για πρόβλεψη συννεφιασμένης ημέρας (28/11/2021)

ΜΗΝΕΣ	MAPE(%)	NRMSE(%)
Ιανουάριος	2.33%	3.56%
Φεβρουάριος	1.67%	3.23%
Μάρτιος	2.56%	3.65%
Απρίλιος	2.68%	3.44%
Μάιος	5.51%	5.90%
Ιούνιος	3.35%	5.26%
Ιούλιος	10.05%	13.87%
Αύγουστος	8.67%	9.98%
Σεπτέμβριος	13.97%	12.25%
Οκτώβριος	3.36%	3.32%
Νοέμβριος	2.05%	3.01%

Σχήμα 5.20: Ραβδόγραμμα 2^{ης} μεθόδου υβριδικού για συννεφιασμένη ημέρα (28/11/2021)

Πίνακας 5.13. Σφάλματα μοντέλων για ηλιόλουστη, ημι-συννεφιασμένη και συννεφιασμένη ημέρα πρόβλεψης για κάθε εποχή του 2021

ΣΦΑΛΜΑΤΑ ΑΝΑ ΕΠΟΧΗ ΓΙΑ ΈΝΑ ΜΗΝΑ ΠΙΣΩ ΤΡΑΙΝΙΝΓ									
ΕΠΟΧΕΣ	ΗΜΕΡΕΣ	MAPE(%)				NRMSE(%)			
		LSTM	ARIMA	1 ST HYBRID METHOD	2 ND HYBRID METHOD	LSTM	ARIMA	1 ST HYBRID METHOD	2 ND HYBRID METHOD
ΧΕΙΜΩΝΑΣ	Ηλιόλουστη 25/02/2021	5.43	5.78	5.45	5.41	5.49	6.25	5.55	5.43
	Συννεφιασμένη 23/02/2021	3.01	4.67	3.13	3.15	2.87	4.53	3.55	3.55
	Ημι-συννεφιασμένη 02/12/2021	2.94	3.98	3.01	2.89	2.87	3.98	3.03	2.56
ΑΝΟΙΞΗ	Ηλιόλουστη 20/05/2021	4.02	4.55	4.03	4.03	4.01	4.98	4.23	3.99
	Συννεφιασμένη 30/04/2021	6.34	7.03	6.46	6.35	5.65	6.78	5.79	5.56
	Ημι-συννεφιασμένη 20/04/2021	4.03	5.76	4.14	4.02	4.56	5.25	4.35	4.53
ΚΑΛΟΚΑΙΡΙ	Ηλιόλουστη 24/08/2021	1.60	2.61	1.61	1.50	2.21	3.77	3.01	2.12
	Συννεφιασμένη 29/07/2021	5.24	6.87	5.55	5.23	4.62	6.44	4.43	4.61
	Ημι-συννεφιασμένη 03/08/2021	5.01	6.88	5.89	5.02	4.02	6.78	5.33	5.05
ΦΘΙΝΟΠΩΡΟ	Ηλιόλουστη 29/09/2021	7.01	7.23	7.02	6.58	7.00	9.98	7.56	7.04
	Συννεφιασμένη 28/11/2021	2.03	2.01	2.02	2.00	2.34	2.32	2.24	2.00
	Ημι-συννεφιασμένη 03/11/2021	4.43	6.01	5.02	4.34	4.03	4.33	4.24	3.98

5.2.5 Σφάλματα Μοντέλων για κάθε Εποχή

Στην Ενότητα αυτή επιλέγονται, σύμφωνα με την μεθοδολογία της Ενότητας 2.1.4, μια ηλιόλουστη, μία συννεφιασμένη και μία ημι-συννεφιασμένη ημέρα για κάθε εποχή. Αυτό σημαίνει, πως επιλέγεται ένα ζεύγος τριών ημερών για τον Χειμώνα, την Άνοιξη, το Καλοκαίρι και το Φθινόπωρο αντίστοιχα. Στην συνέχεια, υπολογίζονται τα σφάλματα για σύνολο εκπαίδευσης ένα μήνα πίσω, για όλες αυτές τις ημέρες. Στον πίνακα 5.13 φαίνονται τα σφάλματα MAPE και NRMSE επί τοις εκατό για κάθε εποχή και ημέρα πρόβλεψης. Παρατηρείται πως τα σφάλματα είναι εντός ορίων, πράγμα που σημαίνει πως οι προβλέψεις εμφανίζουν καλή ακρίβεια. Βέβαια υπάρχουν και περιπτώσεις που τα σφάλματα προσεγγίζουν το όριο του 10%, χωρίς όμως να το ξεπερνούν. Τα συμπεράσματα από τα σφάλματα πρόβλεψης θα αναπτυχθούν στο Κεφάλαιο 6.

5.3 ΣΥΓΚΡΙΣΗ ΣΦΑΛΜΑΤΩΝ

Στην Ενότητα αυτή θα γίνει σύγκριση των σφαλμάτων, τόσο μεταξύ των δύο μεμονωμένων μοντέλων (ARIMA και LSTM) ξεχωριστά, όσο και με τα υβριδικά τους μοντέλα. Θα επεξηγηθούν οι αποκλίσεις στα σφάλματα και θα μελετηθεί αν τα υβριδικά μοντέλα επιφέρουν κάποια ουσιαστική βελτίωση στα μεμονωμένα μοντέλα.

5.3.1 Σύγκριση ARIMA και LSTM

Στην παρούσα Ενότητα θα αναφερθούν τα βασικά στοιχεία που διαφοροποιούν τα μοντέλα ARIMA και LSTM, τα οποία έχουν οδηγήσει σε αυτές τις μικρές αποκλίσεις που παρατηρεί κανείς και στα σφάλματα του κεφαλαίου 5.2. Μερικά από αυτά έχουν ήδη αναφερθεί στο Κεφάλαιο 3, με την διαφορά όμως πως εδώ παρουσιάζονται συγκεντρωτικά με στόχο την σύγκριση των σφαλμάτων τους που αντανακλά και στην απόδοσή τους.

Τα πλεονεκτήματα του μοντέλου ARIMA είναι τα εξής [43], [52]: Τα μοντέλα ARIMA είναι ιδιαίτερα κατάλληλα για την σύλληψη γραμμικών σχέσεων και στάσιμων δεδομένων χρονοσειρών. Λειτουργούν καλά όταν τα δεδομένα παρουσιάζουν σαφή τάση και εποχικότητα. Είναι μοντέλα ερμηνεύσιμα και παρέχουν πληροφορίες σχετικά με το πώς οι παρελθοντικές τιμές επηρεάζουν τις μελλοντικές προβλέψεις.

Αντίθετα, οι περιορισμοί που ενδεχομένως εμφανίζει συχνά το μοντέλο ARIMA είναι οι εξής: Τα μοντέλα ARIMA ενδέχεται να δυσκολεύονται με μη γραμμικές και πολύπλοκες σχέσεις στα δεδομένα. Απαιτούν τον μετασχηματισμό των δεδομένων σε στάσιμες σειρές, γεγονός που μπορεί να οδηγήσει σε απώλεια πληροφοριών. Τα μοντέλα ARIMA είναι συνήθως ικανά να αντιμετωπίζουν πιο απλά προβλήματα, γεγονός που μπορεί να περιορίσει την προβλεπτική τους ικανότητα για σύνθετες εργασίες.

Ως αποτέλεσμα, τα σφάλματα πρόβλεψης για τα μοντέλα ARIMA τείνουν να αποδίδουν καλά όταν τα δεδομένα παρουσιάζουν σαφή μοτίβα και ακολουθούν γραμμική τάση. Τα σφάλματα πρόβλεψης (RMSE, NRMSE, MAPE) είναι γενικά χαμηλά για προβλήματα καλά προσαρμοσμένα σε τέτοιες περιπτώσεις.

Στην περίπτωση των δεδομένων του ΦΒ πάρκου της Λαμπρινής υπάρχει ένα γενικό μοτίβο, όχι βέβαια με απόλυτη ακρίβεια. Πράγματι, παρατηρείται ότι τις μεσημεριανές ώρες και συγκεκριμένα λίγο πριν τις 12 το μεσημέρι μέχρι και περίπου τις 4μ.μ υπάρχει μεγαλύτερη ηλιοφάνεια, οπότε και μεγαλύτερη παραγωγή ισχύος από το ΦΒ. Αυτό είναι μία γενική παρατήρηση. Υπάρχουν όμως και άλλοι παράγοντες που υπεισέρχονται. Για παράδειγμα, αυτή η ηλιοφάνεια δεν είναι ίδια για όλους τους μήνες του έτους. Ιδιαίτερα τους φθινοπωρινούς και

χειμερινούς μήνες, που παρουσιάζεται περισσότερη συννεφιά ή και βροχοπτώσεις, η ηλιοφάνεια είναι σαφώς μικρότερη. Ακόμα όμως και σε ένα μήνα που κατά κύριο λόγο παρουσιάζει ηλιοφάνεια μπορεί να υπάρχουν ημέρες με μερική ηλιοφάνεια ή και ημέρες με περισσότερη συννεφιά. Το αποτέλεσμα είναι το μοτίβο εποχικότητας να μην είναι απολύτως σταθερό.

Όσον αφορά το μοντέλο LSTM, είναι κατάλληλο να καταγράφει πολύπλοκες χρονικές εξαρτήσεις στα δεδομένα. Υπερέχει στον χειρισμό ακολουθιών, με εξαρτήσεις μεγάλης εμβέλειας και μη γραμμικά μοτίβα. Τα LSTM μπορούν να μοντελοποιήσουν πολυμεταβλητές χρονοσειρές, ενσωματώνοντας πληροφορίες από πολλαπλές πηγές [5], [14], [50].

Παρά τα πολλά προτερήματά του μοντέλου LSTM, έχει και ορισμένους περιορισμούς που αφορούν κυρίως τα εξής ζητήματα: Η εκπαίδευση των μοντέλων LSTM μπορεί να είναι υπολογιστικά δαπανηρή, ιδίως για μεγάλα σύνολα δεδομένων. Τα LSTM απαιτούν περισσότερα δεδομένα για να εκπαιδευτούν αποτελεσματικά και μπορεί να υπερπροσαρμοστούν, εάν το σύνολο δεδομένων είναι μικρό.

Γενικά, όσον αφορά τα σφάλματα πρόβλεψης, τα μοντέλα LSTM μπορούν να επιτύχουν εξαιρετικές επιδόσεις πρόβλεψης, ιδίως όταν έχουν να κάνουν με πολύπλοκα και μη γραμμικά δεδομένα χρονοσειρών. Ωστόσο, ενδέχεται να μην αποδίδουν τόσο καλά, όσο το ARIMA, σε περιπτώσεις όπου τα δεδομένα ακολουθούν μια απλή γραμμική τάση με σαφή εποχικότητα. Με βάση τα παραπάνω εξάγονται τα παρακάτω γενικά συμπεράσματα:

- Πολυπλοκότητα δεδομένων: Το ARIMA είναι μια καλή επιλογή για σχετικά απλά, γραμμικά δεδομένα χρονοσειρών, ενώ το LSTM είναι πιο κατάλληλο για σύνθετες, μη γραμμικές και πολυμεταβλητές χρονοσειρές.
- Πολυπλοκότητα μοντέλου: Γενικά το LSTM είναι ένα πιο πολύπλοκο μοντέλο και ενδέχεται να απαιτεί περισσότερα δεδομένα για να εκπαιδευτεί αποτελεσματικά.
- Υπολογιστικοί πόροι: Οι διαθέσιμοι πόροι μπορούν να επηρεάσουν την επιλογή του κατάλληλου μοντέλου. Για μικρά σύνολα δεδομένων ή περιβάλλοντα με περιορισμένους πόρους, μπορεί να προτιμηθεί το ARIMA.
- Υβριδικά μοντέλα: Σε ορισμένες περιπτώσεις, ο συνδυασμός ARIMA και LSTM σε ένα υβριδικό μοντέλο μπορεί να αποδώσει καλύτερα αποτελέσματα, αξιοποιώντας τα πλεονεκτήματα και των δύο προσεγγίσεων. Αυτός είναι και στόχος της παρούσας διπλωματικής εργασίας και θα αναπτυχθεί στην Ενότητα 5.3.2.

Είναι λογικό, ότι στα δεδομένα του ΦΒ πάρκου της Λαμπρινής, υπάρχει μία εποχικότητα, η οποία όμως λόγω της ευμεταβλητότητας του καιρού δεν είναι απόλυτα σαφής. Επιπλέον, επειδή η παραγωγή ισχύος είναι ένα μέγεθος που εξαρτάται από ποικίλους παράγοντες, με τους βασικότερους να έχουν αναφερθεί στην Ενότητα 2.1.2, είναι σαφές πως αυτό που συμφέρει είναι ένα μοντέλο που να μπορεί να διαχειριστεί πιο σωστά αυτή την πολυπλοκότητα. Για αυτό τον λόγο είναι αναμενόμενο, πιο αποτελεσματικό μοντέλο να είναι το LSTM, σε σχέση με το μοντέλο ARIMA. Πράγματι, από τα αποτελέσματα σφαλμάτων που προέκυψαν στην Ενότητα 5.2. φαίνεται πως τα σφάλματα του μοντέλου LSTM είναι λίγο μικρότερα από τα αντίστοιχα του ARIMA.

5.3.2 Σύγκριση ARIMA και LSTM με τα Υβριδικά τους Μοντέλα

Τα υβριδικά μοντέλα, όπως ήταν αναμενόμενο, βελτιώνουν την απόδοση της πρόβλεψης. Συνδυάζοντας δύο διαφορετικές μεθόδους πρόβλεψης, συνδυάζονται και τα πλεονεκτήματα

της κάθε μεθόδου. Σε κάποιες λίγες περιπτώσεις το ARIMA έχει καλύτερα αποτελέσματα από το LSTM, ενώ στις περισσότερες συμβαίνει το αντίστροφο. Σε κάθε περίπτωση, η εισαγωγή ενός ακόμα μεγέθους, που χρησιμοποιείται ως επιπλέον πληροφορία για την εξαγωγή πρόβλεψης, επιφέρει καλύτερα αποτελέσματα από τα μεμονωμένα μοντέλα. Έτσι, και για τις δύο μεθόδους που μελετήθηκαν, όπως προκύπτει και από τα σφάλματα που παρατέθηκαν στην Ενότητα 5.2, τα υβριδικά μοντέλα έχουν μικρότερα σφάλματα τουλάχιστον για ένα από τα δύο μοντέλα. Δηλαδή, τα υβριδικά σε γενικές γραμμές, παράγουν καλύτερη πρόβλεψη. Επομένως, το ερώτημα που προκύπτει είναι ποια από τις δύο μεθόδους υβριδικού μοντέλου είναι καλύτερη και γιατί.

Γενικά, η επιλογή μεταξύ των δύο μεθόδων υβριδικών μοντέλων εξαρτάται από τα χαρακτηριστικά των δεδομένων και το συγκεκριμένο πρόβλημα πρόβλεψης.

Η πρώτη μέθοδος, κατά την οποία λαμβάνεται ο μέσος όρος των προβλέψεων ARIMA και LSTM (Mean Ensemble) εμφανίζει ορισμένα σημαντικά πλεονεκτήματα. Είναι απλή στην εφαρμογή. Η εκπαίδευση γίνεται ανεξάρτητα, τόσο στα μοντέλα ARIMA, όσο και στα μοντέλα LSTM και στην συνέχεια συνδυάζονται οι προβλέψεις τους με μια απλή λειτουργία μέσου όρου. Ο συνδυασμός προβλέψεων από δύο διαφορετικά μοντέλα μπορεί να συμβάλει στην μείωση της επίδρασης των σφαλμάτων από κάθε μοντέλο, οδηγώντας σε πιο ακριβείς προβλέψεις. Η μέθοδος αυτή παρέχει στην ουσία μια σαφή ερμηνεία, είναι απλά ο μέσος όρος των προβλέψεων από δύο μοντέλα. Οπότε είναι εύκολη στην εφαρμογή.

Παρά όλα τα παραπάνω, υπάρχει και ένας βασικός περιορισμός: Το Mean Ensemble αντιμετωπίζει εξίσου τις προβλέψεις ARIMA και LSTM, υποθέτοντας ότι έχουν την ίδια βαρύτητα στην τελική πρόβλεψη. Στην πράξη, η σημασία της πρόβλεψης κάθε μοντέλου μπορεί να διαφέρει.

Γενικά, το Mean Ensemble μπορεί να είναι μια καλή επιλογή για δύο καλά εκπαιδευμένα μοντέλα που παρέχουν συμπληρωματικές πληροφορίες. Για παράδειγμα, εάν το ARIMA καταγράφει καλά τις βραχυπρόθεσμες τάσεις και το LSTM καταγράφει τα μακροπρόθεσμα πρότυπα, ο συνδυασμός τους μπορεί να οδηγήσει σε πιο ακριβείς προβλέψεις [53], [54].

Η δεύτερη μέθοδος (ARIMA-LSTM Hybrid) αφορά την εισαγωγή των προβλέψεων του μοντέλου ARIMA ως είσοδο στο LSTM. Η μέθοδος αυτή παρουσιάζει δύο βασικά πλεονεκτήματα: Αρχικά αξιοποιεί διαδοχικές πληροφορίες. Χρησιμοποιώντας τις προβλέψεις ARIMA ως είσοδο στο LSTM, ενσωματώνει τις διαδοχικές εξαρτήσεις που καταγράφονται από το ARIMA στο μοντέλο LSTM. Αυτό επιτρέπει στο LSTM να μαθαίνει τόσο από τα δεδομένα του παρελθόντος, όσο και από τις γνώσεις του ARIMA.

Από την άλλη πλευρά, η δεύτερη μέθοδος είναι αρκετά πιο πολύπλοκη και πρέπει πάντα να υπάρχει προσοχή για έκθεση σε κίνδυνο υπερπροσαρμογής [43], [45].

Στην περίπτωση των δεδομένων του ΦΒ πάρκου της Λαμπρινής, όπως αναφέρθηκε και στην Ενότητα 5.3.1, δεν μπορεί να θεωρηθεί πως οι προβλέψεις από τα μοντέλα ARIMA και LSTM έχουν την ίδια βαρύτητα. Αυτό συμβαίνει γιατί το μοντέλο LSTM έχει την δυνατότητα να χειρίζεται πιο πολύπλοκα δεδομένα και να πραγματοποιεί βραχυπρόθεσμες και μακροπρόθεσμες προβλέψεις, με αποτέλεσμα να πλεονεκτεί έναντι του ARIMA. Επιπλέον, ο παράγοντας της εποχικότητας του ARIMA δεν είναι απόλυτα αυστηρός, λόγω των μεταβολών του καιρού και των εποχών. Οπότε, είναι σαφές πως η πρώτη μέθοδος του μέσου όρου των προβλέψεων που αντιμετωπίζει εξ ίσου τις δύο διαφορετικές μεθόδους πρόβλεψης, δεν θα έχει τόση ακρίβεια, όσο η δεύτερη. Στην ουσία, αυτό που συμβαίνει είναι ότι όταν εισάγεται σαν είσοδος μία νέα πρόβλεψη από το ARIMA, τότε υπάρχει μια επιπλέον πληροφορία, η οποία τις περισσότερες φορές επιφέρει και μικρότερο τελικό σφάλμα. Άρα, η μέθοδος χρήσης των προβλέψεων του ενός μοντέλου ως είσοδο στο άλλο, είναι πιο ακριβής και πιο αποδοτική.

ΣΥΜΠΕΡΑΣΜΑΤΑ-ΕΠΕΚΤΑΣΕΙΣ

6.1 ΣΥΝΟΨΗ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ ΕΡΓΑΣΙΑΣ

Στο Κεφάλαιο αυτό συνοψίζονται τα συμπεράσματα της παρούσας διπλωματικής εργασίας. Στόχος ήταν η πρόβλεψη παραγωγής ισχύος των φωτοβολταϊκών για το ΦΒ πάρκο της Λαμπρινής με την καλύτερη δυνατή απόδοση. Για τον σκοπό αυτό εξετάστηκαν διεξοδικά δύο μοντέλα, τα LSTM και ARIMA, ενώ στην συνέχεια από τον συνδυασμό τους προέκυψαν τα αντίστοιχα υβριδικά τους μοντέλα με δύο μεθόδους, όπως αναλύθηκε διεξοδικά στο Κεφάλαιο 4.

Για κάθε μέθοδο πρόβλεψης από τις παραπάνω υπολογίστηκαν τα αντίστοιχα σφάλματα MAPE και NRMSE επί τοις εκατό (%).

Όσον αφορά το μοντέλο LSTM, για πρόβλεψη ηλιόλουστης μέρας, τα σφάλματα MAPE και NRMSE ήταν περίπου γύρω στο 3 με 4% για δεδομένα εκπαίδευσης καλοκαιρινών μηνών, ενώ για τους υπόλοιπους φθινοπωρινούς και ανοιξιάτικους μήνες ήταν της τάξης του 5 με 8%. Τέλος για τους χειμερινούς μήνες ως δεδομένα εκπαίδευσης, τα σφάλματα ήταν μεγαλύτερα από 10% και σε κάποιες περιπτώσεις μεγαλύτερα και από 20%.

Αντίστοιχα σφάλματα, αλλά λίγο μεγαλύτερα για την πρόβλεψη μιας ηλιόλουστης ημέρας είχε το μοντέλο ARIMA. Ανάλογα με τον μήνα που επιλεγόταν κάθε φορά ως σύνολο δεδομένων εκπαίδευσης, το σφάλμα ήταν το χαμηλότερο κοντά στο 4 με 6%, ενώ το ψηλότερο κοντά στο 20%.

Τα αντίστοιχα υβριδικά βελτίωναν άλλοτε τα αποτελέσματα του LSTM, άλλοτε του ARIMA και άλλοτε και των δύο, προσφέροντας πιο ακριβή πρόβλεψη. Συγκρίνοντας τις μεθόδους των υβριδικών μοντέλων στο Κεφάλαιο 5, προέκυψε πως η μέθοδος εισαγωγής των προβλέψεων ARIMA ως είσοδο στο LSTM παρουσιάζει μεγαλύτερη ακρίβεια και καλύτερη απόδοση σε σχέση με τον απλό υπολογισμό της μέσης τιμής των προβλέψεων.

Αντίστοιχα συμπεράσματα ισχύουν και για την πρόβλεψη μιας συννεφιασμένης ημέρας, αλλά αντίστροφα. Δηλαδή, το μικρότερο σφάλμα εντοπίζεται για σύνολο δεδομένων εκπαίδευσης χειμερινούς και φθινοπωρινούς μήνες, οι οποίοι προφανώς περιλαμβάνουν και περισσότερες συννεφιασμένες ημέρες. Εκτός ορίων ή πολύ κοντά στο ανώτατο όριο είναι τα σφάλματα για σύνολο δεδομένων εκπαίδευσης καλοκαιρινούς μήνες με ηλιοφάνεια.


Επίσης, όσον αφορά τις ημι-συννεφιασμένες/ημι-ηλιόλουστες ημέρες, παρατηρείται ότι το σφάλμα είναι για τους περισσότερους μήνες εντός ορίων και μόνο για συγκεκριμένους μήνες είναι κοντά στο ανώτατο όριο. Αυτό συμβαίνει γιατί οι ημέρες αυτές είναι στην ουσία ένας μέσος όρος ηλιοφάνειας και συννεφιάς. Ουσιαστικά, σε κάθε μήνα υπάρχουν ημέρες μερικής ηλιοφάνειας, είτε υπάρχουν καθαρά ηλιόλουστες και συννεφιασμένες ημέρες, των οποίων ο μέσος όρος οδηγεί και πάλι στο ίδιο αποτέλεσμα της μερικής ηλιοφάνειας.

Τα παραπάνω συμπεράσματα προκύπτουν τόσο από το σφάλμα MAPE (%), όσο και από το NRMSE (%). Βέβαια, στο σημείο αυτό επιλέγεται να γίνει μία τελική σύγκριση με βάση το σφάλμα MAPE (%), επειδή αυτό παρέχει ένα άμεσο ποσοστιαίο σφάλμα, καθιστώντας εύκολη την ερμηνεία των αποτελεσμάτων, ενώ ταυτόχρονα είναι ανεξάρτητο από την κλίμακα,

επιτρέποντας την σωστή σύγκριση στην ακρίβεια των προβλέψεων σε διαφορετικές μεταβλητές ή σύνολα δεδομένων. Ουσιαστικά, πρόκειται για ένα σχετικό σφάλμα, το οποίο μπορεί να είναι σημαντικό όταν το μέγεθος των προβλεπόμενων τιμών διαφέρει σημαντικά. Για τον λόγο αυτό, παρουσιάζονται σε κοινό πίνακα τα σφάλματα MAPE (%) για ηλιόλουστη, συνεφιασμένη και ημι-συννεφιασμένη/ημι-ηλιόλουστη μέρα, για όλα τα μοντέλα και για τα υβριδικά τους, ώστε να είναι σαφής η σύγκριση και διαφοροποίηση. Τα αντίστοιχα σφάλματα παριστάνονται στους Πίνακες και στα Σχήματα 6.1 έως και 6.3.

Πίνακας 6.1. Σφάλματα MAPE(%) μοντέλων για ηλιόλουστη μέρα συγκεντρωτικά για δεδομένα εκπαίδευσης κάθε μήνα του έτους μέχρι την ημέρα πρόβλεψης


MAPE(%)-Ηλιόλουστη ημέρα (24/08/2021)				
ΜΗΝΕΣ	LSTM	ARIMA	ΥΒΡΙΔΙΚΟ 1^Η ΜΕΘΟΔΟΣ	ΥΒΡΙΔΙΚΟ 2^Η ΜΕΘΟΔΟΣ
Ιανουάριος	26.42%	19.84%	22.73%	10.98%
Φεβρουάριος	4.23%	25.70%	13.86%	9.92%
Μάρτιος	11.98%	26.70%	14.37%	14.01%
Απρίλιος	5.71%	13.88%	9.61%	9.68%
Μάιος	3.86%	6.66%	4.65%	3.68%
Ιούνιος	3.66%	3.82%	3.28%	3.59%
Ιούλιος	3.79%	3.02%	3.39%	3.09%
Αύγουστος	2.09%	3.91%	2.74%	2.07%



Σχήμα 6.1. Ραβδόγραμμα MAPE (%) όλων των μεθόδων πρόβλεψης για ηλιόλουστη ημέρα

Πίνακας 6.2. Σφάλματα MAPE(%) μοντέλων για ημι-ηλιόλουστη μέρα συγκεντρωτικά


MAPE(%) - Ημι-Ηλιόλουστη μέρα (29/12/2021)				
ΜΗΝΕΣ	LSTM	ARIMA	ΥΒΡΙΔΙΚΟ 1^Η ΜΕΘΟΔΟΣ	ΥΒΡΙΔΙΚΟ 2^Η ΜΕΘΟΔΟΣ
Ιανουάριος	4.32%	2.42%	3.35%	3.35%
Φεβρουάριος	1.34%	4.73%	2.85%	2.87%
Μάρτιος	1.96%	6.92%	4.91%	2.03%
Απρίλιος	2.32%	15.20%	11.25%	1.96%
Μάιος	8.53%	11.75%	10.03%	8.03%
Ιούνιος	4.83%	17.78%	12.37%	3.57%
Ιούλιος	5.82%	7.02%	6.53%	6.53%
Αύγουστος	6.52%	2.43%	4.87%	5.87%
Σεπτέμβριος	7.85%	4.84%	6.33%	6.33%
Οκτώβριος	3.60%	18.24%	7.25%	3.25%
Νοέμβριος	2.47%	5.35%	3.99%	3.99%
Δεκέμβριος	2.43%	4.35%	3.02%	2.02%



Σχήμα 6.2. Ραβδόγραμμα MAPE (%) όλων των μεθόδων πρόβλεψης για ημι-ηλιόλουστη ημέρα

Πίνακας 6.3. Σφάλματα MAPE(%) μοντέλων για συννεφιασμένη ημέρα συγκεντρωτικά

ΜΑΡΕ (%) - Συννεφιασμένη ημέρα (28/11/2021)				
ΜΗΝΕΣ	LSTM	ARIMA	ΥΒΡΙΔΙΚΟ 1 ^Η ΜΕΘΟΔΟΣ	ΥΒΡΙΔΙΚΟ 2 ^Η ΜΕΘΟΔΟΣ
Ιανουάριος	2.09%	3.99%	2.97%	2.33%
Φεβρουάριος	2.19%	4.34%	4.03%	1.67%
Μάρτιος	2.89%	4.27%	3.95%	2.56%
Απρίλιος	3.99%	8.65%	6.54%	2.68%
Μάιος	7.26%	8.80%	7.06%	5.51%
Ιούνιος	3.35%	11.25%	10.35%	3.35%
Ιούλιος	8.06%	20.06%	18.25%	10.05%
Αύγουστος	8.73%	15.35%	10.22%	8.67%
Σεπτέμβριος	14.45%	19.36%	16.35%	13.97%
Οκτώβριος	4.62%	4.01%	4.02%	3.36%
Νοέμβριος	3.61%	3.12%	3.54%	2.05%



Σχήμα 6.3. Ραβδόγραμμα MAPE (%) όλων των μεθόδων πρόβλεψης για συννεφιασμένη ημέρα

Μία ακόμα μεθοδολογία που υλοποιήθηκε, ήταν αυτή της επιλογής μιας ηλιόλουστης, μίας συννεφιασμένης και μίας ημι-συννεφιασμένης ημέρας για κάθε εποχή του έτους (Χειμώνα, Άνοιξη, Καλοκαίρι και Φθινόπωρο αντίστοιχα). Τα σφάλματα υπολογίζονται για σύνολο εκπαίδευσης ένα μήνα πίσω. Τα αποτελέσματα των σφαλμάτων καταγράφηκαν στον πίνακα 5.13 του Κεφαλαίου 5 και είναι εντός ορίων, πράγμα που σημαίνει πως οι προβλέψεις εμφανίζουν πολύ καλή ακρίβεια. Παρατηρείται ότι για σύνολο δεδομένων εκπαίδευσης μέσα στον Χειμώνα και στο Φθινόπωρο, που περιλαμβάνουν περισσότερες συννεφιασμένες, ημι-συννεφιασμένες και βροχερές ημέρες, οι προβλέψεις για μια ηλιόλουστη ημέρα εμφανίζουν μεγαλύτερο σφάλμα. Αντίστοιχα, για σύνολο δεδομένων εκπαίδευσης που να αντιστοιχεί σε μήνες της Άνοιξης και του Καλοκαιριού, το σφάλμα είναι μεγαλύτερο για συννεφιασμένες ημέρες πρόβλεψης. Οι περιπτώσεις που το σφάλμα είναι μεγαλύτερο, πλησιάζουν πολλές φορές το όριο του 10%. Πάραυτα, τα σφάλματα, έστω και οριακά είναι τέτοια, ώστε να επιτυγχάνεται ικανοποιητική ακρίβεια πρόβλεψης.

6.2 ΕΠΕΚΤΑΣΕΙΣ ΤΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία περιορίστηκε σε δύο μόνο μεθόδους Μηχανικής Μάθησης για την πρόβλεψη της παραγόμενης ισχύος ΦΒ πάρκων. Η βελτίωση των επιδόσεων των προβλέψεων των ηλιακών συλλεκτών περιλαμβάνει έναν συνδυασμό προηγμένων τεχνικών μοντελοποίησης. Μερικές στρατηγικές και προσεγγίσεις που θα μπορούσαν να συνεισφέρουν στην βελτίωση των επιδόσεων πρόβλεψης των ηλιακών συλλεκτών είναι οι ακόλουθες [55]–[57]:

- Προηγμένα μοντέλα χρονοσειρών:
 - Prophet: Έχει σχεδιαστεί για να χειρίζεται δεδομένα χρονολογικών σειρών με έντονα εποχιακά φαινόμενα και ελλιπή δεδομένα. Είναι χρήσιμο για την μοντελοποίηση της παραγωγής ηλιακών πάνελ.
 - Gated Recurrent Units (GRU): Μια εναλλακτική λύση του LSTM, το GRU, είναι υπολογιστικά πιο αποδοτικό και μπορεί μερικές φορές να επιτύχει παρόμοια ή και καλύτερη απόδοση για ορισμένες ακολουθίες.
 - Μοντέλα μετασχηματιστών (transformers models): Οι μετασχηματιστές, ειδικά εκείνοι που έχουν σχεδιαστεί για την πρόβλεψη χρονοσειρών, μπορούν να συλλάβουν αποτελεσματικά τις μακροπρόθεσμες εξαρτήσεις και τα εποχιακά μοτίβα.
- Ensemble models: Συνδυάζονται προβλέψεις από πολλαπλά μοντέλα (π.χ. LSTM, ARIMA, Prophet) για το σχηματισμό ενός συνόλου. Μπορούν να χρησιμοποιηθούν τεχνικές, όπως ο σταθμισμένος μέσος όρος ή η στοίβαξη.
- Υβριδικά μοντέλα με γνώση τομέα (Hybrid Models with Domain Knowledge): Ενσωματώνονται στα μοντέλα ειδικά χαρακτηριστικά που σχετίζονται, εκτός από τις καιρικές συνθήκες (οι οποίες λήφθηκαν υπόψη στην παρούσα διπλωματική εργασία) και με την γεωγραφική θέση και τις προδιαγραφές των ηλιακών συλλεκτών. Αυτά τα χαρακτηριστικά μπορούν να βελτιώσουν σημαντικά την ακρίβεια πρόβλεψης.
- Βαθιά ενισχυτική μάθηση (DRL): Οι μέθοδοι DRL μπορούν να βελτιστοποιήσουν την λειτουργία των ηλιακών συλλεκτών, λαμβάνοντας υπόψη παράγοντες όπως η αποθήκευση μπαταριών, η ζήτηση ηλεκτρικής ενέργειας και οι συνθήκες της αγοράς για την μεγιστοποίηση της συνολικής απόδοσης.
- Συνεχής παρακολούθηση και ενημέρωση του μοντέλου: Είναι σημαντική η συνεχής ενημέρωση και επανεκπαίδευση των μοντέλων χρησιμοποιώντας τα πιο πρόσφατα δεδομένα. Η συνεχής παρακολούθηση επιτρέπει στα μοντέλα να προσαρμόζονται στα μεταβαλλόμενα πρότυπα και να βελτιώνουν την ακρίβεια.

Οι παραπάνω προτάσεις θα μπορούσαν να εφαρμοστούν για την περαιτέρω βελτίωση της ακρίβειας πρόβλεψης και της απόδοσης των μοντέλων που ήδη αξιοποιήθηκαν στην δεδομένη διπλωματική εργασία. Όμως, σε κάθε περίπτωση, η επιλογή της βέλτιστης προσέγγισης εξαρτάται από τα ειδικά χαρακτηριστικά του συνόλου δεδομένων και το πλαίσιο του προβλήματός. Ο πειραματισμός και οι επαναληπτικές βελτιώσεις είναι το κλειδί για την επίτευξη της καλύτερης δυνατής απόδοσης πρόβλεψης για τα αποτελέσματα των ηλιακών πάνελ.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] B. Sørensen, “A history of renewable energy technology,” *Energy Policy*, vol. 19, no. 1, pp. 8–12, Jan. 1991, doi: 10.1016/0301-4215(91)90072-V.
- [2] Π. Γεωργιλάκης, “Οικονομική και αξιόπιστη λειτουργία σύγχρονων Συστημάτων Ηλεκτρικής Ενέργειας [Προπτυχιακό εγχειρίδιο],” *Κάλλιπος, Ανοικτές Ακαδημαϊκές Εκδόσεις*, 2023.
- [3] Π. Σ. Γεωργιλάκης, *Σύγχρονα Συστήματα Μεταφοράς και Διανομής Ηλεκτρικής Ενέργειας*. Κάλλιπος, Ανοικτές Ακαδημαϊκές Εκδόσεις, Αθήνα, 2015. <https://hdl.handle.net/11419/2013>
- [4] R.-D. Chang, J. Zuo, Z.-Y. Zhao, G. Zillante, X.-L. Gan, and V. Soebarto, “Evolving theories of sustainability and firms: History, future directions and implications for renewable energy research,” *Renewable and Sustainable Energy Reviews*, vol. 72, pp. 48–56, May 2017, doi: 10.1016/j.rser.2017.01.029.
- [5] Y. Yu, J. Cao, and J. Zhu, “An LSTM Short-Term Solar Irradiance Forecasting under Complicated Weather Conditions,” *IEEE Access*, vol. 7, 2019, doi: 10.1109/ACCESS.2019.2946057.
- [6] S. B. Kjaer, J. K. Pedersen, and F. Blaabjerg, “A Review of Single-Phase Grid-Connected Inverters for Photovoltaic Modules,” *IEEE Trans Ind Appl*, vol. 41, no. 5, pp. 1292–1306, Sep. 2005, doi: 10.1109/TIA.2005.853371.
- [7] M. D. Lammert and R. J. Schwartz, “The interdigitated back contact solar cell: A silicon solar cell for use in concentrated sunlight,” *IEEE Trans Electron Devices*, vol. 24, no. 4, pp. 337–342, Apr. 1977, doi: 10.1109/T-ED.1977.18738.
- [8] M. A. Green, Jianhua Zhao, A. Wang, and S. R. Wenham, “Very high efficiency silicon solar cells-science and technology,” *IEEE Trans Electron Devices*, vol. 46, no. 10, pp. 1940–1947, 1999, doi: 10.1109/16.791982.
- [9] G. R. Walker and P. C. Sernia, “Cascaded DC–DC Converter Connection of Photovoltaic Modules,” *IEEE Trans Power Electron*, vol. 19, no. 4, pp. 1130–1139, Jul. 2004, doi: 10.1109/TPEL.2004.830090.
- [10] K. Emery *et al.*, “Temperature dependence of photovoltaic cells, modules and systems,” in *Conference Record of the Twenty Fifth IEEE Photovoltaic Specialists Conference - 1996*, IEEE, 1996, pp. 1275–1278. doi: 10.1109/PVSC.1996.564365.
- [11] D. D. Nguyen, B. Lehman, and S. Kamarthi, “Performance evaluation of solar photovoltaic arrays including shadow effects using neural network,” in *2009 IEEE Energy Conversion Congress and Exposition*, IEEE, Sep. 2009, pp. 3357–3362. doi: 10.1109/ECCE.2009.5316451.
- [12] R. Arshad, S. Tariq, M. U. Niaz, and M. Jamil, “Improvement in solar panel efficiency using solar concentration by simple mirrors and by cooling,” in *2014 International Conference on Robotics and Emerging Allied Technologies in Engineering (iCREATE)*, IEEE, Apr. 2014, pp. 292–295. doi: 10.1109/iCREATE.2014.6828382.

- [13] M. Massaoudi *et al.*, “An Effective Hybrid NARX-LSTM Model for Point and Interval PV Power Forecasting,” *IEEE Access*, vol. 9, pp. 36571–36588, 2021, doi: 10.1109/ACCESS.2021.3062776.
- [14] C.-H. Liu, J.-C. Gu, and M.-T. Yang, “A Simplified LSTM Neural Networks for One Day-Ahead Solar Power Forecasting,” *IEEE Access*, vol. 9, pp. 17174–17195, 2021, doi: 10.1109/ACCESS.2021.3053638.
- [15] M. R. Tur, I. Colak, and R. Bayindir, “Effect of Faults in Solar Panels on Production Rate and Efficiency,” in *2018 International Conference on Smart Grid (icSmartGrid)*, IEEE, Dec. 2018, pp. 287–293. doi: 10.1109/ISGWCP.2018.8634509.
- [16] M. Wolf, “Limitations and Possibilities for Improvement of Photovoltaic Solar Energy Converters: Part I: Considerations for Earth’s Surface Operation,” *Proceedings of the IRE*, vol. 48, no. 7, pp. 1246–1263, Jul. 1960, doi: 10.1109/JRPROC.1960.287647.
- [17] R. M. Kapila Tharanga Rathnayaka, D. M. K. N. Seneviratna, W. Jianguo, and H. I. Arumawadu, “A hybrid statistical approach for stock market forecasting based on Artificial Neural Network and ARIMA time series models,” in *2015 International Conference on Behavioral, Economic and Socio-cultural Computing (BESC)*, IEEE, Oct. 2015, pp. 54–60. doi: 10.1109/BESC.2015.7365958.
- [18] L. von Rueden *et al.*, “Informed Machine Learning - A Taxonomy and Survey of Integrating Prior Knowledge into Learning Systems,” *IEEE Trans Knowl Data Eng*, pp. 1–1, 2021, doi: 10.1109/TKDE.2021.3079836.
- [19] A. Gandelli, F. Grimaccia, S. Leva, M. Mussetta, and E. Ogliari, “Hybrid model analysis and validation for PV energy production forecasting,” in *2014 International Joint Conference on Neural Networks (IJCNN)*, IEEE, Jul. 2014, pp. 1957–1962. doi: 10.1109/IJCNN.2014.6889786.
- [20] P. Du, “Ensemble Machine Learning-Based Wind Forecasting to Combine NWP Output With Data From Weather Station,” *IEEE Trans Sustain Energy*, vol. 10, no. 4, pp. 2133–2141, Oct. 2019, doi: 10.1109/TSTE.2018.2880615.
- [21] H. S. Jang, K. Y. Bae, H.-S. Park, and D. K. Sung, “Solar Power Prediction Based on Satellite Images and Support Vector Machine,” *IEEE Trans Sustain Energy*, vol. 7, no. 3, pp. 1255–1263, Jul. 2016, doi: 10.1109/TSTE.2016.2535466.
- [22] Y. Sahin and E. Duman, “Detecting credit card fraud by ANN and logistic regression,” in *2011 International Symposium on Innovations in Intelligent Systems and Applications*, IEEE, Jun. 2011, pp. 315–319. doi: 10.1109/INISTA.2011.5946108.
- [23] S. Mohan, C. Thirumalai, and G. Srivastava, “Effective Heart Disease Prediction Using Hybrid Machine Learning Techniques,” *IEEE Access*, vol. 7, pp. 81542–81554, 2019, doi: 10.1109/ACCESS.2019.2923707.
- [24] 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.
- [25] C.-G. Haba, “Monitoring Solar Panels using Machine Learning Techniques,” in *2019 8th International Conference on Modern Power Systems (MPS)*, IEEE, May 2019, pp. 1–6. doi: 10.1109/MPS.2019.8759651.
- [26] R. B. Roy *et al.*, “A Comparative Performance Analysis of ANN Algorithms for MPPT Energy Harvesting in Solar PV System,” *IEEE Access*, vol. 9, pp. 102137–102152, 2021, doi: 10.1109/ACCESS.2021.3096864.

- [27] C. S. Vui, G. K. Soon, C. K. On, R. Alfred, and P. Anthony, “A review of stock market prediction with Artificial neural network (ANN),” in *2013 IEEE International Conference on Control System, Computing and Engineering*, IEEE, Nov. 2013, pp. 477–482. doi: 10.1109/ICCSCE.2013.6720012.
- [28] E. Hodo *et al.*, “Threat analysis of IoT networks using artificial neural network intrusion detection system,” in *2016 International Symposium on Networks, Computers and Communications (ISNCC)*, IEEE, May 2016, pp. 1–6. doi: 10.1109/ISNCC.2016.7746067.
- [29] K. Alhumaid, M. Habes, and S. A. Salloum, “Examining the Factors Influencing the Mobile Learning Usage During COVID-19 Pandemic: An Integrated SEM-ANN Method,” *IEEE Access*, vol. 9, pp. 102567–102578, 2021, doi: 10.1109/ACCESS.2021.3097753.
- [30] L. Munkhdalai, T. Munkhdalai, K. H. Park, H. G. Lee, M. Li, and K. H. Ryu, “Mixture of Activation Functions With Extended Min-Max Normalization for Forex Market Prediction,” *IEEE Access*, vol. 7, pp. 183680–183691, 2019, doi: 10.1109/ACCESS.2019.2959789.
- [31] A. Barwińska-Małajowicz, R. Pyrek, K. Szczotka, J. Szymiczek, and T. Piecuch, “Improving the Energy Efficiency of Public Utility Buildings in Poland through Thermomodernization and Renewable Energy Sources—A Case Study,” *Energies (Basel)*, vol. 16, no. 10, p. 4021, May 2023, doi: 10.3390/en16104021.
- [32] S. S. Soman, H. Zareipour, O. Malik, and P. Mandal, “A review of wind power and wind speed forecasting methods with different time horizons,” in *North American Power Symposium 2010*, IEEE, Sep. 2010, pp. 1–8. doi: 10.1109/NAPS.2010.5619586.
- [33] M. Mahmud, M. S. Kaiser, A. Hussain, and S. Vassanelli, “Applications of Deep Learning and Reinforcement Learning to Biological Data,” *IEEE Trans Neural Netw Learn Syst*, vol. 29, no. 6, pp. 2063–2079, Jun. 2018, doi: 10.1109/TNNLS.2018.2790388.
- [34] L. Troiano, E. M. Villa, and V. Loia, “Replicating a Trading Strategy by Means of LSTM for Financial Industry Applications,” *IEEE Trans Industr Inform*, vol. 14, no. 7, pp. 3226–3234, Jul. 2018, doi: 10.1109/TII.2018.2811377.
- [35] A. De Santo, A. Galli, M. Gravina, V. Moscato, and G. Sperli, “Deep Learning for HDD Health Assessment: An Application Based on LSTM,” *IEEE Transactions on Computers*, vol. 71, no. 1, pp. 69–80, Jan. 2022, doi: 10.1109/TC.2020.3042053.
- [36] J. Du, C.-M. Vong, and C. L. P. Chen, “Novel Efficient RNN and LSTM-Like Architectures: Recurrent and Gated Broad Learning Systems and Their Applications for Text Classification,” *IEEE Trans Cybern*, vol. 51, no. 3, pp. 1586–1597, Mar. 2021, doi: 10.1109/TCYB.2020.2969705.
- [37] T. M. Breuel, A. Ul-Hasan, M. A. Al-Azawi, and F. Shafait, “High-Performance OCR for Printed English and Fraktur Using LSTM Networks,” in *2013 12th International Conference on Document Analysis and Recognition*, IEEE, Aug. 2013, pp. 683–687. doi: 10.1109/ICDAR.2013.140.
- [38] A. Gensler, J. Henze, B. Sick, and N. Raabe, “Deep Learning for solar power forecasting — An approach using AutoEncoder and LSTM Neural Networks,” in *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, IEEE, Oct. 2016, pp. 002858–002865. doi: 10.1109/SMC.2016.7844673.
- [39] J. Yang, T. Wu, K. Wang, and R. Wen, “A Hybrid VMD-Based ARIMA-LSTM Model for Day-ahead PV Prediction and Uncertainty Analysis,” in *2022 4th*

- International Conference on Smart Power & Internet Energy Systems (SPIES)*, IEEE, Dec. 2022, pp. 2009–2014. doi: 10.1109/SPIES55999.2022.10082371.
- [40] J. Youness and M. Driss, “LSTM Deep Learning vs ARIMA Algorithms for Univariate Time Series Forecasting: A case study,” in *2022 8th International Conference on Optimization and Applications (ICOA)*, IEEE, Oct. 2022, pp. 1–4. doi: 10.1109/ICOA55659.2022.9934119.
- [41] F. Hamami and I. A. Dahlan, “Univariate Time Series Data Forecasting of Air Pollution using LSTM Neural Network,” in *2020 International Conference on Advancement in Data Science, E-learning and Information Systems (ICADEIS)*, IEEE, Oct. 2020, pp. 1–5. doi: 10.1109/ICADEIS49811.2020.9277393.
- [42] M. Munem, T. M. Rubaith Bashar, M. H. Roni, M. Shahriar, T. B. Shawkat, and H. Rahaman, “Electric Power Load Forecasting Based on Multivariate LSTM Neural Network Using Bayesian Optimization,” in *2020 IEEE Electric Power and Energy Conference (EPEC)*, IEEE, Nov. 2020, pp. 1–6. doi: 10.1109/EPEC48502.2020.9320123.
- [43] D. Fan, H. Sun, J. Yao, K. Zhang, X. Yan, and Z. Sun, “Well production forecasting based on ARIMA-LSTM model considering manual operations,” *Energy*, vol. 220, p. 119708, Apr. 2021, doi: 10.1016/j.energy.2020.119708.
- [44] L. Yermal and P. Balasubramanian, “Application of Auto ARIMA Model for Forecasting Returns on Minute Wise Amalgamated Data in NSE,” in *2017 IEEE International Conference on Computational Intelligence and Computing Research (ICCIC)*, IEEE, Dec. 2017, pp. 1–5. doi: 10.1109/ICCIC.2017.8524232.
- [45] D. Fan, H. Sun, J. Yao, K. Zhang, X. Yan, and Z. Sun, “Well production forecasting based on ARIMA-LSTM model considering manual operations,” *Energy*, vol. 220, p. 119708, Apr. 2021, doi: 10.1016/j.energy.2020.119708.
- [46] G. Li, S. Xie, B. Wang, J. Xin, Y. Li, and S. Du, “Photovoltaic Power Forecasting With a Hybrid Deep Learning Approach,” *IEEE Access*, vol. 8, pp. 175871–175880, 2020, doi: 10.1109/ACCESS.2020.3025860.
- [47] A. S. Temür, M. Akgün, and G. Temür, “PREDICTING HOUSING SALES IN TURKEY USING ARIMA, LSTM AND HYBRID MODELS,” *Journal of Business Economics and Management*, vol. 20, no. 5, pp. 920–938, Jul. 2019, doi: 10.3846/jbem.2019.10190.
- [48] H. Liu, C. Chen, H. Tian, and Y. Li, “A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks,” *Renew Energy*, vol. 48, pp. 545–556, Dec. 2012, doi: 10.1016/j.renene.2012.06.012.
- [49] S. Wu, L. Jia, and Y. Liu, “Ultra-short-term wind energy prediction based on wavelet denoising and multivariate LSTM,” in *Proceedings - 2021 Power System and Green Energy Conference, PSGEC 2021*, 2021. doi: 10.1109/PSGEC51302.2021.9541909.
- [50] H. Widiputra, A. Mailangkay, and E. Gautama, “Multivariate CNN-LSTM Model for Multiple Parallel Financial Time-Series Prediction,” *Complexity*, vol. 2021, 2021, doi: 10.1155/2021/9903518.
- [51] P. Kang, J. Lao, M. Yu, H. Song, and C. Wang, “Reliable prediction on emerging energy supply for national sustainability and stability: A case study on coal bed gas supply in china based on the dual-LSTM model,” *IEEE Access*, vol. 9, 2021, doi: 10.1109/ACCESS.2021.3096532.
- [52] D. Fan, H. Sun, J. Yao, K. Zhang, X. Yan, and Z. Sun, “Well production forecasting based on ARIMA-LSTM model considering manual operations,” *Energy*, vol. 220, 2021, doi: 10.1016/j.energy.2020.119708.

-
- [53] X. Zhang, Y. Li, S. Lu, H. F. Hamann, B.-M. Hodge, and B. Lehman, “A Solar Time Based Analog Ensemble Method for Regional Solar Power Forecasting,” *IEEE Trans Sustain Energy*, vol. 10, no. 1, pp. 268–279, Jan. 2019, doi: 10.1109/TSTE.2018.2832634.
- [54] J. W. Taylor and R. Buizza, “Neural network load forecasting with weather ensemble predictions,” *IEEE Transactions on Power Systems*, vol. 17, no. 3, pp. 626–632, Aug. 2002, doi: 10.1109/TPWRS.2002.800906.
- [55] M. Massaoudi, I. Chihi, H. Abu-Rub, S. S. Refaat, and F. S. Oueslati, “Convergence of Photovoltaic Power Forecasting and Deep Learning: State-of-Art Review,” *IEEE Access*, vol. 9, pp. 136593–136615, 2021, doi: 10.1109/ACCESS.2021.3117004.
- [56] Md. M. Hasan Shawon, S. Akter, Md. K. Islam, S. Ahmed, and Md. M. Rahman, “Forecasting PV Panel Output Using Prophet Time Series Machine Learning Model,” in *2020 IEEE REGION 10 CONFERENCE (TENCON)*, IEEE, Nov. 2020, pp. 1141–1144. doi: 10.1109/TENCON50793.2020.9293751.
- [57] M. Xia, H. Shao, X. Ma, and C. W. de Silva, “A Stacked GRU-RNN-Based Approach for Predicting Renewable Energy and Electricity Load for Smart Grid Operation,” *IEEE Trans Industr Inform*, vol. 17, no. 10, pp. 7050–7059, Oct. 2021, doi: 10.1109/TII.2021.3056867.