



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

**ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ ΜΕ
ΜΕΘΟΔΟΥΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΚΑΙ ΤΕΧΝΗΤΑ
ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Γεώργιος Ι. Σχινάς

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

Αθήνα, Οκτώβριος 2022



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

**ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ ΜΕ
ΜΕΘΟΔΟΥΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΚΑΙ ΤΕΧΝΗΤΑ
ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Γεώργιος Ι. Σχινάς

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

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 27 Οκτωβρίου 2022

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

.....
Δημήτριος Σούντρης
Καθηγητής Ε.Μ.Π.

.....
Ιωάννης Γκόνος
Αν. Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2022

.....

Γεώργιος Ι. Σχινάς

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

Copyright © Γεώργιος Σχινάς, 2022.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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

ΠΕΡΙΛΗΨΗ

Σκοπός αυτής της εργασίας είναι η αξιοποίηση δύο μεθόδων μηχανικής μάθησης, των Τεχνητών Νευρωνικών Δικτύων και των Μηχανών Διανυσμάτων Υποστήριξης, για την δημιουργία μοντέλων τεχνητής νοημοσύνης που εξάγουν βραχυπρόθεσμες προβλέψεις για την παραγωγή ενεργού ισχύος δύο φωτοβολταϊκών πάρκων, αξιοποιώντας ιστορικά δεδομένα από μετρητές και αισθητήρες των ίδιων πάρκων. Στόχος της δημιουργίας των μοντέλων είναι η διεξαγωγή μελέτης πάνω στην ικανότητα των μοντέλων μηχανικής μάθησης να προβλέπουν με ακρίβεια την παραγόμενη ισχύ, στις απαιτήσεις τους όσον αφορά στη μορφή τους και στο είδος των δεδομένων εισόδου τους, και τέλος, στην καταλληλότητά τους για χρήση σε πραγματικές εφαρμογές.

Αρχικά, διατυπώνεται το πρόβλημα της στοχαστικής φύσης της ηλιακής ενέργειας και η σύγχρονη απαίτηση για πρόβλεψη της φωτοβολταϊκής παραγωγής. Στη συνέχεια παρουσιάζονται αναλυτικά οι μέθοδοι των Τεχνητών Νευρωνικών Δικτύων και των Μηχανών Διανυσμάτων Υποστήριξης, καθώς και η διαδικασία κατασκευής και τελειοποίησης των μοντέλων πρόβλεψης που βασίζονται σε αυτές τις μεθόδους. Έπειτα, περιγράφεται η υλοποίηση έξι μοντέλων πρόβλεψης σε Η/Υ στην γλώσσα Python, η δοκιμή τους πάνω στα δεδομένα από τα δύο φωτοβολταϊκά πάρκα και η ανάλυση των αποτελεσμάτων που προκύπτουν. Τα μοντέλα συγκρίνονται μεταξύ τους και με άλλες μεθόδους πρόβλεψης που χρησιμοποιούνται σήμερα και προτείνονται ορισμένες πιθανές επεκτάσεις της εργασίας.

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ

Ανανεώσιμες πηγές ενέργειας, φωτοβολταϊκά, ηλιακή ενέργεια, πρόβλεψη παραγωγής ισχύος, μηχανική μάθηση, τεχνητή νοημοσύνη, τεχνητά νευρωνικά δίκτυα, μηχανές διανυσμάτων υποστήριξης, αλγόριθμοι βελτιστοποίησης.

ABSTRACT

The scope of this diploma thesis is the utilization of two Machine Learning methods, Artificial Neural Networks and Support Vector Machines, to develop artificial intelligence models capable of forecasting the real power produced by two photovoltaic power stations, using historic data collected from sensors and data acquisition systems of said stations. The creation of these models serves the purpose of studying their ability to generate accurate predictions of the produced real power, as well as identifying their structural demands, determining their ideal input data, and examining their suitability for real time applications.

The issue of photovoltaic power's stochastic nature is discussed, and the modern need for accurate prediction of photovoltaic power is highlighted. Artificial Neural Networks and Support Vector Machines are presented in detail and the process of making and optimizing prediction models is analyzed. The implementation of six computer models, written in Python programming language, and their subsequent testing on historic data from two photovoltaic stations, is described. The models' results are discussed and compared to each other and to different prediction methods currently in use. Possible future research on the subject is also proposed.

KEY WORDS

Renewable energy sources, photovoltaics, solar power, power generation forecasting, machine learning, artificial intelligence, artificial neural networks, support vector machines, optimization algorithms.

ΕΥΧΑΡΙΣΤΙΕΣ

Για την παρούσα διπλωματική εργασία θα ήθελα να ευχαριστήσω όλα τα άτομα τα οποία μου στάθηκαν και με βοήθησαν αυτόν τον τελευταίο χρόνο, χωρίς τα οποία δεν θα ήταν δυνατή η ολοκλήρωση της.

Αρχικά, ευχαριστώ θερμά τον επιβλέποντα καθηγητή μου, κ. Παύλο Γεωργιλιάκη, για την αδιάκοπη υποστήριξή του και την ουσιαστική καθοδήγησή του, ο οποίος προσέφερε απλόχερα τη βοήθεια του και την εμπιστοσύνη του σε όλη την διάρκεια της συνεργασίας μας πάνω σε αυτό το εξαιρετικά ενδιαφέρον θέμα.

Ακόμα, ευχαριστώ ιδιαιτέρως τον διδάκτορα κ. Γιάννη Μπαζιώνη, για τις εύστοχες συμβουλές και καίριες υποδείξεις του, οι οποίες ήταν μία πολύτιμη βοήθεια σε κάθε στιγμή της εκπόνησης αυτής της εργασίας, αλλά και για τα ατσάλινα νεύρα του που τον βοήθησαν να αντέχει τον καταγισμό αποριών που εκτόξευα προς το μέρος του ανά πάση στιγμή.

Επίσης, θα ήθελα να ευχαριστήσω την οικογένεια μου και τους φίλους μου, τους μεγαλύτερους συμβούλους μου, οι οποίοι μου στάθηκαν σε όλο αυτό το ταξίδι, με συνόδευσαν στις χαρές και με ανέβαζαν στις λύπες, και είχαν πάντοτε να μοιραστούν κάποιο εύστοχο σχόλιο, καμιά σοφή παρατήρηση, όποτε βρισκόμασταν στις παραδοσιακές συναντήσεις μας.

ΠΕΡΙΕΧΟΜΕΝΑ

Κεφάλαιο 1: Εισαγωγή.....	1
1.1 Παραγωγή ηλεκτρικής ενέργειας από ΑΠΕ	1
1.2 Αντικείμενο της εργασίας.....	2
1.3 Δομή της εργασίας.....	3
Κεφάλαιο 2: Φωτοβολταϊκά Πάρκα	5
2.1 Γενικά	5
2.2 Λειτουργία Φ/Β πάρκων.....	5
2.3 Διείσδυση ΑΠΕ στα δίκτυα διανομής	7
2.4 Πρόβλεψη παραγωγής ηλιακής ενέργειας.....	8
2.4.1 Μέθοδοι πρόβλεψης	8
2.5 Τα Φ/Β πάρκα της έρευνας.....	10
2.5.1 Το πάρκο Λαμπρινής.....	11
2.5.2 Το πάρκο της Περδικουλας	11
2.5.3 Διαθέσιμα δεδομένα	12
Κεφάλαιο 3: Τεχνητά Νευρωνικά Δίκτυα	13
3.1 Γενικά	13
3.2 Βασικά στοιχεία νευρωνικών δικτύων	14
3.2.1 Δομή νευρώνα	14
3.2.2 Δομή και αρχιτεκτονική δικτύου.....	15
3.2.3 Παράμετροι και υπερπαραμέτροι.....	16
3.2.4 Σφάλματα και δείγματα	22
3.3 Πρόβλεψη παραγωγής ισχύος μέσω ΤΝΔ	23
Κεφάλαιο 4: Μηχανές Διανυσμάτων Υποστηρίξης	25
4.1 Γενικά	25
4.2 Βασικά στοιχεία ΜΔΥ.....	27
4.3 Πρόβλεψη παραγωγής ισχύος μέσω ΜΔΥ	28
4.4 Αλγόριθμοι βελτιστοποίησης	28

Κεφάλαιο 5: Υλοποίηση και Έλεγχος Μοντέλων	31
5.1 Γενικά	31
5.2 Κώδικας	31
5.2.1 Περιβάλλον ανάπτυξης και βιβλιοθήκες	31
5.2.2 Προεπεξεργασία δεδομένων	32
5.2.3 Εκπαίδευση μοντέλων	33
5.2.4 Έλεγχος μοντέλων και σφάλματα	34
5.3 Υλοποίηση μοντέλων πρόβλεψης	35
5.3.1 Σύνολα ελέγχου	35
5.3.2 Απλά μοντέλα πρόβλεψης	36
5.3.3 Μοντέλα πρόβλεψης με κυκλικούς χρόνους	38
5.3.4 Βελτιστοποίηση μοντέλων ΜΔΥ με αλγόριθμους βελτιστοποίησης	40
5.3.5 Βελτιστοποίηση μοντέλων ΤΝΔ.....	41
5.4 Αποτελέσματα και σύγκριση μοντέλων	44
5.4.1 Μοντέλα ΤΝΔ.....	44
5.4.2 Μοντέλα ΜΔΥ	46
5.4.3 Σύγκριση μεθόδων στο γενικό σύνολο ελέγχου	47
5.4.4 Σύγκριση μοντέλων στα εποχιακά σύνολα ελέγχου.....	50
5.4.5 Σύγκριση μοντέλων ως προς το δείγμα εισόδου	53
Κεφάλαιο 6: Συμπεράσματα και Μελλοντικές Επεκτάσεις.....	59
6.1 Ανασκόπηση εργασίας	59
6.2 Μελλοντικές επεκτάσεις.....	61
Κεφάλαιο 7: Βιβλιογραφία	63

ΕΙΣΑΓΩΓΗ

1.1 ΠΑΡΑΓΩΓΗ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ ΑΠΟ ΑΠΕ

Σχεδόν 140 χρόνια μετά την δημιουργία του πρώτου σταθμού παραγωγής ηλεκτρικής ενέργειας, ο ηλεκτρισμός αποτελεί την βάση της καθημερινότητας του σύγχρονου πολίτη. Από τις απλούστερες οικιακές ηλεκτρικές συσκευές έως τον βαρύ εξοπλισμό ενός εργοστασίου, ο άνθρωπος του 21^{ου} αιώνα εξαρτάται από το ηλεκτρικό ρεύμα για την ικανοποίηση των βασικών του αναγκών. Ως συνέπεια αυτού, η ικανότητα και ο τρόπος παραγωγής ηλεκτρισμού έχουν κυρίαρχο ρόλο στην ευρυθμία της σύγχρονης κοινωνίας. Αν και ιστορικά η παραγωγή ηλεκτρικής ενέργειας συνδέεται άρρηκτα με την κατανάλωση ορυκτών καυσίμων, όπως οι γαιάνθρακες ή το πετρέλαιο, οι σημερινές συνθήκες απαιτούν την απομάκρυνση από τα συμβατικά καύσιμα, τόσο λόγω της ρύπανσης που προέρχεται από την εξόρυξη, επεξεργασία και καύση τους, όσο και λόγω της ταχύτητας με την οποία η κατανάλωσή τους οδηγεί στην σταδιακή έκλειψη των αποθεμάτων τους.

Δεδομένου ότι η στροφή σε μία κοινωνία χωρίς ηλεκτρικές ενεργειακές ανάγκες είναι πρακτικά αδύνατη, το ζήτημα της παραγωγής ηλεκτρικής ενέργειας έρχονται να επιλύσουν εναλλακτικές πηγές ενέργειας, όπως οι ανανεώσιμες πηγές ενέργειας (ΑΠΕ). Μονάδες παραγωγής, όπως είναι τα υδροηλεκτρικά εργοστάσια, τα αιολικά πάρκα ή τα φωτοβολταϊκά (Φ/Β) πάρκα, προσφέρουν μία διαφορετική προσέγγιση στην αντιμετώπιση του προβλήματος, με λιγότερους ρύπους και ανεξάντλητες πηγές καυσίμου (νερό, άνεμος, ήλιος). Όμως, παρά τα οφέλη της, η τεχνολογία αυτή δεν είναι αρκετά ώριμη να αντικαταστήσει τους συμβατικούς παραγωγούς, καθότι η μεγάλη διείσδυση των ΑΠΕ μπορεί να προκαλέσει ζητήματα αστάθειας συχνότητας στο δίκτυο ή και διακοπές ρεύματος [1], [2].

Τα τελευταία 30 χρόνια γίνονται ραγδαίες εξελίξεις στον τομέα των ΑΠΕ, προκειμένου να γίνει εφικτή η επέκταση της χρήσης τους σε σημείο που επιτρέπει την σταδιακή εγκατάλειψη των ορυκτών καυσίμων. Για παράδειγμα, ο ρυθμός εγκατάστασης νέων Φ/Β μονάδων αυξάνεται εκθετικά, γεγονός που οφείλεται στο ολοένα μειούμενο κόστος των μονάδων και στις κρατικές και ιδιωτικές επενδύσεις σε προγράμματα ένταξης ηλιακών παραγωγών στο δίκτυο ενέργειας [2]. Η Ευρωπαϊκή Ένωση (ΕΕ) είναι από ένας από τους κύριους ευεργέτες του εγχειρήματος της προώθησης των ΑΠΕ, μέσω της υπογραφής της Ευρωπαϊκής Πράσινης Συμφωνίας, η οποία προβλέπει, μεταξύ άλλων, την στήριξη της έρευνας και της ανάπτυξης αγοράς των ΑΠΕ και την υποχρεωτική μείωση ρυπογόνων πηγών ενέργειας. Αυτή η πρωτοβουλία έχει ήδη οδηγήσει στην αύξηση της διείσδυσης των ΑΠΕ στο ενεργειακό δίκτυο της ΕΕ, επιτρέποντας την θέσπιση στόχων για κλιματική ουδετερότητα έως το 2050.

Από την έναρξη του πολέμου στην Ουκρανία, η ενεργειακή κρίση που έχει προκύψει από την παγκόσμια εξάρτηση από τα ρωσικά καύσιμα έχει προκαλέσει την ανάγκη για επιτάχυνση της επίτευξης αυτών των στόχων. Αυτό οδήγησε στην υποβολή του σχεδίου

REPowerEU τον Μάρτιο του 2022, που έχει σκοπό την ταχεία αντικατάσταση των ορυκτών καυσίμων από καθαρές μορφές ενέργειας. Συγκεκριμένα για την ηλιακή ενέργεια, στο σχέδιο αυτό προβλέπεται η εγκατάσταση νέων ηλιακών φωτοβολταϊκών ισχύος άνω των 320 GW έως το 2025, υπερδιπλάσιας 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.

Μία από τις μορφές των ΑΠΕ με ιδιαίτερη παρουσία στον ελλαδικό χώρο είναι η ηλιακή ενέργεια από Φ/Β πάρκα, η οποία βασίζεται στην μετατροπή της ενέργειας των φωτονίων που προσπίπτουν στις φωτοβολταϊκές διατάξεις σε ηλεκτρική ενέργεια, μέσω του φωτοβολταϊκού φαινομένου που πραγματοποιείται στις ημιαγωγικές διατάξεις των Φ/Β στοιχείων [3]. Πολύ σημαντικοί παράγοντες που επηρεάζουν την παραγωγή ενός Φ/Β πάρκου είναι η ποσότητα της ηλιακής ακτινοβολίας αλλά και η γωνία πρόσπτωσης της πάνω στα Φ/Β πάνελα, για αυτό και γίνονται προσεκτικές μελέτες πριν την κατασκευή ενός Φ/Β πάρκου που αποσκοπούν στην μέγιστη δυνατή εκμετάλλευση του ηλιακού φωτός. Οι μελέτες αυτές είναι μοναδικές για κάθε υποψήφιο πάρκο, καθώς αφορούν στα χαρακτηριστικά της συγκεκριμένης τοποθεσίας, όπως το υψόμετρο, η μορφή του γεωγραφικού ανάγλυφου της περιοχής, το κλίμα, η κλίση του εδάφους, η θέση του ήλιου ανά εποχή, κτλ.

Ως εκ τούτου, η λειτουργία ενός Φ/Β πάρκου βασίζεται κυρίως στην απορροφούμενη ηλιακή ακτινοβολία, συνεπώς και στην παρουσία του ήλιου, τις επικρατούσες περιβαλλοντικές συνθήκες και τον τρόπο εκμετάλλευσης της ωφέλιμης ακτινοβολίας. Αυτό το γεγονός καθιστά την ηλιακή ενέργεια μη ελεγχόμενη από τον άνθρωπο, ο οποίος διαθέτει πολύ περιορισμένη ικανότητα να παρέμβει στην διαδικασία παραγωγής της. Επομένως, αφού είναι αδύνατο να ρυθμιστεί από τον χρήστη, είναι απαραίτητο να προβλεφθεί με την μεγαλύτερη δυνατή ακρίβεια.

Με την πάροδο των χρόνων, έχουν προταθεί και εφαρμοστεί πολλές διαφορετικές μέθοδοι για την πρόβλεψη της φωτοβολταϊκής παραγωγής. Τα τελευταία χρόνια παρατηρείται άνοδος στην αξιοποίηση των Η/Υ για την εξαγωγή προβλέψεων, λόγω της αυξημένης επεξεργαστικής ικανότητάς τους και των απέραντων δυνατοτήτων τους. Στο προσκήνιο έχουν εμφανιστεί πολλές διαφορετικές μέθοδοι, βασισμένες στην τεχνητή νοημοσύνη και την μηχανική μάθηση, οι οποίες έχουν ήδη χρησιμοποιηθεί σε ποικίλες εφαρμογές.

1.2 ΑΝΤΙΚΕΙΜΕΝΟ ΤΗΣ ΕΡΓΑΣΙΑΣ

Η ανάγκη για σταδιακή εγκατάλειψη των ορυκτών καυσίμων οδηγεί στην επέκταση της χρήσης εναλλακτικών παραγωγών ενέργειας, όπως είναι οι ΑΠΕ. Η απρόβλεπτη φύση των καιρικών συνθηκών, όπως ο άνεμος και η παρουσία νεφών, δημιουργεί προβλήματα στην απρόσκοπτη λειτουργία παραγωγών όπως τα αιολικά ή τα Φ/Β πάρκα, γεγονός που αποτρέπει την πλήρη εξάρτηση από τις ΑΠΕ για παραγωγή ηλεκτρικής ενέργειας και ρύθμιση του ηλεκτρικού δικτύου. Αποκτώντας την ικανότητα πρόβλεψης της μελλοντικής παραγωγής ενός παραγωγού, όπως ενός Φ/Β πάρκου, δίνεται η δυνατότητα εκκίνησης εφεδρειών και έγκαιρης οργάνωσης της λειτουργίας του δικτύου ενέργειας.

Σκοπός της παρούσας διπλωματικής εργασίας είναι η δοκιμή δύο μεθόδων τεχνητής νοημοσύνης και μηχανικής μάθησης, των Τεχνητών Νευρωνικών Δικτύων και των Μηχανών Διανυσμάτων Υποστήριξης, για την δημιουργία μοντέλων βραχυπρόθεσμης πρόβλεψης Φ/Β παραγωγής ενεργού ισχύος σε δύο Φ/Β πάρκα. Κάθε μοντέλο αναλαμβάνει να επεξεργαστεί

και αναλύσει ιστορικά στοιχεία από μετρητές και αισθητήρες κάθε πάρκου (σε χρονολογική σειρά) με στόχο την εξαγωγή 15 προβλέψεων, καθεμία σε απόσταση ενός δεκαπεντάλεπτου από την προηγούμενη. Τα προκύπτοντα μοντέλα μελετώνται ως προς την καταλληλότητα και αξιοπιστία τους και συγκρίνονται μεταξύ τους.

1.3 ΔΟΜΗ ΤΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα εργασία οργανώνεται σε επτά κεφάλαια:

- Στο Κεφάλαιο 2 παρουσιάζεται αναλυτικά ο τρόπος λειτουργίας των Φ/Β πάρκων, οι προκλήσεις που προκύπτουν από την ανάγκη πρόβλεψης της φωτοβολταϊκής ισχύος, οι παράγοντες που επηρεάζουν αυτήν την πρόβλεψη και τα διαθέσιμα δεδομένα που έχουν παραχωρήσει τα Φ/Β πάρκα που συμμετέχουν στη μελέτη.
- Στο Κεφάλαιο 3 παρουσιάζεται η μέθοδος των Τεχνητών Νευρωνικών Δικτύων και τα χαρακτηριστικά της.
- Στο Κεφάλαιο 4 παρουσιάζεται η μέθοδος των Μηχανών Διανυσμάτων Υποστήριξης, τα χαρακτηριστικά της και ο αλγόριθμος βελτιστοποίησης Firefly.
- Στο Κεφάλαιο 5 αναλύεται η διαδικασία κατασκευής των μοντέλων πρόβλεψης σε Η/Υ, ο τρόπος υλοποίησής τους και παρουσιάζονται, συγκρίνονται και σχολιάζονται τα αποτελέσματα της μελέτης.
- Στο Κεφάλαιο 6 συνοψίζεται η εργασία και προτείνονται τρόποι επέκτασης και βελτίωσής της.

Στο Κεφάλαιο 7 παρουσιάζεται η βιβλιογραφία που χρησιμοποιήθηκε σε όλη την έκταση της εργασίας.

ΦΩΤΟΒΟΛΤΑΪΚΑ ΠΑΡΚΑ


2.1 ΓΕΝΙΚΑ

Ηλιακή ενέργεια ονομάζεται η ανανεώσιμη πηγή ενέργειας (ΑΠΕ) η οποία βασίζει την λειτουργία της στην μετατροπή της ενέργειας της ηλιακής ακτινοβολίας της ανεξάντλητης πηγής του ήλιου, σε ηλεκτρική ενέργεια, μέσω μιας διαδικασίας που πραγματοποιείται στα φωτοβολταϊκά (Φ/Β) πάρκα [3], [4]. Συγκεκριμένα, οι φωτοβολταϊκές γεννήτριες των πάρκων αυτών έχουν ως κύρια συστατικά τα φωτοβολταϊκά στοιχεία (γνωστά και ως ηλιακά κύτταρα ή φωτοστοιχεία), συγκεντρωμένα στα φωτοβολταϊκά πανέλα, στα οποία συντελείται η μετατροπή της ηλιακής ενέργειας σε ηλεκτρική με βάση το φωτοβολταϊκό φαινόμενο. Τα φωτοστοιχεία κατά κανόνα είναι ημιαγωγικές δίοδοι, συνήθως σχήματος δίσκου, στις οποίες δημιουργείται διαφορά δυναμικού καθώς δέχονται ηλιακή ακτινοβολία στην επιφάνειά τους. Συνδέοντας πολλά φωτοστοιχεία σε σειρά ή/και παράλληλα πάνω σε ένα πάνελ παράγεται συνεχές ηλεκτρικό ρεύμα.

Ανάλογα με το μέγεθος και τους στόχους της κάθε Φ/Β εγκατάστασης μπορεί να υπάρχουν ποικίλες διατάξεις ελέγχου, προστασίας ή και μετατροπής του συνεχούς ρεύματος σε εναλλασσόμενο. Κάθε διάταξη, επίσης, είναι μελετημένη και δομημένη διαφορετικά και μοναδικά σε σχέση με τις υπόλοιπες, προσαρμοσμένη στο ιδιαίτερο ανάγλυφο, τις καιρικές συνθήκες, την επιθυμητή λειτουργικότητα και την τοποθεσία της περιοχής στην οποία βρίσκεται. Όμως, σε κάθε περίπτωση, το κυριότερο χαρακτηριστικό ενός πάρκου είναι η παραγόμενη ισχύς και το κόστος του συστήματος ανά μονάδα ισχύος και όχι η μορφολογία του.

2.2 ΛΕΙΤΟΥΡΓΙΑ Φ/Β ΠΑΡΚΩΝ

Δεδομένης της ανάλογης σχέσης της ποσότητας της προσπίπτουσας, πάνω στο φωτοστοιχείο, ηλιακής ακτινοβολίας και του παραγόμενου ηλεκτρικού ρεύματος, ο κυριότερος παράγοντας που επηρεάζει την παραγόμενη ισχύ ενός Φ/Β πάρκου είναι η πυκνότητα της ηλιακής ακτινοβολίας. Η ίδια η πυκνότητα εξαρτάται από διάφορους παράγοντες, όπως η θέση του ηλίου σε σχέση με τον προσανατολισμό των ηλιακών συλλεκτών, η ώρα της ημέρας και η εποχή αλλά και η ανακλαστικότητα του εδάφους της εγκατάστασης. Για την μέγιστη εκμετάλλευση αυτών των παραγόντων απαιτούνται σχετικά πολύπλοκες εγκαταστάσεις. Για παράδειγμα, υπάρχουν πάρκα με σειρές πανέλων σε ένα ή περισσότερα επίπεδα, πάρκα με κινητά πλαίσια πανέλων τα οποία έχουν την δυνατότητα να στρίβουν ανάλογα με την πορεία του ήλιου προκειμένου να επιτύχουν κάθετη πρόσπτωση τους φωτός επάνω στην επιφάνειά τους ή και πάρκα στα οποία υπάρχουν φακοί ή κάτοπτρα για να αυξάνουν την συγκέντρωση της ηλιακής ακτινοβολίας πάνω στα φωτοστοιχεία, εκμεταλλευόμενα την διάχυτη ηλιακή ακτινοβολία.



Σχήμα 2.1 : Ημέρα με ήλιο



Σχήμα 2.2 : Ημέρα με σύννεφα

Η εύρυθμη λειτουργία των Φ/Β εγκαταστάσεων σημαντικά από εξωγενείς καιρικούς παράγοντες, οι οποίοι μπορούν να επηρεάσουν και την ποσότητα του προσπίπτοντος φωτός πάνω στα Φ/Β στοιχεία και, κατά συνέπεια, την τελική παραγωγή ισχύος [5], [6]. Η παρουσία νεφών και νεφελωμάτων πάνω από την περιοχή της εγκατάστασης περιορίζει την ωφέλιμη ηλιακή ακτινοβολία που καταφθάνει στα φωτοστοιχεία. Με τον ίδιο τρόπο, η βροχή και η υγρασία εμποδίζουν την απρόσκοπτη πορεία του φωτός και πολλαπλασιάζουν τις ανακλάσεις του, ενώ ο άνεμος μπορεί να μεταφέρει σωματίδια σκόνης, χρώματος ή άμμου στον εναέριο χώρο της εγκατάστασης ή και να τα εναποθέσει πάνω στα πανέλα, μειώνοντας την λειτουργική επιφάνειά τους. Τέλος, η άνοδος της θερμοκρασίας των ημιαγωγικών φωτοστοιχείων επηρεάζει αρνητικά το παραγόμενο ρεύμα, καθώς μειώνεται η μέγιστη τάση που μπορούν να αποδώσουν υπό συγκεκριμένη ηλιακή ακτινοβολία. Στα Σχήματα 2.1 και 2.2 αποτυπώνεται η παραγωγή ισχύος του πάρκου Λαμπρινή σε δύο ημέρες με διαφορετικές καιρικές συνθήκες, όπου διαφαίνονται οι επιπτώσεις των καιρικών φαινομένων στην παραγωγή ισχύος και η στενή σχέση μεταξύ της προσπίπτουσας ηλιακής ακτινοβολίας και της παραγόμενης ισχύος.

2.3 ΔΙΕΙΣΔΥΣΗ ΑΠΕ ΣΤΑ ΔΙΚΤΥΑ ΔΙΑΝΟΜΗΣ

Η διείσδυση των Ανανεώσιμων Πηγών Ενέργειας, συμπεριλαμβανομένης και της ηλιακής, στο Δίκτυο Διανομής Ηλεκτρικής Ενέργειας επιβάλλει την συμμόρφωση του κάθε παραγωγού στις απαιτήσεις και τους περιορισμούς της λειτουργίας του δικτύου διανομής, προκειμένου να διατηρηθεί η ακεραιότητά του [7]. Για την αντιμετώπιση της συμφόρησης του δικτύου και την εξασφάλιση της σταθερότητάς του, κάθε μονάδα παραγωγής οφείλει να πληροί συγκεκριμένες προϋποθέσεις παραγωγής όσον αφορά τα χαρακτηριστικά μεγέθη ενεργού και άεργου ισχύος και συχνότητας, και να διαθέτει την ικανότητα έγκαιρου εντοπισμού σφαλμάτων και ρύθμισης της παραγόμενης τάσης ή ρεύματος, έτσι ώστε να αποφευχθεί η αλλοίωση της ποιότητας ισχύος.

Η σταδιακή αύξηση της διείσδυσης των ΑΠΕ στην παραγωγή ενέργειας επιβάλλει την συμμόρφωσή τους στις τεχνικές προδιαγραφές λειτουργίας των δικτύων (όπως επιβάλλει ο κώδικας ENTSO-E στην Ευρώπη), αλλά και την αξιοποίησή τους στην ρύθμιση του δικτύου, όπως για παράδειγμα στην ρύθμιση συχνότητας. Σε ένα Σύστημα Ηλεκτρικής Ενέργειας (ΣΗΕ), οι ανισορροπίες ανάμεσα στην παραγόμενη και καταναλισκόμενη ισχύ μπορούν να οδηγήσουν σε απότομες μεταβολές της συχνότητάς του ΣΗΕ, οι οποίες μπορεί να έχουν ολέθριες συνέπειες, καταστρέφοντας γεννήτριες ή και προκαλώντας σβέση (blackout) ολόκληρου του δικτύου. Για τον περιορισμό του εύρους της συχνότητας εντός επιτρεπτών ορίων, δηλαδή για την ρύθμιση της συχνότητας, κατά την διάρκεια τέτοιων διαταραχών ενεργοποιούνται μηχανισμοί που μηδενίζουν το σφάλμα της συχνότητας μέχρι την αποκατάσταση των φυσιολογικών συνθηκών λειτουργίας του δικτύου.

Όμως, η στοχαστική φύση των ΑΠΕ, κυρίως της ηλιακής και της αιολικής ενέργειας, αποτελεί τροχοπέδη στην κατάληψη τέτοιων ρυθμιστικών ρόλων από αυτές. Με εξαίρεση πηγές όπως τις υδροηλεκτρικές γεννήτριες, πρωταρχικός σκοπός των ΑΠΕ είναι η αποδοτικότερη αξιοποίηση της ανεξάντλητης πηγής ενέργειας (αιολικής και ηλιακής ενέργειας) για το χρονικό διάστημα που είναι εκμεταλλεύσιμη, γεγονός που αφήνει μικρά περιθώρια για τυχόν διαφορετικές λειτουργίες τους. Αυτή η έλλειψη αποθεμάτων ενέργειας λόγω μεγιστοποίησης της παραγωγής ισχύος, σε συνδυασμό με την περιορισμένη χρήση

μπαταριών αποτρέπει την κατάληψη ρυθμιστικών ρόλων στο δίκτυο ενέργειας. Επιπρόσθετα, η έλλειψη περιστρεφόμενων μερών στα Φ/Β, άρα και η μηδενική συνεισφορά τους στην αδράνεια του δικτύου, εμποδίζει την συμμετοχή τους στην άμεση απόκριση συχνότητας του συστήματος. Επιπλέον, η εξάρτησή τους από απρόβλεπτους παράγοντες (πχ. σύννεφα, νηνεμία, καταιγίδες, κτλ.) επιβάλλει την λήψη πρόσθετων μέτρων για να εξασφαλιστεί η ομαλή λειτουργία του δικτύου, που οδηγεί σε σπατάλη υλικών, ενέργειας και αύξηση του κόστους λειτουργίας τους. Όλοι αυτοί οι λόγοι, καθώς και η αδυναμία πλήρους ελέγχου τους από τον άνθρωπο, καθιστούν εξαιρετικά δύσκολη την αντικατάσταση των συμβατικών πηγών ενέργειας, όπως τα ορυκτά καύσιμα, των οποίων οι σύγχρονες γεννήτριες επιτελούν αυτούς τους ρυθμιστικούς ρόλους [8]–[11]. Η ενσωμάτωση μονάδων διανεμημένης παραγωγής, δηλαδή κατανεμημένων μικρών παραγωγικών μονάδων που συνδέονται στο δίκτυο διανομής ή απευθείας στον καταναλωτή, μπορεί δυναμικά να ωφελήσει το δίκτυο ενέργειας με την διαφοροποίηση των ενεργειακών πηγών, την μείωση του κόστους λειτουργίας αιχμής, την μείωση των ενεργειακών απωλειών, λόγω μεταφοράς και διανομής, και την εξομάλυνση των διακυμάνσεων του συστήματος, αλλά απαιτείται προσεκτική μελέτη για την τοποθέτηση τέτοιων μονάδων διανεμημένης παραγωγής στις πλέον κατάλληλες θέσεις του ηλεκτρικού δικτύου [12].

Παρά τις δυσκολίες που προκύπτουν κατά την ένταξη ολοένα και περισσότερων Φ/Β παραγωγών στο δίκτυο διανομής, η ηλιακή ενέργεια έχει πολλαπλά οφέλη και προοπτικές. Έχοντας ως μόνη απαίτηση την παρουσία του ήλιου, ένα Φ/Β πάρκο μπορεί να κατασκευασθεί ακόμα και σε απόμερες περιοχές. Συνεπώς, οι Φ/Β παραγωγοί μπορούν πάντοτε να καλύψουν μέρος των ηλεκτρικών αναγκών οποιασδήποτε περιοχής, κοντά σε μεγάλα αστικά κέντρα ή και σε δυσπρόσιτα μέρη. Αξιοσημείωτη είναι και η μορφή της παραγόμενης Φ/Β ισχύος, η οποία μεγιστοποιείται τις μεσημβρινές ώρες αιχμής, ακολουθώντας την ημερήσια καμπύλη ζήτησης [13].

2.4 ΠΡΟΒΛΕΨΗ ΠΑΡΑΓΩΓΗΣ ΗΛΙΑΚΗΣ ΕΝΕΡΓΕΙΑΣ

Η δυνατότητα πρόβλεψης της ενεργειακής παραγωγής των ΑΠΕ είναι απαραίτητο μέγεθος, που εν πολλοίς κρίνει και την δυνατότητα αύξησης της εισροής τους στο δίκτυο διανομής [11]. Συγκεκριμένα για την ηλιακή ενέργεια, η απρόβλεπτη φύση της κατά τις περιορισμένες ώρες ηλιοφάνειας εμποδίζει την αξιοποίησή της στις βοηθητικές λειτουργίες του δικτύου και επιβάλλει την συνύπαρξη άλλων παραγωγών και εφεδρικών γεννητριών παράλληλα στην λειτουργία της, για να διασφαλιστεί η απαιτούμενη παραγωγή ενέργειας. Εάν όμως καταστεί εφικτή η έγκυρη και έγκαιρη πρόβλεψη της παραγωγής κάθε Φ/Β πάρκου, ο προγραμματισμός του δικτύου διανομής αποκτά την δυνατότητα να συμπεριλάβει ηλιακούς παραγωγούς στις ρυθμίσεις του συστήματος, να περιορίσει την χρήση των εφεδρειών και να λάβει τα καταλληλότερα μέτρα με το μικρότερο δυνατό κόστος για την αντιμετώπιση των διακυμάνσεων στην παραγωγή αυτή.

2.4.1 Μέθοδοι Πρόβλεψης

Η πρόβλεψη της παραγωγής των ΑΠΕ αποτελεί ένα πεδίο με συνεχώς αυξανόμενη αξία, αφού συνδράμει στην βελτιστοποίηση της αξιοποίησης της Φ/Β παραγωγής και στην σταθερότητα του ηλεκτρικού συστήματος. Οι πρώτες μέθοδοι που αναπτύχθηκαν

βασίζονται είτε στην κλιματολογία, χρησιμοποιώντας ιστορικές τιμές των μεταβλητών του περιβάλλοντος (θερμοκρασία, άνεμος, υγρασία, κτλ.) για την δημιουργία καιρικών προβλέψεων, είτε στην υπόθεση της επιμονής των συνθηκών, δηλαδή στην υπόθεση ότι η τρέχουσα κατάσταση θα παραμείνει αναλλοίωτη και η σημερινή παραγωγή ισχύος θα επαναληφθεί και την επόμενη ημέρα [14]. Με την πάροδο των τελευταίων δεκαετιών αναπτύχθηκαν ποικίλες μέθοδοι πρόβλεψης, οι οποίες, αν και πιο περίπλοκες, έχουν την δυνατότητα να αποδώσουν προβλέψεις σημαντικά καλύτερες από τις απλούστερες μεθόδους.

Οι σύγχρονες μέθοδοι πρόβλεψης της παραγωγής Φ/Β πάρκων κατατάσσονται σε πολλές διαφορετικές κατηγορίες, ανάλογα με τον επιλεγμένο άξονα κατηγοριοποίησης. Οι σημαντικότερες κατηγορίες προσδιορίζονται ακολούθως [6], [15], [16]:

- Ανάλογα με τον χρονικό ορίζοντα πρόβλεψης:
 - Βραχυπρόθεσμες: αναφέρονται σε διάστημα λίγων λεπτών έως και μερικές μέρες. Είναι απαραίτητες για τον προγραμματισμό της λειτουργίας του δικτύου διανομής, καθώς εξασφαλίζουν τον σωστό προγραμματισμό και την κατανομή της παραγωγής, την έγκαιρη εκκίνηση των εφεδρειών και την ασφάλεια του συστήματος. Η αύξηση της ακρίβειας των βραχυπρόθεσμων προβλέψεων θα επιτρέψει την ανάληψη ρυθμιστικών ρόλων από τις ΑΠΕ.
 - Μεσοπρόθεσμες: αναφέρονται σε διάστημα μερικών ημερών έως και μήνα. Είναι χρήσιμες για την οργάνωση εργασιών συντήρησης των σταθμών παραγωγής ενέργειας.
 - Μακροπρόθεσμες: αναφέρονται σε διάστημα μηνών ή και χρόνου. Βοηθούν στην ανάπτυξη του συστήματος παραγωγής, μεταφοράς και διανομής της ηλεκτρικής ενέργειας και στην οργάνωση του δικτύου σε περιπτώσεις ένταξης ή απομάκρυνσης παραγωγών, εξυπηρέτησης νέων ηλεκτρικών φορτίων, κοκ.
- Ανάλογα με το είδος των δεδομένων πρόβλεψης:
 - Άμεσες: αναφέρονται στην απευθείας πρόβλεψη της παραγόμενης ισχύος των Φ/Β. Απαιτούν προσεκτική μελέτη των μεταβλητών που επηρεάζουν την Φ/Β παραγωγή.
 - Έμμεσες: αναφέρονται στην πρόβλεψη μεταβλητών, όπως η πυκνότητα της ηλιακής ακτινοβολίας, η θερμοκρασία ή η ταχύτητα του ανέμου, και στην μετέπειτα πρόβλεψη της παραγόμενης ισχύος των Φ/Β. Εξετάζουν εάν η ακριβέστερη πρόβλεψη άλλων μεταβλητών ωφελεί την μετέπειτα πρόβλεψη της Φ/Β ισχύος.
- Ανάλογα με τον τρόπο αξιοποίησης των ιστορικών δεδομένων:
 - Επιμονής: υποθέτουν την ημερήσια επανάληψη των εκάστοτε καιρικών συνθηκών. Αποτελούν το σημείο αναφοράς όλων των άλλων μοντέλων πρόβλεψης.
 - Στατιστικές: χρησιμοποιούν μαθηματικά μοντέλα και τεχνικές στατιστικής ανάλυσης για την εξαγωγή της πρόβλεψης. Αντιμετωπίζουν την παραγόμενη ισχύ ως εξαρτώμενη μεταβλητή και τις εισόδους (συνήθως την ηλιακή ακτινοβολία και την θερμοκρασία) ως ανεξάρτητες.

- Μηχανικής Μάθησης: χρησιμοποιούν αλγόριθμους που αξιοποιούν ιστορικά δεδομένα για την εξαγωγή πρόβλεψης. Είναι εύχρηστες και δεν προαπαιτούν γνώση για τις σχέσεις εξάρτησης των μεταβλητών, αφού τις εντοπίζουν οι ίδιες.
- Υβριδικές: συνδυάζουν τις άνωθεν μεθόδους (στατιστικές και μηχανικής μάθησης) για την εξαγωγή πρόβλεψης. Προσθέτουν μεγαλύτερη πολυπλοκότητα στις προβλεπόμενες μεταβλητές και εξαλείφουν τις αδυναμίες των μεμονωμένων μοντέλων.

Κάθε μέθοδος προσφέρει μία ιδιαίτερη και διαφορετική προσέγγιση στο πρόβλημα της επιτυχούς πρόβλεψης της παραγόμενης ισχύος και έχει τα δικά της πλεονεκτήματα και μειονεκτήματα. Η μεγάλη ποικιλία μεθόδων για την πρόβλεψη φωτοβολταϊκής παραγωγής επιτρέπει την επιτυχή εφαρμογή τους σε πολλές διαφορετικές περιπτώσεις και προσφέρει την δυνατότητα επιλογής της καταλληλότερης μεθόδου ανάλογα με τις ιδιαιτερότητες κάθε συστήματος. Ως σήμερα χρησιμοποιούνται περισσότερο οι άμεσες ή έμμεσες στατιστικές μέθοδοι, όμως τα τελευταία 20 χρόνια υπήρξε μια τεράστια άνθιση στις μεθόδους μηχανικής μάθησης, ενώ οι υβριδικές μέθοδοι εμφανίζονται στο προσκήνιο ολοένα και περισσότερο, συνδυάζοντας μεθόδους στατιστικές και μηχανικής μάθησης και αξιοποιώντας τα πλεονεκτήματά τους.

Στα πλαίσια της έρευνας αυτής επιλέχθηκαν δύο μέθοδοι Μηχανικής Μάθησης, τα Τεχνητά Νευρωνικά Δίκτυα ή ΤΝΔ (Artificial Neural Networks – ANN) και οι Μηχανές Διανυσμάτων Υποστήριξης ή ΜΔΥ (Support Vector Machines – SVM), που χρησιμοποιήθηκαν για την δημιουργία μοντέλων πρόβλεψης της παραγόμενης ισχύος δύο διαφορετικών Φ/Β πάρκων. Τα ΤΝΔ αποτελούν την πλέον γνωστή μέθοδο Επιβλεπόμενης Μηχανικής Μάθησης, με ποικίλες εφαρμογές σε κάθε επιστημονικό πεδίο, και παρέχουν την δυνατότητα προσαρμογής τους στο εκάστοτε πρόβλημα μέσω των πολλών διαθέσιμων επιλογών και ρυθμίσεων. Οι ΜΔΥ ανήκουν επίσης στις μεθόδους Επιβλεπόμενης Μηχανικής Μάθησης, αξιοποιούν όμως εργαλεία στατιστικής ανάλυσης τα οποία επιτρέπουν προβλέψεις βασισμένες σε λιγότερα δεδομένα. Οι δύο μέθοδοι θα αναλυθούν περισσότερο στα σχετικά κεφάλαιά τους.

2.5 ΤΑ Φ/Β ΠΑΡΚΑ ΤΗΣ ΕΡΕΥΝΑΣ

Τα μοντέλα που αναπτύχθηκαν από τις δύο Άμεσες μεθόδους Μηχανικής Μάθησης της εργασίας αναφέρονται σε Βραχυπρόθεσμες προβλέψεις και η εξαγωγή αυτών των προβλέψεων βασίζεται στα ιστορικά δεδομένα από δύο Φ/Β πάρκα της Ελλάδας, τα οποία βρίσκονται σε διαφορετικές περιφέρειες και έχουν διαφορετικό μέγεθος. Τα δεδομένα αυτά έχουν ληφθεί από αισθητήρες και μετρητές οι οποίοι βρίσκονται στην εκάστοτε εγκατάσταση. Για κάθε πρόβλεψη, χρησιμοποιούνται τα στοιχεία από τα τελευταία 225 λεπτά πριν την στιγμή της πρόβλεψης για να πραγματοποιηθούν 15 προβλέψεις της παραγόμενης ισχύος με απόσταση ενός δεκαπεντάλεπτου η καθεμία από την επόμενη. Στην εκπαίδευση των μοντέλων χρησιμοποιούνται δεδομένα έως και ενός έτους.

2.5.1 Το πάρκο Λαμπρινής

Το Φ/Β 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 kVA_r (reactive Power).
- Ολική πυκνότητα της ηλιακής ακτινοβολίας σε W/m² (Inclined Irradiance) σε δύο διαφορετικά σημεία του πάρκου.
- Στοιχεία από τον μετεωρολογικό σταθμό εντός του πάρκου με αισθητήρες για:
 - Θερμοκρασία περιβάλλοντος σε °C (ambient Temperature).
 - Υετό σε mm/h (Precipitation).
 - Ποσοστιαία Σχετική Υγρασία (relative Humidity).
 - Κατεύθυνση Ανέμου σε μοίρες (Wind Direction).
 - Ταχύτητα Ανέμου σε m/s (Wind Speed).
- Θερμοκρασία Φ/Β μονάδας σε °C από δύο διαφορετικά σημεία του πάρκου (module Temperature).

Οι μετρήσεις από κάθε αισθητήρα λαμβάνονται με χρονική απόσταση 1 λεπτού η καθεμία από την επόμενη, αφορούν σε ολόκληρα τα έτη 2020 και 2021, και είναι διαθέσιμες μέσω φυλλομετρητών του Microsoft Office (Excel Worksheets).

2.5.2 Το πάρκο της Περδικούλας

Το Φ/Β πάρκο «Περδικούλα» έχει ονομαστική ενεργό ισχύ 11,9 MW και διαθέτει 14 ομάδες Φ/Β πανέλων, στις οποίες έχει διάσπαρτα τοποθετημένους περιβαλλοντικούς αισθητήρες θερμοκρασίας και ηλιακής ακτινοβολίας. Από το πάρκο «Περδικούλα» 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 PCC σε kW (active Power).
- Ολική παραγόμενη άεργος ισχύς PCC σε kVA_r (reactive Power).
- Ολική πυκνότητα της ηλιακής ακτινοβολίας σε W/m² (Irradiance) σε 10 διαφορετικά σημεία του πάρκου.
- Στοιχεία από 5 μετεωρολογικούς σταθμούς εντός του πάρκου με αισθητήρες για:
 - Θερμοκρασία περιβάλλοντος σε °C (ambient Temperature).
 - Υετό σε mm/h (Precipitation).
 - Ποσοστιαία Σχετική Υγρασία (relative Humidity).
 - Κατεύθυνση Ανέμου σε μοίρες (Wind Direction).
 - Ταχύτητα Ανέμου σε m/s (Wind Speed).
- Θερμοκρασία Φ/Β μονάδας σε °C από 28 διαφορετικά σημεία του πάρκου (module Temperature).

Οι μετρήσεις από κάθε αισθητήρα λαμβάνονται με χρονική απόσταση 15 λεπτών η καθεμία από την επόμενη, αφορούν σε ολόκληρα τα έτη 2019 και 2020, και είναι διαθέσιμες μέσω φυλλομετρητών του Microsoft Office (Excel Worksheets).

2.5.3 Διαθέσιμα δεδομένα

Τα διαθέσιμα δεδομένα από τα δύο πάρκα παρέχονται σε όμοια μορφή και αφορούν τις ίδιες μεταβλητές, γεγονός που επιτρέπει τόσο την ανάπτυξη συγγενικών μοντέλων πρόβλεψης Φ/Β παραγωγής όσο και την μετέπειτα σύγκρισή τους. Η πληθώρα ιστορικών μετρήσεων για την ηλιακή ακτινοβολία, την θερμοκρασία, τον άνεμο και την υγρασία, παραγόντων που αποδεδειγμένα επηρεάζουν την παραγωγή των φωτοστοιχείων [6], σε συνδυασμό με τις μετρήσεις της παραγόμενης ισχύος επιτρέπει την έρευνα πάνω στη συσχέτιση αυτών των μεταβλητών για την δημιουργία προβλέψεων.

Η βασική διαφορά ανάμεσα στα προσβάσιμα δεδομένα εντοπίζεται στη συχνότητα δειγματοληψίας των πάρκων, με τα δεδομένα της Λαμπρινής να λαμβάνονται ανά 1 λεπτό, ενώ της Περδικούλας ανά 15 λεπτά. Ως συνέπεια αυτού υπάρχουν 15 φορές περισσότερα δεδομένα διαθέσιμα για το πάρκο της Λαμπρινής, άρα και περισσότερο διαθέσιμο υλικό για τις εκπαιδεύσεις των μοντέλων, όπως θα παρουσιαστούν στο Κεφάλαιο 5. Εκτός από την δημιουργία μοντέλων πρόβλεψης για τα δύο πάρκα που αξιοποιούν όλα τα δεδομένα ενός πάρκου, κρίνεται χρήσιμη η δημιουργία ενός ακόμα μοντέλου πρόβλεψης στο οποίο εισάγονται δεδομένα Λαμπρινής που απέχουν μεταξύ τους ένα τέταρτο της ώρας. Το νέο μοντέλο (Λαμπρινή ανά τέταρτο) μπορεί έπειτα να συγκριθεί με το αρχικό μοντέλο Λαμπρινής (Λαμπρινή ανά λεπτό), εξετάζοντας τις διαφορές που προκύπτουν από την μικρότερη συχνότητα δειγματοληψίας στο ίδιο πάρκο, και με το μοντέλο Περδικούλας, εξετάζοντας τις διαφορές που προκύπτουν από την ίδια συχνότητα δειγματοληψίας σε διαφορετικά πάρκα.

ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

3.1 ΓΕΝΙΚΑ

Τα Τεχνητά Νευρωνικά Δίκτυα ή ΤΝΔ (Artificial Neural Networks – ANN) είναι μηχανές που επιτελούν συγκεκριμένες εργασίες ή λειτουργίες, προσομοιώνοντας την δομή και συμπεριφορά των νευρώνων ενός ανθρώπινου νευρικού συστήματος. Υλοποιημένα είτε σε ηλεκτρονικές διατάξεις είτε σε ηλεκτρονικό υπολογιστή, μέσω λογισμικών προσομοίωσης, αποτελούνται από ένα σύνολο διασυνδεδεμένων τεχνητών νευρώνων-κυττάρων που εκπαιδεύονται παράλληλα μέσω μιας διαδικασίας μάθησης με χρήση δεδομένων που έχουν συλλεχθεί από το περιβάλλον. Η αποκτημένη γνώση «αποθηκεύεται» υπό την μορφή συναπτικών βαρών των διασυνδέσεων των νευρώνων και των πολώσεων των νευρώνων-κόμβων του δικτύου.

Ένα ΤΝΔ, εκτός από την μεγάλη υπολογιστική ικανότητα που επιτυγχάνει η παραλληλία της δομής του και την δυνατότητα γενίκευσης που παρέχει η διαδικασία μάθησής του, διαθέτει πληθώρα ιδιοτήτων που το καθιστούν χρήσιμο και ευέλικτο εργαλείο. Όπως συνοψίζεται στο [17], οι ιδιότητες των ΤΝΔ είναι οι ακόλουθες:

- *Μη γραμμικότητα*: κάθε νευρώνας, και κατά επέκταση ολόκληρο το δίκτυο, είναι μη γραμμικός, επομένως και η εκπαίδευση μπορεί να πραγματοποιηθεί με μη γραμμικά σήματα εισόδου (πχ. ηλιακή ακτινοβολία, θερμοκρασία, κτλ.).
- *Αντιστοίχιση εισόδου-εξόδου*: αναφέρεται στην ικανότητα τροποποίησης κάποιων παραμέτρων του δικτύου ώστε να επιτευχθεί η επιθυμητή απόκριση (έξοδος) του δικτύου για δεδομένο ερέθισμα (είσοδος). Αυτό επιτυγχάνεται μέσω της διαδικασίας επιβλεπόμενης μάθησης, όπου το ΤΝΔ εκπαιδεύεται σύμφωνα με πρότυπα παραδείγματα πολλαπλές φορές με σκοπό την μείωση της διαφοράς μεταξύ της πραγματικής απόκρισης και της απόκρισης του δικτύου στο ίδιο σήμα εισόδου (ελαχιστοποίηση στατιστικού σφάλματος).
- *Προσαρμοστικότητα*: ένα ΤΝΔ διατηρεί την ικανότητά του να μεταβάλλει τις εσωτερικές του παραμέτρους, όπως είναι τα συναπτικά βάρη, προκειμένου να προσαρμοστεί σε μεταβολές του περιβάλλοντός του, συνεχίζοντας πρακτικά την εκπαίδευσή του σε πραγματικό χρόνο.
- *Ενδεικτική απόκριση*: σε προβλήματα ταξινόμησης προτύπων, το δίκτυο παρέχει εκτός από την πρόβλεψη και τον βαθμό «εμπιστοσύνης» του πάνω στην πρόβλεψη.
- *Πληροφορία σχετική με το περιεχόμενο (contextual information)*: κάθε νευρώνας του δικτύου επηρεάζεται από την συνολική κατάσταση του δικτύου κάθε χρονική στιγμή, επομένως και η γνώση του δικτύου αντιπροσωπεύεται από τη δομή του και την κατάσταση ενεργοποίησής του.

- *Ανοχή σε βλάβες:* δεδομένου ότι η συνολική πληροφορία ενός ΤΝΔ κατανέμεται στους επιμέρους νευρώνες και στις μεταξύ τους διασυνδέσεις, μία βλάβη σε μικρό αριθμό νευρώνων μπορεί μεν να δυσχεραίνει την λειτουργία του συστήματος αλλά δεν οδηγεί στην κατάρρευσή του.
- *Ομοιομορφία Ανάλυσης και Σχεδίασης:* σε όλα τα πεδία εφαρμογής των ΤΝΔ χρησιμοποιείται η ίδια σημειογραφία. Κάθε δίκτυο αποτελείται από την ίδια βασική μονάδα, τον νευρώνα, γεγονός που επιτρέπει την ενοποίηση, την συσχέτιση και την κοινή μελέτη διαφορετικών συστημάτων υπό το πρίσμα ίδιων θεωριών και αλγορίθμων.

Αυτές οι ιδιότητες των ΤΝΔ σε συνδυασμό με την δυνητικά γρήγορη εκτέλεση εργασιών, λόγω της παράλληλης φύσης των υπολογιστικών διαδικασιών τους, έχουν οδηγήσει σε εκτεταμένη χρήση τους και σε συνεχή εξέλιξή τους μέσω της μελέτης των χαρακτηριστικών τους. Η προσομοίωση ενός νευρωνικού δικτύου μπορεί να υλοποιηθεί σε ηλεκτρονικό υπολογιστή με χρήση βιβλιοθηκών της προγραμματιστικής γλώσσας Python, για τις οποίες βιβλιοθήκες υπάρχει εκτενές υλικό διαθέσιμο στο διαδίκτυο.


3.2 ΒΑΣΙΚΑ ΣΤΟΙΧΕΙΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

3.2.1 Δομή Νευρώνα

Η βασική μονάδα ενός νευρωνικού δικτύου είναι ο νευρώνας. Ένας νευρώνας επεξεργάζεται τις πληροφορίες που δέχεται υπό μορφή σήματος και εκτελεί σε αυτές προκαθορισμένες πράξεις, με σκοπό να προωθήσει τις τροποποιημένες πληροφορίες στον επόμενο νευρώνα ή στην έξοδο του δικτύου.

Στο Σχήμα 3.1 φαίνεται μία σχηματική αναπαράσταση ενός τυπικού νευρώνα, όπου η μεταβαλλόμενη πληροφορία ρέει από αριστερά προς τα δεξιά. Μέσω διασυνδέσεων (ή συνάψεων) κάθε νευρώνας λαμβάνει έναν αριθμό από σήματα τα οποία προέρχονται από άλλους νευρώνες ή αποτελούν τα σήματα εισόδου του δικτύου. Διατηρεί έναν πίνακα από συναπτικά βάρη w , ένα βάρος w_{kj} για κάθε σύναψη j που καταλήγει στον νευρώνα k , ενώ κάθε εισερχόμενο σήμα πολλαπλασιάζεται με το σχετικό βάρος της αντίστοιχης σύναψης. Κατόπιν, τα προκύπτοντα γινόμενα αθροίζονται μεταξύ τους και με την πόλωση b_k του νευρώνα k , δημιουργώντας το σήμα u_k . Το σήμα αυτό περιορίζεται από μία συνάρτηση ενεργοποίησης $\varphi(x)$ σε ένα τυπικό εύρος τιμών (συνήθως $[0,1]$ ή $[-1,1]$) και, τέλος, οδηγείται στον επόμενο νευρώνα ή έξοδο.

Κάθε στοιχείο ενός νευρώνα επιτελεί και διαφορετικό ρόλο στην λειτουργία του. Τα συναπτικά βάρη λαμβάνουν και θετικές και αρνητικές τιμές και έχουν σκοπό ή να περιορίζουν ή να αφήνουν ανεπηρέαστα τα σήματα εισόδου να οδηγηθούν στον αθροιστή, δημιουργώντας ενός είδους «προτίμηση» του νευρώνα σε συγκεκριμένες εισόδους. Ο αθροιστής παράγει την πληροφορία που επιθυμεί να μεταβιβάσει ο εκάστοτε νευρώνας στον επόμενο και η συνάρτηση ενεργοποίησης περιορίζει την πληροφορία στα επιτρεπτά όρια πλάτους. Τέλος, η πόλωση αναλαμβάνει την μείωση ή αύξηση της διέγερσης της συνάρτησης ενεργοποίησης και είναι χαρακτηριστική κάθε νευρώνα.




Σχήμα 3.1 : Αναπαράσταση νευρώνα ενός ΤΝΔ

3.2.2 Δομή και Αρχιτεκτονική Δικτύου

Ένα νευρωνικό δίκτυο μπορεί να συμβολιστεί με έναν κατευθυνόμενο γράφο, όπου οι νευρώνες είναι οι κόμβοι και οι διασυνδέσεις του είναι οι γραμμές που ενώνουν τους κόμβους. Όπως φαίνεται στο Σχήμα 3.2, οι νευρώνες τοποθετούνται σε επίπεδα και η ροή της πληροφορίας ακολουθεί την κατεύθυνση του βέλους μίας γραμμής. Επομένως, όλες οι συνδέσεις που δείχνουν προς έναν κόμβο αποτελούν τις εισόδους του, ενώ αυτές που ξεκινούν από αυτόν αποτελούν τις εξόδους του. Κάθε νευρώνας αποστέλλει την ίδια πληροφορία-σήμα σε κάθε κόμβο εξόδου, το οποίο σήμα έχει προκύψει από το σταθμισμένο άθροισμα των εισόδων του νευρώνα, σύμφωνα με την διαδικασία που αναφέρθηκε στην Ενότητα 3.2.1. Οι πλώσεις συμβολίζονται όπως οι συνάψεις, με έξοδο στον αντίστοιχο κόμβο τους και είσοδο με σταθερή τιμή +1.

Στο Σχήμα 3.2 είναι εμφανής και η οργάνωση των νευρώνων ενός δικτύου σε επίπεδα (Layers). Σε κάθε ΤΝΔ υπάρχουν τουλάχιστον δύο επίπεδα, το Επίπεδο Εισόδου (Input Layer) αποτελούμενο από πηγές και το Επίπεδο Εξόδου (Output Layer) αποτελούμενο από νευρώνες. Ένα τέτοιο δίκτυο χωρίς αναδράσεις στην ροή πληροφορίας και με μόνο ένα επίπεδο νευρώνων ονομάζεται Ενόσ Επιπέδου Δίκτυο Πρόσθιας Τροφοδότησης (One Layer Feedforward Network). Εάν, όπως στο σχήμα, παρεμβάλλονται ένα ή περισσότερα επίπεδα ανάμεσα στα επίπεδα εισόδου και εξόδου, τότε κάθε ένα από αυτά καλείται Κρυφό Επίπεδο Νευρώνων (Hidden Layer) και το δίκτυο χαρακτηρίζεται ως Πολυεπίπεδο (Multilayered). Ο χαρακτηρισμός «κρυφός» αναφέρεται στο γεγονός ότι οι ενδιάμεσοι «κρυφοί» νευρώνες δεν



Σχήμα 3.2 : Αναπαράσταση των νευρώνων και των συνάψεων ενός ΤΝΔ

είναι ορατοί ούτε από την είσοδο ούτε από την έξοδο του δικτύου. Η προσθήκη περισσότερων νευρώνων και επιπέδων πολλαπλασιάζει τον αριθμό των συνάψεων του δικτύου και επιτρέπει πιο σύνθετες εκπαιδεύσεις.

Στα δίκτυα πρόσθιας τροφοδότησης όλοι οι νευρώνες ενός κρυφού επιπέδου λαμβάνουν ως σήματα εισόδου τις εξόδους των κόμβων του προηγούμενου επιπέδου και αποστέλλουν το σήμα εξόδου τους σε κάθε κόμβο του επόμενου επιπέδου. Οι πηγές σημάτων του επιπέδου εισόδου αποτελούν τις εισόδους του επόμενου επιπέδου και οι εξόδοι των νευρώνων του επιπέδου εξόδου αποτελούν τις εξόδους ολόκληρου του δικτύου.

Στην περίπτωση όπου στον γράφο ενός δικτύου υπάρχει τουλάχιστον ένας βρόχος ανάδρασης, το δίκτυο χαρακτηρίζεται ως Αναδρομικό Δίκτυο (Recurrent Network). Σε κάθε βρόχο ανάδρασης υπάρχει τουλάχιστον ένας κλάδος με στοιχεία μοναδιαίας χρονικής καθυστέρησης, τα οποία προωθούν το σήμα τους στην επόμενη επανάληψη της εκπαίδευσης του δικτύου. Αυτό έχει ως αποτέλεσμα την ανατροφοδότηση προηγούμενων εξόδων του δικτύου στις εισόδους της νέας εκτέλεσής του. Με αυτόν τον τρόπο ένα νευρωνικό δίκτυο συνυπολογίζει στην εκπαίδευσή του αποτελέσματα προηγούμενων χρονικών βημάτων, επομένως και εκπαιδεύεται λαμβάνοντας υπόψιν προηγούμενες προβλέψεις του.

3.2.3 Παράμετροι και Υπερπαράμετροι

Τα νευρωνικά δίκτυα αποτελούνται από ένα σύνολο παραμέτρων, δηλαδή μεταβλητών που προκύπτουν από την διαδικασία εκπαίδευσής τους, και ένα σύνολο υπερπαραμέτρων, δηλαδή μεταβλητών που ορίζει ο κατασκευαστής του δικτύου κατά την επιλογή του μοντέλου εργασίας για τον έλεγχο της μάθησης. Όπως έχει ήδη αναφερθεί, οι ποσότητες που προκύπτουν από την εκπαίδευση ενός δικτύου, άρα και οι παράμετροί του, είναι τα βάρη των συνάψεων και οι πολώσεις των νευρώνων. Κατά την διαδικασία της εκπαίδευσης οι παράμετροι αλλάζουν συνεχώς, μέχρι να λάβουν την τελική τιμή τους κατά


την λήξη της εκπαίδευσης. Ο αριθμός, το είδος και ο τρόπος με τον οποίο ενημερώνονται οι παράμετροι ορίζεται από τις υπερπαραμέτρους.

Υπάρχουν δύο υπερπαραμέτροι που καθορίζουν την αρχιτεκτονική ενός δικτύου: ο αριθμός των κρυφών επιπέδων νευρώνων και ο αριθμός των νευρώνων ανά επίπεδο. Οι κόμβοι εισόδου είναι πάντα όσα τα σήματα εισόδου, ενώ ο αριθμός των εξόδων καθορίζεται από την επιθυμητή λειτουργία του μοντέλου πρόβλεψης. Επομένως, ο αριθμός των συνάψεων εξαρτάται από το πλήθος και το μέγεθος των κρυφών επιπέδων, που είναι και οι παράγοντες που καθορίζουν και τον αριθμό των διασυνδέσεων που απαιτούνται μεταξύ των νευρώνων. Η δημιουργία δικτύων με πολλούς κρυφούς νευρώνες αυξάνει την υπολογιστική δύναμή τους και τους παρέχει ευελιξία και ανοχή στα σφάλματα, μπορεί ωστόσο να οδηγήσει σε πολύπλοκα συστήματα που αδυνατούν να γενικεύσουν τις λύσεις τους εκτός των ορίων της εκπαίδευσής τους. Η επιλογή του σωστού αριθμού κρυφών επιπέδων και νευρώνων είναι κρίσιμη για την διατήρηση της απλότητας ενός δικτύου και την αποφυγή δημιουργίας μηχανών με μεγάλες ενεργειακές απαιτήσεις.


Κατά την διαδικασία της εκπαίδευσης κάθε νευρωνικό δίκτυο τροφοδοτείται με συγκεκριμένα σήματα εισόδου και, στα πλαίσια της επιβλεπόμενης μάθησης, συγκρίνει τις παραγόμενες εξόδους του με τις πραγματικές εξόδους ενός φυσικού συστήματος (πχ. Είσοδοι: ηλιακή ακτινοβολία και θερμοκρασία περιβάλλοντος, Έξοδος: φ/β ισχύς). Σε κάθε διαδικασία σύγκρισης υπολογίζεται το σφάλμα ανάμεσα στην πρόβλεψη και την πραγματική τιμή, ενημερώνονται οι παράμετροι του δικτύου με τις νέες τιμές και επαναλαμβάνεται η ίδια διαδικασία. Σκοπός κάθε εκπαίδευσης ενός ΤΝΔ είναι η ελαχιστοποίηση ενός σφάλματος, τυπικά του ελάχιστου μέσου τετραγωνικού σφάλματος, και στόχος είναι η σύγκλιση του συστήματος στη λύση με το ελάχιστο δυνατό σφάλμα μέσω των συνεχών ενημερώσεων των τιμών των παραμέτρων. Ο αριθμός των επαναλήψεων ονομάζεται εποχή και καθορίζει την διάρκεια της εκπαίδευσης. Ο αριθμός των εποχών πρέπει να είναι αρκετά μεγάλος ώστε το σύστημα να μπορέσει να συγκλίνει προς μία τελική και σταθερή κατάσταση, αλλά αρκετά μικρός ώστε να αποφευχθούν άσκοπες επαναλήψεις.

Αν και οι εποχές καθορίζουν τις επαναλήψεις των δεδομένων εισόδου στα πλαίσια μιας εκπαίδευσης, το μέγεθος παρτίδας (batch size) καθορίζει τον αριθμό των δειγμάτων που θα διαπερνά το δίκτυο κάθε φορά, μέχρι να ενημερωθούν οι παράμετροί του. Μετά από κάθε εκπαίδευση με μία παρτίδα, ενημερώνεται κάθε βάρος και πόλωση, με σκοπό την σύγκλιση προς την τελική κατάσταση του δικτύου. Το μέγεθος της αλλαγής που επιτρέπεται να γίνει σε ένα βάρος ή μία πόλωση ονομάζεται ρυθμός μάθησης (learning rate) και καθορίζει την ταχύτητα με την οποία συγκλίνει το σύστημα προς την λύση του. Οι μεγάλοι ρυθμοί μάθησης επιτρέπουν στο δίκτυο να συγκλίνει γρηγορότερα, αλλά έχουν τον κίνδυνο αυτό να μην συγκλίνει ποτέ (ταλάντωση), ενώ μικρότεροι ρυθμοί μάθησης συγκλίνουν ευκολότερα αλλά με πιο αργό ρυθμό. Για να αποφύγει το δίκτυο την σύγκλιση σε κάποιο τοπικό ελάχιστο, δηλαδή μία κατάσταση του δικτύου όπου επιτυγχάνεται μικρότερο σφάλμα από ότι σε γειτονικές καταστάσεις με μικρές διαφορές στην τιμή των παραμέτρων τους, αλλά μεγαλύτερο από ότι σε καταστάσεις όπου οι παράμετροι είναι εντελώς διαφορετικές, προσθέτει ένα ποσοστό της προηγούμενης αλλαγής κάθε παραμέτρου σε κάθε ενημέρωσή τους. Αυτό το ποσοστό ονομάζεται ορμή (momentum) και συνήθως επιταχύνει την σύγκλιση του συστήματος. Ωστόσο, υψηλές τιμές ορμής μπορούν να οδηγήσουν σε υπερπήδηση του ελαχίστου, αποσταθεροποιώντας το σύστημα.


Στην δομή των νευρώνων αναφέρθηκαν οι συναρτήσεις ενεργοποίησης, οι οποίες περιορίζουν το σήμα ενός νευρώνα σε ένα επιτρεπτό εύρος, με έναν μη γραμμικό τρόπο. Μία συνάρτηση ενεργοποίησης πρέπει να είναι συνεχής, διαφορίσιμη και να διαθέτει την δυνατότητα να περιορίζει ή να ενεργοποιεί έναν νευρώνα, επιτρέποντας σε ένα δίκτυο να μαθαίνει και να εκτελεί πιο σύνθετες εργασίες. Στα Σχήματα 3.3 έως 3.10 παρουσιάζονται οκτώ τυπικές συναρτήσεις ενεργοποίησης, όπως είναι η σιγμοειδής, η υπερβολική εφαπτομένη ή η ELU (Exponential Linear Unit). Σε επόμενα κεφάλαια της διπλωματικής εργασίας εξετάζεται η επίπτωση της επιλογής αυτών των οκτώ συναρτήσεων ενεργοποίησης στην ακρίβεια της πρόβλεψης της Φ/Β παραγωγής.




Σχήμα 3.3 : Η συνάρτηση ενεργοποίησης ELU




Σχήμα 3.4 : Η συνάρτηση ενεργοποίησης ReLU




Σχήμα 3.5 : Η συνάρτηση ενεργοποίησης SELU




Σχήμα 3.6 : Η εκθετική συνάρτηση ενεργοποίησης




Σχήμα 3.7 : Η σιγμοειδής συνάρτηση ενεργοποίησης



Σχήμα 3.8 : Η συνάρτηση ενεργοποίησης Softplus



Σχήμα 3.9 : Η συνάρτηση ενεργοποίησης Softsign



Σχήμα 3.10 : Η συνάρτηση ενεργοποίησης της υπερβολικής εφαπτομένης

3.2.4 Σφάλματα και Δείγματα

Σε επιβλεπόμενα συστήματα για προβλήματα παλινδρόμησης, όπως η πρόβλεψη μίας ποσότητας (πχ. Ενεργός Ισχύς) από ιστορικά δεδομένα άλλων μεταβλητών (πχ. Ηλιακή Ακτινοβολία, Θερμοκρασία, κτλ.), ο σκοπός της εκπαίδευσης του ΤΝΔ είναι η ελαχιστοποίηση της διαφοράς της τιμής της πρόβλεψης και της πραγματικής ιστορικής τιμής της μετρούμενης ποσότητας. Η απόλυτη διαφορά των δύο μεγεθών όμως δεν είναι συχνά ενδεικτική της απόδοσης ενός δικτύου, δεδομένου ότι τα μετρούμενα μεγέθη λαμβάνουν τιμές σε διάφορες τάξεις μεγέθους. Αντί της απόλυτης τιμής της διαφοράς, ως στατιστικό μέτρο απόδοσης του συστήματος ορίζεται συνήθως το μέσο τετραγωνικό σφάλμα (Mean Square Error ή MSE):

$$MSE = \frac{1}{N} \times \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 \quad (3.1)$$

όπου N ο αριθμός των δειγμάτων, Y_i η πραγματική τιμή της ποσότητας Y για το δείγμα i και \hat{Y}_i η τιμή της πρόβλεψης.

Ένα άλλο στατιστικό σφάλμα που χρησιμοποιείται ως μέτρο ακρίβειας σε προβλήματα πρόβλεψης είναι το μέσο απόλυτο ποσοστιαίο σφάλμα (Mean Average Percentage Error ή MAPE):

$$MAPE = \frac{100\%}{N} \times \sum_{i=1}^N \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (3.2)$$

Το MAPE ως στατιστική ποσότητα προσφέρει μία διαισθητική ερμηνεία του σφάλματος πρόβλεψης, καθότι η απόκλιση της προβλεπόμενης ποσότητας από την πραγματική εκφράζεται σε σχέση με την πραγματική τιμή.

Ανάλογα με μέτρο εκτίμησης της απόδοσης ενός δικτύου που επιλέγεται, η εκπαίδευση ενός νευρωνικού δικτύου αποσκοπεί στην ελαχιστοποίηση του σχετικού σφάλματος. Όλες οι υπερπαραμέτροι ενός δικτύου επιλέγονται με τέτοιο τρόπο ώστε να επιτυγχάνεται η σύγκλιση προς το ελάχιστο δυνατό σφάλμα, άρα και προς την μέγιστη δυνατή ταύτιση πρόβλεψης και πραγματικής τιμής. Η τιμή του σφάλματος που προκύπτει από σύγκριση του δείγματος με το οποίο εκπαιδεύεται (Δείγμα Εκπαίδευσης ή Training Set) ένα δίκτυο και των αντίστοιχων προβλέψεών του ονομάζεται σφάλμα εκπαίδευσης (Training Error). Το σφάλμα που προκύπτει από οποιοδήποτε άλλο δείγμα που «ελέγχει» την απόδοση του δικτύου (Δείγμα Ελέγχου ή Test Set) σε δεδομένα που δεν έχει συναντήσει ποτέ ονομάζεται σφάλμα ελέγχου (Test Error).

Η συνήθης τακτική για την εκπαίδευση ενός νευρωνικού δικτύου συμπεριλαμβάνει τον διαχωρισμό των διαθέσιμων δεδομένων στα σύνολα εκπαίδευσης και ελέγχου. Αφού ολοκληρωθεί η διαδικασία της μάθησης πάνω στα δείγματα εκπαίδευσης και εξαχθούν οι σχετικές προβλέψεις και σφάλματα, το δίκτυο εξετάζεται με το δείγμα ελέγχου. Δεδομένου ότι στο δείγμα ελέγχου υπάρχουν στοιχεία με τα οποία δεν έχει αλληλοεπιδράσει ξανά το δίκτυο, το σφάλμα ελέγχου αναμένεται μεγαλύτερο από το σφάλμα εκπαίδευσης. Η

επιτυχημένη απόκριση ενός δικτύου στα δεδομένα που του παρουσιάζονται για πρώτη φορά αποκαλείται γενίκευση και είναι ενδεικτική ενός αποδοτικού δικτύου.

3.3 ΠΡΟΒΛΕΨΗ ΠΑΡΑΓΩΓΗΣ ΙΣΧΥΟΣ ΜΕΣΩ ΤΝΔ

Τα τελευταία 20 χρόνια, μοντέλα που βασίζονται σε τεχνικές Τεχνητής Νοημοσύνης (Artificial Intelligence ή AI) και Μηχανικής Μάθησης (Machine Learning) εφαρμόζονται επιτυχώς σε εφαρμογές για την πρόβλεψη παραγωγής ηλεκτρικής ισχύος και περιβαλλοντικών μεταβλητών όπως θερμοκρασία και ηλιακή ακτινοβολία (άμεση και έμμεση πρόβλεψη) [6]. Η ικανότητά τους να εντοπίζουν μοτίβα στα ιστορικά δεδομένα και η μη γραμμική επεξεργασία τους προσφέρουν μία νέα λύση στο πρόβλημα της πρόβλεψης των ΑΠΕ, μειώνοντας αισθητά τα σφάλματα των προϋπαρχόντων στατιστικών μοντέλων. Η προσαρμοστικότητά τους και η ανοχή τους στα σφάλματα καθιστούν εφαρμογές βασισμένες στην χρήση ΤΝΔ συχνά καλύτερες από κλασικά στατιστικά μοντέλα [16].

Όπως αναφέρεται στην εργασία [18], τα ΤΝΔ εφαρμόζονται πολύ εύκολα στις περισσότερες περιπτώσεις, καθότι δεν προαπαιτούν υποθέσεις για τις σχέσεις που συνδέουν τις εισόδους και τις εξόδους του δικτύου. Ένα ΤΝΔ αναλαμβάνει μόνο του κατά την εκπαίδευσή του να μοντελοποιήσει αυτές τις σχέσεις και να συσχετίσει, για παράδειγμα, την υψηλή ηλιακή ακτινοβολία με μεγάλη παραγόμενη ισχύ ή αντίθετα την απουσία φωτός με την μηδενική ισχύ. Αυτό το καταφέρνει δίνοντας μεγαλύτερα συναπτικά βάρη σε διασυνδέσεις που μεταφέρουν πληροφορία από το σήμα εισόδου για την ηλιακή ακτινοβολία και μικρότερα βάρη στις διασυνδέσεις των υπόλοιπων μεταβλητών εισόδου.

Παρά τα μεγάλα πλεονεκτήματά τους, τα νευρωνικά δίκτυα είναι επιρρεπή στην υπερπροσαρμογή (overfitting) τους στο συγκεκριμένο πρόβλημα που επιλύουν. Ένα σωστά σχεδιασμένο ΤΝΔ αποκτά την ικανότητα της γενίκευσης (generalization), δηλαδή να παράγει σωστή αντιστοίχιση εισόδου-εξόδου ακόμα και με δεδομένα εισόδου διαφορετικά από αυτά με τα οποία εκπαιδεύτηκε. Όμως, στην περίπτωση που το ΤΝΔ εκπαιδεύεται με πολλά παραδείγματα εισόδου-εξόδου κινδυνεύει να υπερεκπαιδευτεί (overtraining), απομνημονεύοντας τα παραδείγματα αυτά και αδυνατώντας να λειτουργήσει με νέα δεδομένα. Επομένως, καθίσταται απαραίτητος ο σωστός σχεδιασμός του ΤΝΔ προκειμένου να αποφευχθεί η υπερπροσαρμογή και να επιτευχθεί η σωστή πρόβλεψη παραγωγής ισχύος παρά τα ευμετάβλητα καιρικά φαινόμενα.


ΜΗΧΑΝΕΣ ΔΙΑΝΥΣΜΑΤΩΝ ΥΠΟΣΤΗΡΙΞΗΣ

4.1 ΓΕΝΙΚΑ

Οι Μηχανές Διανυσμάτων Υποστήριξης ή ΜΔΥ (Support Vector Machines, SVM), όπως και τα Τεχνητά Νευρωνικά Δίκτυα, αποτελούν μία ειδική κατηγορία δικτύων μηχανικής μάθησης με σκοπό την εκτέλεση μίας συγκεκριμένης λειτουργίας [17]. Είναι μοντέλα επιβλεπόμενης μάθησης και χρησιμοποιούνται κυρίως για την στατιστική ταξινόμηση και παλινδρόμηση δεδομένων (statistical classification and regression). Το όνομά τους προέρχεται από τα διανύσματα υποστήριξης x_i , των οποίων το εσωτερικό γινόμενο με ένα διάνυσμα x από τα δεδομένα εισόδου αποτελεί τον «πυρήνα», την κεντρική ιδέα δηλαδή για την ανάπτυξη του αλγόριθμου μάθησης (πυρήνας εσωτερικού γινομένου, inner product kernel).

Οι ΜΔΥ χρησιμοποιούνται για την επίλυση δύο ειδών προβλημάτων: ταξινόμησης μοτίβων και μη γραμμικής παλινδρόμησης. Αν και το δεύτερο είδος είναι αυτό που συμπεριλαμβάνει προβλήματα πρόβλεψης της τιμής μιας ποσότητας, όπως η παραγόμενη ισχύς ενός Φ/Β πάρκου, το πρώτο είδος είναι το καταλληλότερο για την περιγραφή και την κατανόηση της λειτουργίας μίας ΜΔΥ. Μία μηχανή που επιλύει πρόβλημα ταξινόμησης αναλαμβάνει να αντιστοιχήσει το σύνολο των δεδομένων εισόδου σε έναν συγκεκριμένο αριθμό κλάσεων, όπως είναι, για παράδειγμα, η κατηγοριοποίηση χρονικών στιγμών σε «φωτεινές» και «σκοτεινές». Εάν υποθεθεί ότι στα δεδομένα εκπαίδευσης υπάρχουν n σε αριθμό μεταβλητές (πχ. ώρα της ημέρας, γεωγραφική τοποθεσία, ημερομηνία, κτλ.), μία ΜΔΥ κατασκευάζει ένα υπερεπίπεδο $n-1$ διαστάσεων ως επιφάνεια απόφασης, με τρόπο ώστε το περιθώριο διαχωρισμού μεταξύ παραδειγμάτων διαφορετικών κλάσεων να μεγιστοποιείται. Μία τέτοια μηχανή αναλαμβάνει να δημιουργήσει ένα σύνορο που ξεχωρίζει απευθείας κάθε διαφορετική παρατήρηση στις διαθέσιμες κατηγορίες, με τέτοιο τρόπο ώστε αυτό να είναι «βέλτιστο» και να απέχει όσο το δυνατόν περισσότερο από την πλησιέστερη παρατήρηση κάθε κατηγορίας.

Στο παράδειγμα του Σχήματος 4.1 μελετάται ο διαχωρισμός των χρονικών στιγμών σε «φωτεινές» και «σκοτεινές» για το κέντρο της πόλης του Ηρακλείου Κρήτης. Τα δεδομένα του συνόλου εκπαίδευσης της μηχανής που επιλύει το πρόβλημα ορίζονται από δύο μεταβλητές, ημερομηνία και ώρα, και επομένως ο χώρος των δεδομένων εισόδου είναι δύο διαστάσεων, δηλαδή ένα επίπεδο. Η μηχανή αναλαμβάνει να δημιουργήσει ένα σύνορο $2-1=1$ διάστασης, δηλαδή μία γραμμή (με μπλε χρώμα στο σχήμα), η οποία αποτελεί την «επιφάνεια απόφασης» της: κάθε δεδομένο εισόδου του οποίου το αντίστοιχο σημείο στο επίπεδο βρίσκεται στο ημιεπίπεδο που ορίζεται από την επιφάνεια απόφασης και πάνω ταξινομείται ως «φωτεινό». Αντίθετα, κάθε δεδομένο με σημείο στο ημιεπίπεδο κάτω από την επιφάνεια απόφασης χαρακτηρίζεται ως «σκοτεινό». Ιδανικά, η επιφάνεια απόφασης θα έπρεπε να ταυτίζεται με την γραμμή που σχηματίζουν τα σημεία της ανατολή του ηλίου για την πόλη του Ηρακλείου (με πορτοκαλί χρώμα στο σχήμα), ωστόσο η εκπαίδευση της



Σχήμα 4.1 : ΜΔΥ για τον διαχωρισμό φωτεινών και σκοτεινών στιγμών

μηχανής έγινε με δείγμα που περιλάμβανε λίγες μόνο χρονικές στιγμές μέσα στον χρόνο. Παρά τα ελλιπή στοιχεία, η μηχανή δημιούργησε ένα «βέλτιστο» σύνορο αρκετά κοντά στο ιδανικό, με αποτέλεσμα οι περισσότερες στιγμές να ταξινομηθούν σωστά (με πράσινο και κίτρινο χρώμα στο σχήμα). Οι περιπτώσεις που ταξινομήθηκαν λάθος παρουσιάζονται με κόκκινο χρώμα και όλες αναφέρονται σε στιγμές σκοταδιού που κατηγοριοποιήθηκαν ως φωτεινές.

Η εξίσωση μιας επιφάνειας απόφασης είναι η ακόλουθη:

$$\mathbf{w}^T \mathbf{x} + b = 0 \quad (4.1)$$

όπου \mathbf{x} ένα διάνυσμα της επιφάνειας απόφασης, \mathbf{w} το διάνυσμα βαρών και b η πόλωση. Στόχος της μηχανής διανυσμάτων υποστήριξης είναι η εύρεση της βέλτιστης επιφάνειας με την οποία επιτυγχάνεται ο σωστός διαχωρισμός των δεδομένων εισόδου:

$$\begin{aligned} \mathbf{w}_o^T \mathbf{x}_i + b_o &\geq 0, & \text{για την κλάση 1} \\ \mathbf{w}_o^T \mathbf{x}_i + b_o &< 0, & \text{για την κλάση 2} \end{aligned} \quad (4.2)$$

(όπου \mathbf{w}_o και b_o συμβολίζουν τις βέλτιστες τιμές του διανύσματος βαρών και της πόλωσης και \mathbf{x}_i ένα διάνυσμα εισόδου) και η μεγιστοποίηση του ρ που είναι η απόσταση του πλησιέστερου σημείου δεδομένων από το σύνορο και ονομάζεται περιθώριο διαχωρισμού (margin of separation) (Σχήμα 4.1). Η μεγιστοποίηση του ρ αποσκοπεί στην ελαχιστοποίηση των σφαλμάτων της μηχανής, καθώς τα σημεία που βρίσκονται κοντά στο σύνορο είναι πιθανότερο να ταξινομηθούν σε λάθος κλάση. Αυξάνοντας την απόσταση του πλησιέστερου σημείου εισόδου από το σύνορο εξασφαλίζεται και η καλύτερη δυνατή απόδοση της μηχανής.

Ένα σημείο δεδομένων που απέχει την βέλτιστη απόσταση ρ_o από το σύνορο (με κίτρινο χρώμα στο σχήμα) ικανοποιεί μία από τις ακόλουθες εξισώσεις:

$$\begin{aligned} \mathbf{w}_o^T \mathbf{x}_i + b_o &\geq 1, && \text{για την κλάση 1} \\ \mathbf{w}_o^T \mathbf{x}_i + b_o &\leq -1, && \text{για την κλάση 2} \end{aligned} \quad (4.3)$$

Το διάνυσμα του σημείου αυτού αποκαλείται διάνυσμα υποστήριξης και σε αυτό οφείλεται η ονομασία των αντίστοιχων μηχανών. Δεδομένης της μικρής απόστασής τους από το σύνορο, αυτά τα σημεία είναι και τα δυσκολότερα να ταξινομηθούν και έχουν άμεση επίδραση στη βέλτιστη θέση της επιφάνειας απόφασης.

Ως μέθοδος βασισμένη τόσο στην στατιστική θεωρία όσο και στην μηχανική μάθηση, κυρίαρχος σκοπός των ΜΔΥ είναι η γενίκευση (generalization) της λύσης που εξάγεται από την εκπαίδευση με ένα συγκεκριμένο δείγμα, ώστε το ίδιο μοντέλο να μπορεί να παραμείνει αποδοτικό σε οποιαδήποτε νέα δεδομένα. Η αρχή αυτή ονομάζεται Ελαχιστοποίηση του Δομικού Ρίσκου (Structural Risk Minimization).

4.2 ΒΑΣΙΚΑ ΣΤΟΙΧΕΙΑ ΜΔΥ

Στόχος μίας μηχανής διανυσμάτων υποστήριξης είναι η δημιουργία ενός «βέλτιστου» υπερεπιπέδου απόφασης, το οποίο μεγιστοποιεί το περιθώριο διαχωρισμού ρ . Θεωρητικά, σε πρώτο βαθμό υπολογίζονται τα βέλτιστα \mathbf{w}_o και b_o της εξίσωσης 4.2. Ο υπολογισμός τους περιλαμβάνει τη δήλωση του προβλήματος στον χώρο των βαρών και την μετέπειτα επίλυση του προβλήματος βελτιστοποίησης με χρήση πολλαπλασιαστών Lagrange. Στην επίλυση πρωταρχικό ρόλο λαμβάνουν τα διανύσματα υποστήριξης. Πρακτικά, όμως, ο υπολογισμός των \mathbf{w}_o και b_o δεν είναι απαραίτητος για την ταξινόμηση προτύπων, καθότι επαρκεί ο καθορισμός του πυρήνα εσωτερικών γινομένων. Ο ίδιος ο πυρήνας (kernel) είναι μία συνάρτηση η οποία υπολογίζει το εσωτερικό γινόμενο των εικόνων που παράγονται στον χώρο των βαρών βάσει δύο σημείων δεδομένων στον χώρο εισόδου. Παραδείγματα κατάλληλων πυρήνων είναι η πολυωνυμική συνάρτηση, το perceptron δύο επιπέδων, ένα δίκτυο RBF, κ.α.

Στην περίπτωση ταξινόμησης όπου τα πρότυπα εισόδου δεν είναι εφικτό να αντιστοιχηθούν στα πρότυπα εξόδου διότι δεν είναι γραμμικά διαχωρίσιμα, τότε είναι αναπόφευκτο να γίνουν λάθη και για αυτό η μηχανή επιδιώκει την ελαχιστοποίηση του σφάλματος ταξινόμησης. Τα μη διαχωρίσιμα σημεία αντιστοιχούν στις μεταβλητές χαλάρωσης (slack). Ο χρήστης της μηχανής μπορεί να επιλέξει την τιμή της παραμέτρου C για να καθορίσει πόσο σημαντικές είναι αυτές οι μεταβλητές στην εκπαίδευση. Για μικρές τιμές της C , το δείγμα εκπαίδευσης θεωρείται θορυβώδες και δίνεται μικρότερη έμφαση σε αυτό, ενώ για μεγάλες τιμές της C , το δείγμα εκπαίδευσης θεωρείται αξιόπιστο και κανένα σφάλμα δεν κρίνεται αμελητέο.

Όπως και στα προβλήματα ταξινόμησης, έτσι και στα προβλήματα παλινδρόμησης στόχος είναι η βελτιστοποίηση της επιφάνειας απόφασης για την ελαχιστοποίηση των σφαλμάτων. Σε αυτά τα προβλήματα η βελτιστοποίηση γίνεται με σκοπό την ευρωστία (robustness) του μοντέλου, δηλαδή την ικανότητά του να αντιστέκεται στις μικρές μεταβολές των παραμέτρων του λόγω θορύβου. Ένα σύστημα χαρακτηρίζεται εύρωστο όταν

ελαχιστοποιεί την μείωση της απόδοσής του λόγω του ε , που είναι η απόκλιση από το ονομαστικό μοντέλο θορύβου. Στα προβλήματα παλινδρόμησης, η εξάρτηση ενός βαθμωτού μεγέθους d από ένα παλινδρομητή x είναι η ακόλουθη:

$$d = \mathbf{w}^T \mathbf{x} + b \quad (4.3)$$

όπου \mathbf{w} και b είναι το διάνυσμα του βάρους και η πόλωση, αντίστοιχα. Η επίλυση του προβλήματος που προκύπτει από την εξίσωση (4.3) οδηγεί στην εξαγωγή πρόβλεψης για το μέγεθος d με ανάλογο τρόπο που προκύπτει η δημιουργία μίας επιφάνειας απόφασης για τις ΜΔΥ σε προβλήματα ταξινόμησης.

4.3 ΠΡΟΒΛΕΨΗ ΠΑΡΑΓΩΓΗΣ ΙΣΧΥΟΣ ΜΕΣΩ ΜΔΥ

Οι μηχανές διανυσμάτων υποστήριξης αποτελούν την πλέον αποδοτική επιβλεπόμενη μέθοδο πρόβλεψης παραγωγής ανανεώσιμων πηγών ενέργειας [6]. Αν και αρχικά χρησιμοποιήθηκαν για την πρόβλεψη αιολικής ισχύος, πλέον η χρήση τους επεκτείνεται και σε άλλες μορφές ενέργειας, συμπεριλαμβανομένης και της ηλιακής ενέργειας από φωτοβολταϊκά πάρκα.

Σε σύγκριση με την επικρατούσα μέθοδο των Τεχνητών Νευρωνικών Δικτύων, οι ΜΔΥ παρουσιάζουν πολλά προτερήματα. Όντας βασισμένες σε στατιστικές μεθόδους και ακολουθώντας την αρχή ελαχιστοποίησης του ρίσκου, μοντελοποιούν καλύτερα την συσχέτιση μεταξύ των μεταβλητών εισόδου και διαθέτουν την ικανότητα γενίκευσης της λύσης που παράγουν, αντιμετωπίζοντας έτσι το πρόβλημα υπερπροσαρμογής των ΤΝΔ στο εκάστοτε πρόβλημα. Από υπολογιστική σκοπιά, μία ΜΔΥ έχει μικρότερες απαιτήσεις υλικού καθώς χρειάζεται λιγότερους πυρήνες για τους υπολογισμούς της, δεν απαιτεί συνεχείς ενημερώσεις των παραμέτρων της και μπορεί να εξάγει πρόβλεψη με σχετικά μικρότερο δείγμα εκπαίδευσης [19]. Αντίθετα, η αδυναμία τους να μοντελοποιήσουν ικανοποιητικά τα απρόβλεπτα καιρικά φαινόμενα και το πολλαπλάσια αυξανόμενο υπολογιστικό κόστος τους όταν μεγαλώνει το δείγμα εκπαίδευσης αποτελούν τα μειονεκτήματά τους. Σε κάθε περίπτωση, όμως, η επιτυχής χρησιμοποίησή τους σε πληθώρα εφαρμογών οδηγεί στην σταδιακή άνοδο της χρήσης τους ως μεθόδους πρόβλεψης.

4.4 ΑΛΓΟΡΙΘΜΟΙ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ

Η επιτυχής εκπαίδευση μίας ΜΔΥ συμπεριλαμβάνει την σωστή επιλογή από τον χρήστη των παραμέτρων της, όπως είναι η συνάρτηση πυρήνα και η παράμετρος C . Λόγω των πολλών παραμέτρων και του μεγάλου εύρους επιλογών για καθεμία από αυτές, καθίσταται πολύ δύσκολη η εύρεση του ιδανικού συνδυασμού τους που θα οδηγήσει στην βέλτιστη δυνατή λύση του προβλήματος. Για την αντιμετώπιση αυτού του ζητήματος έχουν δημιουργηθεί οι Αλγόριθμοι Βελτιστοποίησης (Optimization Algorithms).

Ένας Αλγόριθμος Βελτιστοποίησης είναι μία μεταευσριστική μέθοδος, δηλαδή είναι μία υψηλού επιπέδου διαδικασία με σκοπό την εύρεση λύσης σε ένα πρόβλημα βελτιστοποίησης. Αν και είναι δύσκολο να εγνηθεί μία καθολικά βέλτιστη λύση, ένας τέτοιος αλγόριθμος είναι ιδιαίτερα βοηθητικός στην εύρεση (ή τουλάχιστον στην

προσέγγιση) των ιδανικών παραμέτρων ώστε να δημιουργηθεί μία αποδοτική ΜΔΥ. Συνήθως, τέτοιου είδους μεταεβριστικές μέθοδοι είναι εύχρηστες, αλλά απαιτούν μεγάλη υπολογιστική ισχύ, χωρίς αυτό να είναι απαραίτητο. Οι περισσότεροι Αλγόριθμοι Βελτιστοποίησης έχουν εμπνευστεί από την φύση, ενώ άλλοι βασίζονται στη θεωρία μαθηματικών για την σύγκλιση σε μία βέλτιστη λύση [20]

Ο Firefly Algorithm (FFA) αποτελεί έναν τέτοιο αλγόριθμο εμπνευσμένο από την φύση, και συγκεκριμένα από την συμπεριφορά των πυγολαμπίδων και την έλξη τους προς το φως. Παραλλάσσοντας τον ευρέως γνωστό αλγόριθμο PSO (Particle Swarm Optimization), ο FFA δοκιμάζει πολλές διαφορετικές πιθανές λύσεις του προβλήματος βελτιστοποίησης, προσομοιάζοντας καθεμία από αυτές με μία πυγολαμπίδα. Όσο καταλληλότερη ως λύση θεωρείται μία «πυγολαμπίδα», τόσο πιο λαμπρά «φωτίζει», με αποτέλεσμα, σε κάθε βήμα εκτέλεσης του αλγορίθμου, να προσελκύει λιγότερο «φωτεινές» πυγολαμπίδες. Σταδιακά, οι πυγολαμπίδες συσσωρεύονται σε ένα ή περισσότερα σημεία και τελικά μόνο μία επιλέγεται ως η φωτεινότερη. Αυτή η πυγολαμπίδα είναι και η προτεινόμενη λύση του προβλήματος από τον FFA.

Ο FFA, όπως και άλλοι παρεμφερείς αλγόριθμοι εμπνευσμένοι από την φύση, έχει αποδειχθεί αποδοτικός στα προβλήματα βελτιστοποίησης, χωρίς ωστόσο να λειτουργεί με συνέπεια σε διαφορετικά προβλήματα ή να γίνεται πλήρως κατανοητό πώς δουλεύει. Παρόλα αυτά, χρησιμοποιείται αρκετά συχνά για τον υπολογισμό των παραμέτρων κάποιας μηχανής πρόβλεψης, ιδιαίτερα των ΜΔΥ, διότι διαθέτουν παραμέτρους που μπορούν να λάβουν τιμές μέσα σε ένα εύρος πραγματικών αριθμών πολλών τάξεων μεγέθους. Αυτό τον καθιστά σημαντικό εργαλείο για την δημιουργία ενός καλού μοντέλου πρόβλεψης.

ΥΛΟΠΟΙΗΣΗ ΚΑΙ ΕΛΕΓΧΟΣ ΜΟΝΤΕΛΩΝ

5.1 ΓΕΝΙΚΑ

Σκοπός αυτής της διπλωματικής εργασίας είναι η βραχυπρόθεσμη πρόβλεψη της παραγωγής ισχύος με εφαρμογή σε δύο διαφορετικά φωτοβολταϊκά πάρκα με χρήση των δύο μεθόδων μηχανικής μάθησης: τα Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ) και τις Μηχανές Διανυσμάτων Υποστήριξης (ΜΔΥ). Ανά μέθοδο κατασκευάστηκαν τρία μοντέλα πρόβλεψης, δύο για το Φ/Β πάρκο «Λαμπρινή» και ένα για το Φ/Β πάρκο «Περδικούλα», των οποίων τα δείγματα εκπαίδευσης έχουν τις ίδιες περιβαλλοντικές μεταβλητές, όπως η ηλιακή ακτινοβολία ή η θερμοκρασία περιβάλλοντος. Τα μοντέλα έχουν αναπτυχθεί σε περιβάλλον που υποστηρίζει την προγραμματιστική γλώσσα Python και υλοποιούνται σε Η/Υ. Οι προβλέψεις των μοντέλων εξάγονται απευθείας σε φυλλομετρητές του Microsoft Excel για την αποθήκευση, απεικόνιση και σύγκρισή τους.

5.2 ΚΩΔΙΚΑΣ

5.2.1 Περιβάλλον Ανάπτυξης και Βιβλιοθήκες

Η συγγραφή του κώδικα έγινε στην πλατφόρμα Spyder, ένα περιβάλλον ανάπτυξης ανοιχτού κώδικα για την γλώσσα Python. Το Spyder εμπεριέχει πολλά από τα συνηθέστερα πακέτα της συγκεκριμένης γλώσσας προγραμματισμού και διαθέτει την ικανότητα προσθήκης και ενημέρωσης οποιασδήποτε ανοιχτής βιβλιοθήκης της. Ακόμα, επιτρέπει τον γρήγορο και αποδοτικό έλεγχο του κώδικα επισημαίνοντας συντακτικά λάθη, προτείνοντας προσθήκες και συμπληρώσεις και δίνοντας άμεση πρόσβαση στα εγχειρίδια των βιβλιοθηκών και συναρτήσεων που χρησιμοποιούνται. Τέλος, δίνει στον χρήστη την δυνατότητα να βλέπει και να τροποποιεί τις μεταβλητές ενός προγράμματος ενώ εκτελείται, απλοποιώντας και διευκολύνοντας τον έλεγχο της λειτουργίας του.

Στην συγγραφή του κώδικα χρησιμοποιήθηκαν, πέρα από τις απαραίτητες βιβλιοθήκες για τις αλγεβρικές εξισώσεις, τις μετατροπές δεδομένων και τις κλήσεις συστήματος, οι ακόλουθες:

- *pandas*: Η βιβλιοθήκη *pandas* επιτρέπει στο πρόγραμμα την ανάγνωση αρχείων Excel και, αντίστροφα, την δημιουργία νέων ή συμπλήρωση παλαιών τέτοιων αρχείων. Επιπλέον, δίνει την δυνατότητα οργάνωσης των δεδομένων σε *dataframes*, δηλαδή πίνακες όπου κάθε στήλη αντιστοιχεί σε μία μεταβλητή ή ένα χαρακτηριστικό και κάθε σειρά έχει αύξοντα αριθμό. Τα *dataframes* διευκόλυναν την μελέτη των δεδομένων και τους χειρισμούς εντός του κώδικα και ανά χαρακτηριστικό και ανά χρονικό βήμα.

- *sklearn*: Η βιβλιοθήκη *sklearn* εμπεριέχει πολλές συναρτήσεις για την ανάλυση δεδομένων, τον υπολογισμό λαθών και άλλα μετρικά, τον διαχωρισμό των δειγμάτων εκπαίδευσης και ελέγχου, κ.α. Ακόμα, διαθέτει όλες τις απαραίτητες συναρτήσεις για την υλοποίηση Παλινδρόμησης Διανουσμάτων Υποστήριξης (Support Vector Regression ή SVR).
- *tensorflow.keras*: Η βιβλιοθήκη *tensorflow.keras* δίνει πρόσβαση στην δημιουργία και επεξεργασία μοντέλων ΤΝΔ.

5.2.2 Προεπεξεργασία Δεδομένων

Τα διαθέσιμα δεδομένα από τα Φ/Β πάρκα δίνονται σε μορφή Excel Worksheet, όπου κάθε στήλη αντιστοιχεί στις ενδείξεις ενός αισθητήρα ή ενός μετρητή (η πρώτη στήλη είναι πάντα η ενιαία μεταβλητή χρονοσήμανσης (timestamp) που εμπεριέχει ημερομηνία και ώρα) και κάθε σειρά στο εκάστοτε χρονικό βήμα (1 λεπτό για την Λαμπρινή και 15 λεπτά για την Περδικούλα). Τα δεδομένα αυτά δεν είναι δυνατόν να αξιοποιηθούν απευθείας όπως δίνονται και επομένως περνούν μέσα από πολλά στάδια επεξεργασίας.

Αρχικά, οι στήλες δεδομένων, από τις οποίες θα δημιουργηθούν τα δείγματα εκπαίδευσης και ελέγχου, απομονώνονται σε αρχείο Τιμών Διαχωρισμένων με Κόμματα (.csv). Σε αυτό το αρχείο είναι απαραίτητη η ύπαρξη τουλάχιστον τριών στηλών, αυτών της χρονοσήμανσης, της παρατηρούμενης ενεργού ισχύος και άλλης μίας μεταβλητής. Η χρονοσήμανση απαιτείται και ως είσοδος σε κάθε μηχανή αλλά και ως βοηθητικός παράγοντας μέσα στο πρόγραμμα, καθώς διευκολύνει την οργάνωση, τον διαχωρισμό και αντιστοίχιση των δεδομένων. Η παρατηρούμενη ενεργός ισχύς χρησιμοποιείται πρώτα στην επίβλεψη της εκπαίδευσης της μηχανής, καθώς η μηχανή «μαθαίνει» την επιθυμητή απόκρισή της στα δεδομένα εισόδου, και έπειτα στον έλεγχο της εκπαιδευμένης μηχανής και τον υπολογισμό των σφαλμάτων-αποκλίσεων της. Οι υπόλοιπες μεταβλητές συγκαταλέγονται στα δεδομένα εισόδου και είναι επιλεγμένες με τέτοιο τρόπο ώστε να συνεισφέρουν στην δημιουργία μίας αποδοτικότερης μηχανής χωρίς μεγάλη επιβάρυνση στην πολυπλοκότητά της λόγω του όγκου των δεδομένων.

Στην συνέχεια, το αρχείο τιμών εισάγεται στο πρόγραμμα ως το dataframe X, όπου αρχίζει η επεξεργασία του εντός της εφαρμογής. Σε πρώτο βήμα, τα δεδομένα εξετάζονται για τυχόν κενά ή ελαττωματικές τιμές που μπορούν να οφείλονται σε ημέρες συντήρησης του Φ/Β πάρκου ή σφάλματα των αισθητήρων και μπορούν να διακινδυνεύσουν την ομαλή λειτουργία της μηχανής. Εάν τα σφάλματα είναι σύντομης χρονικής διάρκειας, μέχρι και δύο ωρών, τότε αντικαθίστανται με την τελευταία έγκυρη τιμή που έλαβαν, αλλιώς διαγράφονται από τον πίνακα-dataframe. Αφού αφαιρεθούν οι σειρές που περιέχουν αυτά τα δεδομένα, αφαιρούνται και όλες όσες αντιστοιχούν σε στιγμές πριν τις 6:45 ή μετά τις 21:00, προκειμένου οι ενδείξεις κατά την διάρκεια ωρών χωρίς ηλιοφάνεια να μην επηρεάσουν την εκπαίδευση των μοντέλων. Ο πίνακας X πλέον περιέχει μόνο έγκυρα δεδομένα.

Μετά την απομάκρυνση των ανεπιθύμητων τιμών, ακολουθεί η τελική προετοιμασία των δεδομένων. Ο χρήστης εισάγει δύο παραμέτρους: μία λίστα χρονοσημάνσεων με βάση τις οποίες θα οριστεί το δείγμα ελέγχου και το εύρος ημερών εκπαίδευσης, οι οποίες συνδυαστικά ορίζουν τις χρονικές στιγμές έναρξης και λήξης της εκπαίδευσης και την έναρξη του ελέγχου. Από τον πίνακα X αφαιρούνται τα δεδομένα που αναφέρονται σε ημέρες που δεν ανήκουν σε κανένα από τα δύο δείγματα, τα υπόλοιπα δεδομένα κανονικοποιούνται ανά

στήλη στο εύρος $[0,1]$, διαδικασία απαραίτητη για να λειτουργήσουν τόσο τα Νευρωνικά Δίκτυα όσο και οι Μηχανές Διανυσμάτων, και τέλος, τα δεδομένα χωρίζονται στα δείγματα εκπαίδευσης και ελέγχου (training and testing) και σε δεδομένα εισόδου και εξόδου του μοντέλου (X και Y , αντίστοιχα). Τελικά προκύπτουν τέσσερις πίνακες (X_{train} , X_{test} , Y_{train} , Y_{test}) δεδομένων, οι οποίοι είναι έτοιμοι για τροφοδότηση σε καθένα από τα μοντέλα.

5.2.3 Εκπαίδευση μοντέλων

Διαθέτοντας τα τέσσερα δείγματα κανονικοποιημένα γίνεται εφικτή η εκπαίδευση των μοντέλων. Παρότι πρόκειται για δύο διαφορετικές μεθοδολογίες, στα πλαίσια του κώδικα ακολουθούνται τα ίδια βήματα σε κάθε περίπτωση, προκειμένου να εξαχθεί η επιθυμητή πρόβλεψη. Το πρώτο βήμα περιλαμβάνει την δημιουργία της μηχανής πρόβλεψης και τον προσδιορισμό από τον χρήστη των υπερπαραμέτρων της:

- Στην περίπτωση των Τεχνητών Νευρωνικών Δικτύων δημιουργείται ένα απλό δίκτυο εμπρόσθιας τροφοδότησης με την συνάρτηση *tensorflow.keras.Sequential*. Ο χρήστης επιλέγει:
 - τον αριθμό των κρυφών επιπέδων (*hl1*, *hl2*, κοκ.).
 - την συνάρτηση ενεργοποίησης κάθε κρυφού επιπέδου και του επιπέδου εξόδου (*activation_function*).
 - τον αριθμό των εξόδων του μοντέλου, οι οποίες είναι ίσες με τον αριθμό των επιθυμητών προβλέψεων (*prediction_number*).
 - την συνάρτηση υπολογισμού του σφάλματος πρόβλεψης του μοντέλου (*loss_function*), με βάση την οποία το μοντέλο προσπαθεί να ελαχιστοποιήσει το σφάλμα κατά την εκπαίδευσή του.
 - τον optimizer του δικτύου. Ο *optimizer* αναλαμβάνει την αλλαγή των παραμέτρων (πχ. βάρη, καμπύλη μάθησης) ενός ΤΝΔ κατά την διάρκεια της εκπαίδευσης με στόχο την μείωση του σφάλματος πρόβλεψης του μοντέλου.
 - τον αριθμό των εποχών εκπαίδευσης (*epochs*).
 - το δείγμα εκπαίδευσης για την είσοδο (X_{train}) και την έξοδο (Y_{train}).
- Στην περίπτωση των Μηχανών Διανυσμάτων Υποστήριξης δημιουργείται μια απλή μηχανή με την συνάρτηση *sklearn.svm.SVR*. Ο χρήστης επιλέγει:
 - τον αριθμό των εξόδων του μοντέλου, οι οποίες είναι ίσες με τον αριθμό των επιθυμητών προβλέψεων (*prediction_number*).
 - τον πυρήνα υπολογισμών της μηχανής (*kernel*).
 - την τιμή της υπερπαραμέτρου C .
 - την τιμή της υπερπαραμέτρου γ (*gamma*). Το γ προσδιορίζει πόσο μακριά φτάνει η επιρροή ενός παραδείγματος εκπαίδευσης. Υψηλές τιμές του γ οδηγούν στη δημιουργία υπερεπιπέδου απόφασης με μεγάλη καμπυλότητα, ενώ μικρές τιμές του οδηγούν στη δημιουργία πιο ευθύγραμμων υπερεπιπέδων.
 - το δείγμα εκπαίδευσης για την είσοδο (X_{train}) και την έξοδο (Y_{train}).

Στο τέλος κάθε εκπαίδευσης υπολογίζεται το σχετικό σφάλμα της. Έχοντας το δείγμα εκπαίδευσης ως είσοδο, το μοντέλο εξάγει 15 προβλέψεις για την τιμή της παρατηρούμενης

ενεργού ισχύος, καθεμία με απόσταση 15 λεπτών από την προηγούμενη, και έπειτα υπολογίζει το σφάλμα $MAPE$ των προβλέψεων σύμφωνα με την ακόλουθη σχέση:

$$MAPE = \frac{100\%}{15} \times \sum_{i=1}^{15} \left| \frac{Y_i - \hat{Y}_i}{P} \right| \quad (5.1)$$

όπου ο αριθμός 15 αντιστοιχεί στον αριθμό των προβλέψεων, Y_i η πραγματική τιμή της ισχύος για την πρόβλεψη i , \hat{Y}_i η τιμή της προβλεπόμενης ισχύος και P η ονομαστική τιμή της ενεργού ισχύος για το Φ/Β πάρκο. Η Εξίσωση (5.1) για τον υπολογισμό του $MAPE$ είναι μία παραλλαγή της Εξίσωσης (3.2) του Κεφαλαίου 3, όπου αντικαθίσταται ο μεταβλητός παρονομαστής Y_i με την τιμή P . Ο στόχος της αλλαγής αυτής είναι η έκφραση του σφάλματος σε σχέση με μία σταθερή υψηλή τιμή, ώστε οι μεγάλες αποκλίσεις της πρόβλεψης από την πραγματική τιμή, κυρίως τις μεσημβρινές ώρες, να έχουν μεγαλύτερη σημασία από τις μικρές αποκλίσεις κατά την αυγή ή την δύση, όπου τα Φ/Β έχουν ελάχιστη παραγωγή.

5.2.4 Έλεγχος μοντέλων και σφάλματα

Με την ολοκλήρωση της εκπαίδευσης, οριστικοποιούνται οι τιμές των παραμέτρων και τα μοντέλα είναι έτοιμα να δοκιμαστούν με τα σύνολα ελέγχου (test sets). Τα δεδομένα που εμπεριέχονται στο δείγμα ελέγχου αναφέρονται σε χρονικές στιγμές που έπονται αυτές του δείγματος εκπαίδευσης, και ως συνέπεια είναι ξένα προς κάθε εκπαιδευμένη μηχανή. Επομένως, τα σύνολα ελέγχου έχουν ως σκοπό την αξιολόγηση των μηχανών που προκύπτουν από την εκπαίδευση ως προς την ικανότητά τους να αποκρίνονται επιτυχώς σε νέα, άγνωστα δεδομένα.

Κάθε σύνολο ελέγχου αποτελείται από πολλές υποθέσεις ελέγχου (test cases), οι οποίες εξετάζουν την απόκριση ενός εκπαιδευμένου μοντέλου σε ένα εύρος 225 λεπτών μίας ημέρας λειτουργίας ενός Φ/Β πάρκου. Συγκεκριμένα σε κάθε υπόθεση, τα δεδομένα των τελευταίων 225 λεπτών πριν την ορισμένη στιγμή της πρόβλεψης εισάγονται στην μηχανή με σκοπό την πρόβλεψη της τιμής της παραγόμενης ισχύος για τα επόμενα 15 δεκαπεντάλεπτα. Το σφάλμα κάθε υπόθεσης ελέγχου $MAPE_{test}$ υπολογίζεται όπως και το $MAPE_{train}$ και το μέσο σφάλμα όλων των υποθέσεων ελέγχου ονομάζεται $MMAPE_{test}$ (Mean $MAPE_{test}$). Το $MAPE_{test}$ είναι κατά κανόνα μεγαλύτερο από το $MAPE_{train}$, καθότι αναφέρεται στην απόκριση της μηχανής σε άγνωστα δεδομένα, αλλά ιδανικά το προσεγγίζει. Εάν η διαφορά των δύο σφαλμάτων είναι μικρή, τότε το μοντέλο θεωρείται ότι γενικεύει καλά, ενώ αν είναι μεγάλη, αυτό σημαίνει ότι το μοντέλο έχει υπερπροσαρμοστεί στο δείγμα εκπαίδευσης.

Μετά τον υπολογισμό των σφαλμάτων, οι τιμές των προβλέψεων αποκανονικοποιούνται και αποθηκεύονται σε αρχείο Excel, μαζί με οποιαδήποτε στοιχεία θεωρούνται σημαντικά για την συγκεκριμένη εκτέλεση του κώδικα (πχ. ημερομηνία εκτέλεσης, ιδιαίτεροι παράμετροι εκτέλεσης, σχόλια, κτλ.). Τα αρχεία αυτά οργανώνονται σε φακέλους ανάλογα με τις παραμέτρους εκτέλεσης του κάθε μοντέλου και συγκρίνονται μεταξύ τους.

5.3 ΥΛΟΠΟΙΗΣΗ ΜΟΝΤΕΛΩΝ ΠΡΟΒΛΕΨΗΣ

5.3.1 Σύνολα Ελέγχου

Για κάθε διαφορετική μέθοδο πρόβλεψης, ΤΝΔ και ΜΔΥ, δημιουργήθηκαν τρία διαφορετικά μοντέλα πρόβλεψης ισχύος. Το πρώτο μοντέλο χρησιμοποιεί, κατά τη διάρκεια της εκπαίδευσής του, δεδομένα ανά λεπτό από το πάρκο της Λαμπρινής για το έτος 2020, ενώ το δεύτερο μοντέλο διαθέτει δεδομένα από το ίδιο πάρκο δειγματοληπτημένα ανά τέταρτο της ώρας. Το τρίτο μοντέλο αξιοποιεί τα δεδομένα ανά τέταρτο της ώρας από το πάρκο της Περδικούλας για το έτος 2019. Και τα τρία μοντέλα επεξεργάζονται τα δεδομένα τους πριν την εκπαίδευση με τον ίδιο τρόπο, όπως παρουσιάζεται στην Ενότητα 5.2.2.

Τα εκπαιδευμένα μοντέλα δοκιμάζονται σε πέντε διαφορετικά σύνολα υποθέσεων ελέγχου, τα οποία αναφέρονται σε δεδομένα άγνωστα για κάθε μοντέλο, τοποθετημένα στο 2021 και στο 2020 για το μοντέλα της Λαμπρινής και της Περδικούλας, αντίστοιχα. Οι υποθέσεις αυτές μπορούν να κατηγοριοποιηθούν σε τέσσερις διαφορετικές κλάσεις ανάλογα με τις καιρικές συνθήκες που επικρατούσαν σε κάθε πάρκο την ημέρα της υπόθεσης:

- **Ημέρες με Λιακάδα (Λ):** τις ημέρες αυτές η καμπύλη της παραγόμενης ισχύος ακολουθεί την κανονική κατανομή, φτάνοντας το μέγιστό της κατά τις μεσημβρινές ώρες. Οι πρώτες ώρες μετά την αυγή και οι τελευταίες πριν το ηλιοβασίλεμα σημειώνουν ελάχιστη παραγωγή ισχύος. Αποτελούν το 27% των ημερών του 2021 στην Λαμπρινή και το 42% του 2020 στην Περδικούλα.
- **Ημέρες με Σποραδική Συννεφιά (Σ):** σε αυτές τις ημέρες η καμπύλη της παραγόμενης ισχύος ακολουθεί, κατά βάση, την κανονική κατανομή, με μικρές διακυμάνσεις που διαρκούν λιγότερο από δύο ώρες. Αποτελούν το 25% των ημερών του 2021 στην Λαμπρινή και το 23% του 2020 στην Περδικούλα.
- **Ημέρες με Μέτρια Συννεφιά (Μ):** όπως ισχύει με τις ημέρες Σ, με την διαφορά ότι οι διακυμάνσεις τους διαρκούν συνήθως περισσότερο χρόνο και τοποθετούνται συστηματικά κατά τις ώρες αιχμής. Αποτελούν το 35% των ημερών του 2021 στην Λαμπρινή και το 28% του 2020 στην Περδικούλα.
- **Ημέρες με Βαριά Συννεφιά (Β):** τις ημέρες αυτές η ισχύς δεν πλησιάζει ποτέ την ονομαστική της τιμή ή είναι διαρκώς χαμηλή, λόγω της απουσίας ηλιοφάνειας. Αποτελούν το 9% των ημερών του 2021 στην Λαμπρινή και το 7% του 2020 στην Περδικούλα.

Ένα μοντέλο πρόβλεψης ισχύος πρέπει να μπορεί να ανταπεξέρχεται στις οποιοσδήποτε περιβαλλοντικές συνθήκες επικρατούν την κάθε χρονική στιγμή και να μπορεί να λειτουργεί με μικρά σφάλματα τόσο σε συνθήκες ηλιοφάνειας όσο και σε έντονη συννεφιά. Για ένα μοντέλο μάθησης, η πρόβλεψη της κατανομής ισχύος για τις ημέρες Λ είναι πολύ ευκολότερη από την πρόβλεψη για τις ημέρες με συννεφιά, όπου πρέπει να συνυπολογιστεί

και η επίδραση των σύννεφων στην παραγωγή ισχύος του Φ/Β. Αντίθετα, δεδομένης της ήδη αμελητέας παραγωγής ισχύος τις ημέρες Β, οι κρισιμότερες ημέρες για την επίδοση ενός μοντέλου είναι οι ημέρες Σ και Μ, στις οποίες δίνεται έμφαση στα σύνολα υποθέσεων ελέγχου. Επομένως, για κάθε πάρκο έχουν φτιαχτεί τα ακόλουθα σύνολα:

- **Γενικό σύνολο:** Αποτελείται από 36 διαφορετικές υποθέσεις ελέγχου κατανεμημένες μέσα σε ένα έτος, από τις οποίες 8 αναφέρονται σε ημέρες με

Λιακάδα (Λ), 12 σε ημέρες με Σποραδική Συννεφιά (Σ), 12 σε ημέρες με Μέτρια Συννεφιά (Μ) και οι υπόλοιπες 4 σε ημέρες με Βαριά Συννεφιά (Β). Οι περισσότερες υποθέσεις αναφέρονται στην πρόβλεψη ισχύος κατά τις ώρες αιχμής, ενώ λιγότερες αναφέρονται σε πρωινές και απογευματινές ώρες.

- Εποχιακά σύνολα: Τα σύνολα αυτά είναι ένα για κάθε εποχή και περιλαμβάνουν 20 υποθέσεις, 5 για κάθε κατηγορία καιρικών συνθηκών, και αναφέρονται σε μεσημβρινές ώρες. Εξαιρέση αποτελούν τα σύνολα καλοκαιριού, καθώς ούτε στην Λαμπρινή ούτε στην Περδικούλα σημειώθηκαν ημέρες με Βαριά Συννεφιά τα καλοκαίρια του 2021 και του 2020, αντίστοιχα.

5.3.2 Απλά Μοντέλα Πρόβλεψης

Αφού ολοκληρωθούν η εκπαίδευση και ο έλεγχος ενός μοντέλου, υπολογίζονται το σφάλμα εκπαίδευσης $MAPE_{train}$, το σφάλμα ελέγχου $MAPE_{test}$ κάθε υπόθεσης ελέγχου του συνόλου που επιλέχθηκε και το μέσο σφάλμα ελέγχου όλων των υποθέσεων $MMAPE_{test}$. Οι τιμές των σφαλμάτων αυτών είναι ενδεικτικές της απόδοσης του μοντέλου και σκοπός της εκπαίδευσής του είναι η ελαχιστοποίησή τους. Τα σφάλματα είναι πολύ ευαίσθητα στις τιμές των υπερπαραμέτρων κατά τη δημιουργία ενός μοντέλου, γεγονός που καθιστά πολύ σημαντική την επιλογή τους.

Κατά την κατασκευή των μοντέλων πρόβλεψης, όλες οι υπερπαραμέτροι λαμβάνουν τις τυπικές τιμές τους, οι οποίες δεν είναι απαραίτητα οι καταλληλότερες για τη δημιουργία ενός αποδοτικού μοντέλου. Το πρώτο βήμα για την βελτίωση του μοντέλου περιλαμβάνει τον πειραματισμό με τις τιμές που μπορεί να λάβει κάθε μία από τις μεταβλητές που αναφέρονται στην Ενότητα 5.2.3 και την εύρεση του συνδυασμού τους που ελαχιστοποιεί τα σφάλματα εκπαίδευσης και ελέγχου. Ορισμένες από αυτές τις δοκιμές παρουσιάζονται στην Ενότητα 5.3.5. Αυτή η ρύθμιση των μεταβλητών οδήγησε στην δημιουργία μοντέλων με τις ακόλουθες υπερπαραμέτρους:

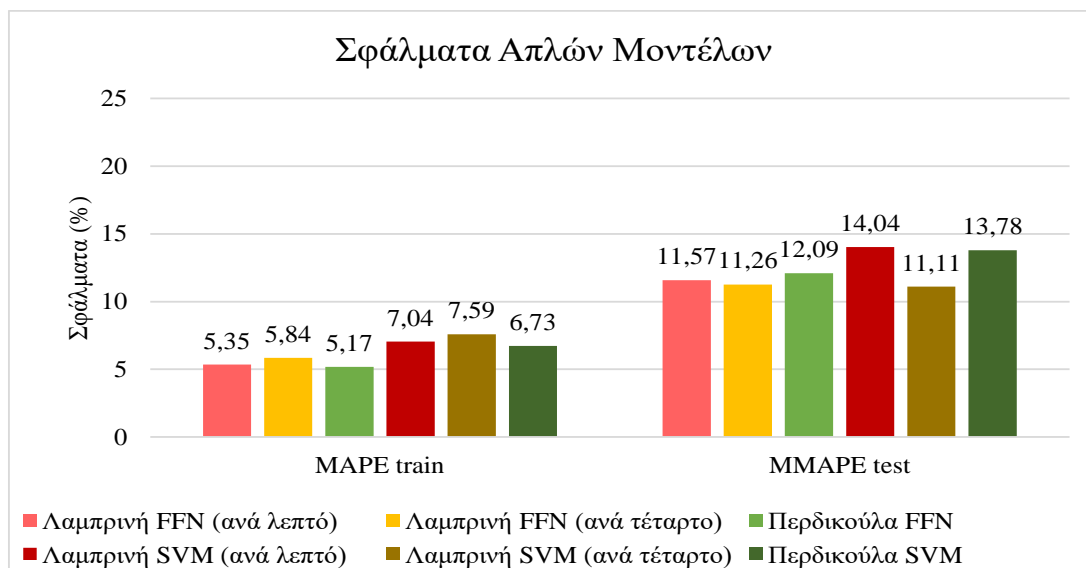
- Για τα μοντέλα ΤΝΔ:
 - δύο κρυφά επίπεδα $hl1$ και $hl2$ με 10 νευρώνες το καθένα.
 - συνάρτηση ενεργοποίησης κάθε κρυφού επιπέδου την εκθετική (exponential).
 - συνάρτηση ενεργοποίησης του επιπέδου εξόδου την απλή σιγμοειδή (sigmoid).
 - δεκαπέντε έξοδοι, όσες και οι τιμές πρόβλεψης.
 - συνάρτηση υπολογισμού του σφάλματος πρόβλεψης του μοντέλου $MAPE$ της Εξίσωσης (5.1).
 - optimizer τον *Nadam*.
 - 100 εποχές εκπαίδευσης για το μοντέλο Λαμπρινής με δεδομένα ανά λεπτό και 200 εποχές για τα υπόλοιπα μοντέλα.
- Για τα μοντέλα ΜΔΥ:
 - δεκαπέντε έξοδοι, όσες και οι τιμές πρόβλεψης.
 - πυρήνα υπολογισμών τον *radial basis function (RBF)*.
 - υπερπαραμέτρο C ίση με 100.
 - υπερπαραμέτρο γ ίση με 1.

Εκτός από την ρύθμιση των υπερπαραμέτρων, είναι απαραίτητη η επιλογή του σωστού δείγματος εισόδου. Τα διαθέσιμα δεδομένα δύο ετών από τους αισθητήρες και μετρητές των δύο πάρκων προσφέρουν τη δυνατότητα αξιοποίησης πολλών διαφορετικών μεταβλητών ως μεταβλητών εισόδου των μοντέλων. Όμως, πολλές μεταβλητές σε ένα μεγάλο δείγμα εισόδου οδηγούν σε αύξηση της πολυπλοκότητας μιας μηχανής πρόβλεψης, με τις ανάλογες επιπτώσεις στον χρόνο και την ακρίβεια εκτέλεσης της. Η χρήση μεταβλητών που δεν σχετίζονται με το φωτοβολταϊκό φαινόμενο και την μεταβολή των καιρικών συνθηκών επιβάλλει περιττή πληροφορία στο μοντέλο και μπορεί να οδηγήσει σε μεγαλύτερα σφάλματα. Αντίστοιχα, η συμπερίληψη μεγάλου εύρους ημερών στην εκπαίδευση πολλαπλασιάζει τον χρόνο εκτέλεσης του μοντέλου και μεγαλώνει τον κίνδυνο υπερπροσαρμογής του στο δείγμα εκπαίδευσης.

Αναμφίβολα, η πυκνότητα της ηλιακής ακτινοβολίας και η χρονοσήμανση αποτελούν τις κυριότερες μεταβλητές που επηρεάζουν την παραγόμενη ισχύ των Φ/Β, και οι δύο αυτές μεταβλητές είναι επαρκείς για εξαγωγή ικανοποιητικής πρόβλεψης. Η προσθήκη των ακόλουθων μεταβλητών στο δείγμα εκπαίδευσης, ωστόσο, αποδείχθηκε ωφέλιμη για την μείωση του σφάλματος πρόβλεψης, χωρίς ιδιαίτερη επιβάρυνση στον χρόνο εκτέλεσης:

- Για το πάρκο «Λαμπρινή»:
 - Θερμοκρασία περιβάλλοντος σε $^{\circ}\text{C}$ (ambient Temperature).
 - Θερμοκρασία Φ/Β μονάδας σε $^{\circ}\text{C}$ στο σημείο του μετεωρολογικού σταθμού (module Temperature).
- Για το πάρκο «Περδικούλα»:
 - Θερμοκρασία περιβάλλοντος σε $^{\circ}\text{C}$ (ambient Temperature).
 - Ποσοστιαία Σχετική Υγρασία (relative Humidity).
 - Θερμοκρασία Φ/Β μονάδας σε $^{\circ}\text{C}$ (module Temperature) και ολική Πυκνότητα της Ηλιακής Ακτινοβολίας σε W/m^2 (Irradiance) από 4 διαφορετικά σημεία του πάρκου.

Με την επιλογή των άνωθεν υπερπαραμέτρων και δειγμάτων εκπαίδευσης και ελέγχου δημιουργήθηκαν τα απλά μοντέλα πρόβλεψης. Στο Σχήμα 5.1 παρουσιάζονται τα σφάλματα εκπαίδευσης και ελέγχου για τα απλά μοντέλα πρόβλεψης, δοκιμασμένα στο γενικό σύνολο ελέγχου.



Σχήμα 5.1 : MAPE Απλών Μοντέλων πρόβλεψης

5.3.3 Μοντέλα πρόβλεψης με κυκλικούς χρόνους


Απαραίτητη μεταβλητή εισόδου σε κάθε μοντέλο είναι η χρονοσήμανση (Timestamp), δηλαδή η πληροφορία της χρονικής στιγμής που αντιστοιχεί κάθε σειρά δεδομένων εισόδου. Πριν την έναρξη μίας εκπαίδευσης, η χρονοσήμανση χωρίζεται στις δύο βασικές μεταβλητές που την αποτελούν: την μεταβλητή Ημερομηνίας d (Date) και την μεταβλητή ώρας t (Time). Αυτές οι δύο μεταβλητές έχουν την μορφή ευθείας γραμμής: η d λαμβάνει ακέραιες τιμές από το 1 (1^η Ιανουαρίου) έως το 365 ή το 366 (για τα δίσεκτα έτη) και η t από το 1 (00:00) έως το 1440 (23:59 για τα μοντέλα με δεδομένα ανά λεπτό) ή το 96 (23:45 για τα μοντέλα με δεδομένα ανά τέταρτο).

Η συμπερίληψη των δύο μεταβλητών στο δείγμα εκπαίδευσης είναι απαραίτητη για να την δημιουργία συνδέσεων μεταξύ εποχών και καιρικών συνθηκών (για την d) και ώρας και θέσης του ήλιου (για την t) από ένα μοντέλο. Αν και πράγματι τα μοντέλα επιτυγχάνουν στην δημιουργία συσχέτισης μεταξύ χρόνου και παραγωγής ισχύος, δεν μοντελοποιούν εύκολα την περιοδικότητα των περιβαλλοντικών φαινομένων. Αυτή η κυκλικότητα μπορεί να αναπαρασταθεί με τις απλούστερες κυκλικές συναρτήσεις, τις ημιτονικές, μετατρέποντας τις μεταβλητές d και t από ευθείες σε συνημίτονα [21]. Οι τριγωνομετρικές μεταβλητές d_{trig} και t_{trig} ορίζονται ως εξής:

$$d_{trig} = \cos 2\pi \left(\frac{d - d_{ss}}{D} \right) \quad (5.2)$$

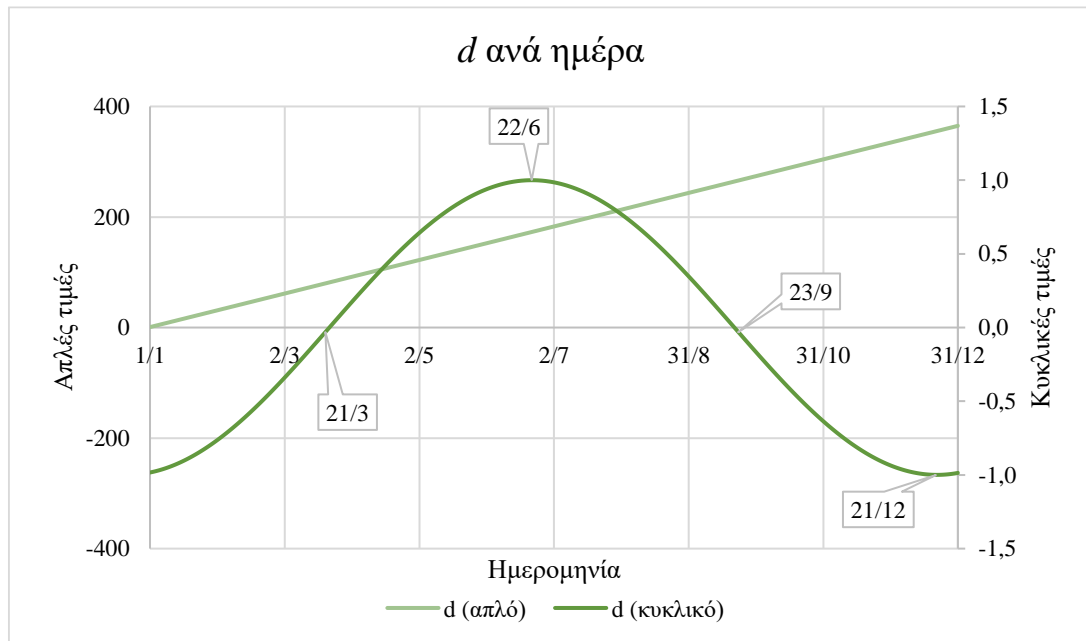
$$t_{trig} = \cos 2\pi \left(\frac{t - t_{peak}}{T} \right) \quad (5.3)$$

όπου d_{ss} είναι η Ημερομηνία d του θερινού ηλιοστασίου ($d_{ss} = 173$ για τα δίσεκτα έτη), D ο αριθμός των ημερών ενός έτους ($D = 366$ για τα δίσεκτα έτη), t_{peak} η ώρα που αναμένεται η μέγιστη παραγόμενη ισχύς (για ευκολία ορίστηκαν οι 14:00, με $t = 841$ σε λεπτά ή $t = 57$ σε τέταρτα της ώρας) και T ο αριθμός λεπτών ($T = 1440$) ή τέταρτων ($T = 96$) της ημέρας. Προσθέτοντας τις μεταβλητές d_{trig} και t_{trig} στις εισόδους των μοντέλων, δημιουργούνται τα Μοντέλα με Κυκλικούς Χρόνους, των οποίων τα σφάλματα φαίνονται στο Σχήμα 5.2.




Σχήμα 5.2 : MAPE Μοντέλων πρόβλεψης με κυκλικούς χρόνους

Στα Σχήματα 5.3α και 5.3β φαίνονται η απλή και η κυκλική εκδοχή των μεταβλητών d και t . Οι απλές εκδοχές είναι ευθείες γραμμές από τον αριθμό 1 έως το μέγιστο κάθε μεταβλητής, ενώ οι κυκλικές έχουν μορφή συνημίτονου. Στην περίπτωση της μεταβλητής d το μέγιστο αντιστοιχεί στις 21/6 (θερινό ηλιοστάσιο) για τα δίσεκτα έτη και στις 22/6 για τα υπόλοιπα έτη, όπως στο σχήμα, το ελάχιστο περίπου στις 21/12 (χειμερινό ηλιοστάσιο) και οι μηδενισμοί περίπου στις 21/3 και 23/9 (εαρινή και φθινοπωρινή ισημερία, αντίστοιχα). Στην περίπτωση της μεταβλητής t το μέγιστο αντιστοιχεί στις 14:00, το ελάχιστο στις 2:00 (εκτός σχήματος) και οι μηδενισμοί στις 8:00 και στις 20:00. Η καμπύλη του κυκλικού t ομοιάζει στην παραγωγή ισχύος μίας τυπικής ημέρας Λ .



Σχήμα 5.3α : Οι δύο εκδοχές της μεταβλητής d σε ένα μη δίσεκτο έτος



Σχήμα 5.3β : Οι δύο εκδοχές της μεταβλητής t μεταξύ 7 π.μ. και 9 μ.μ.


5.3.4 Βελτιστοποίηση μοντέλων ΜΔΥ με Αλγόριθμους Βελτιστοποίησης

Οι υπερπαραμέτροι των μοντέλων ΜΔΥ, σε αντίθεση με τις υπερπαραμέτρους των μοντέλων ΤΝΔ, έχουν τις τυπικές τιμές τους, οι οποίες δεν είναι ιδανικές για τα συγκεκριμένα μοντέλα. Αξιοποιώντας τον αλγόριθμο FFA που παρουσιάστηκε στο Κεφάλαιο 4, τα μοντέλα ΜΔΥ βελτιστοποιήθηκαν ως προς την ελαχιστοποίηση του σφάλματος $MAPE_{test}$. Στον Πίνακα 5.1 φαίνονται οι τιμές των υπερπαραμέτρων C και γ για τα βέλτιστα μοντέλα.


Πίνακας 5.1: Τιμές υπερπαραμέτρων ανά μοντέλο ΜΔΥ

	<i>Μοντέλο</i>	<i>C</i>	<i>γ</i>
<i>Μη βέλτιστα</i>	Όλα	100	1,0
<i>Απλά</i>	Λαμπρινή ανά λεπτό	0,4	0,1
	Λαμπρινή ανά τέταρτο	0,1	5,0
	Περδικούλα	0,6	0,3
<i>Με κυκλικούς χρόνους</i>	Λαμπρινή ανά λεπτό	2,0	0,2
	Λαμπρινή ανά τέταρτο	1,0	1,0
	Περδικούλα	0,6	0,6

Με τις τιμές των παραμέτρων του Πίνακα 5.1, βελτιώνονται οι σημαντικές ανακρίβειες που παρουσιάζοντουσαν σε ορισμένα σενάρια, βελτιώνοντας την συνολική εικόνα της εκπαίδευσης, όπως φαίνεται στα Σχήματα 5.4α και 5.4β.



Σχήμα 5.4α : MAPE Βέλτιστων Απλών Μοντέλων πρόβλεψης



Σχήμα 5.4β : MAPE Βέλτιστων Μοντέλων πρόβλεψης με κυκλικούς χρόνους

5.3.5 Βελτιστοποίηση μοντέλων ΤΝΔ

Στην Ενότητα 5.3.2 παρουσιάστηκαν τα βέλτιστα μοντέλα ΤΝΔ, για τα οποία έχουν επιλεγθεί συγκεκριμένες υπερπαραμέτροι. Σε αυτήν την ενότητα παρουσιάζονται τα κριτήρια επιλογής ορισμένων από αυτές τις υπερπαραμέτρους.

Τα τελικά μοντέλα ΤΝΔ αποτελούνται από δύο κρυφά επίπεδα νευρώνων, που είναι ο τυπικός αριθμός κρυφών επιπέδων και πράγματι αποδίδει καλύτερα από το ένα κρυφό επίπεδο. Κάθε επίπεδο, όμως, μπορεί να αποτελείται από οποιονδήποτε αριθμό νευρώνων και επομένως απαιτούνται δοκιμές για την εύρεση του ιδανικού αριθμού τους. Τα μοντέλα ΤΝΔ εκπαιδεύθηκαν με κάθε δυνατό συνδυασμό αριθμού νευρώνων, από 2 έως 20 νευρώνες, προκειμένου να εξακριβωθεί κατά πόσο επηρεάζει ο αριθμός των συνάψεων την λειτουργία ενός μοντέλου. Στον Πίνακα 5.2 αναγράφονται οι συνδυασμοί με τα καλύτερα αποτελέσματα για το ΤΝΔ Περδικούλας.

Πίνακας 5.2: Σφάλματα $MAPE_{test}$ (%) ανά συνδυασμό αριθμό νευρών στα κρυφά επίπεδα HL_2 και HL_1

<i>ΑΡΙΘΜΟΣ ΝΕΥΡΩΝΩΝ</i> HL_1	HL_2	6	8	10	12	14
6		12,52	12,19	12,77	12,35	12,40
8		11,95	12,62	11,93	12,31	12,29
10		12,12	12,10	12,02	12,38	12,13
12		11,89	12,15	12,18	12,07	12,62
14		11,99	12,45	12,58	11,91	12,15

Όπως φαίνεται από τις τιμές που αναγράφονται στον Πίνακα 5.2, οποιοσδήποτε συνδυασμός αριθμού νευρώνων στα κρυφά επίπεδα σε τιμές κοντινές στο 10 εμφανίζει μικρές αποκλίσεις στα προκύπτοντα σφάλματα. Επομένως, για λόγους ομοιομορφίας, επιλέχθηκε τα δύο κρυφά επίπεδα να περιέχουν από 10 νευρώνες το καθένα.

Αφού οριστικοποιήθηκε η μορφή των κρυφών επιπέδων, έπρεπε να επιλεχθεί η σωστή συνάρτηση ενεργοποίησης για τα κρυφά επίπεδα και το επίπεδο εξόδων. Οι διαθέσιμες συναρτήσεις ενεργοποίησης της βιβλιοθήκης *tensorflow.keras* που μπορούν να χρησιμοποιηθούν στα μοντέλα ΤΝΔ είναι η ίδιας που παρουσιάστηκαν στο Κεφάλαιο 3. Το επόμενο πείραμα αποσκοπεί στην σύγκριση των διάφορων συνδυασμών συναρτήσεων ως προς την απόδοση των μοντέλων.

Ακολουθώντας την συνήθη πρακτική σε παρόμοια προβλήματα όπου χρησιμοποιείται η ίδια συνάρτηση ενεργοποίησης για όλα τα κρυφά επίπεδα, παρουσιάζονται τα σφάλματα $MAPE_{test}$ των συνδυασμών συναρτήσεων για τα επίπεδα του μοντέλου ΤΝΔ Περδικούλας στον Πίνακα 5.3. Τα σφάλματα που αναγράφονται στους πίνακες αυτούς ανήκουν στην καλύτερη εκπαίδευση που έδωσαν πολλαπλές εκτελέσεις κάθε νευρωνικού δικτύου.

Πίνακας 5.3: Σφάλματα $MAPE_{test}$ (%) ανά συνδυασμό συναρτήσεων ενεργοποίησης

Output Layer Hidden Layers	ELU	Exponential	ReLU	SELU
ELU	12,59	12,12	12,47	11,96
Exponential	12,91	12,25	47,43	13,28
ReLU	13,16	12,47	47,43	12,45
SELU	12,19	11,97	47,43	12,45
Sigmoid	12,56	12,51	13,91	12,73
Softplus	13,47	13,09	47,43	13,52
Softsign	11,42	12,13	11,28	11,67
Tanh	11,72	11,88	47,43	12,04


Output Layer Hidden Layers	Sigmoid	Softplus	Softsign	Tanh
ELU	11,88	12,29	12,45	11,92
Exponential	11,93	12,09	12,56	12,25
ReLU	12,73	11,84	12,48	12,91
SELU	11,69	11,87	12,81	12,30
Sigmoid	12,53	12,60	12,44	12,53
Softplus	12,59	12,69	12,96	12,50
Softsign	11,62	12,15	12,03	11,36
Tanh	11,96	12,13	11,63	11,95

Από τον Πίνακα 5.3 διαπιστώνεται ότι ορισμένες συναρτήσεις έχουν διαφορετική συμπεριφορά ανάλογα με το επίπεδο στο οποίο χρησιμοποιούνται. Για παράδειγμα, η σιγμοειδής συνάρτηση αποδίδει μέτρια σφάλματα όταν αξιοποιείται στα κρυφά επίπεδα, αλλά όταν αξιοποιείται στο επίπεδο εξόδου αποδίδει σταθερά χαμηλά σφάλματα, γεγονός που την καθιστά την καταλληλότερη συνάρτηση ενεργοποίησης για το επίπεδο εξόδου. Αντίθετα, στα κρυφά επίπεδα η επιλογή συνάρτησης είναι πολύ δυσκολότερη. Οι δύο καλύτερες συναρτήσεις με τα χαμηλότερα σφάλματα, η Softsign και η Tanh, εμφανίζουν μεγάλες αποκλίσεις σε διαδοχικές εκτελέσεις του μοντέλου, παρουσιάζοντας σφάλματα στο εύρος 11,4–16%. Παρόμοια, οι συναρτήσεις ELU και SELU εμφανίζουν σφάλματα στο εύρος 11,9–14%. Για αυτόν τον λόγο, καταλληλότερη συνάρτηση για τα κρυφά επίπεδα νευρώνων κρίνεται η εκθετική συνάρτηση, η οποία έχει πολύ μικρή διακύμανση όταν συνδυάζεται με την σιγμοειδή στο επίπεδο εξόδου (~11,9–12,5%), παρότι έχει μεγαλύτερο σφάλμα από ότι οι προαναφερθείσες συναρτήσεις.

Το τελευταίο πείραμα για την βελτιστοποίηση των μοντέλων ΤΝΔ περιλαμβάνει την επιλογή του καταλληλότερου βελτιστοποιητή (optimizer), μίας υπερπαραμέτρου που αλλάζει δυναμικά παραμέτρους του δικτύου κατά την διάρκεια της εκπαίδευσής του. Οι διαθέσιμοι βελτιστοποιητές της βιβλιοθήκης *tensorflow.keras* είναι οι ακόλουθοι:

- *Stochastic gradient descent – SGD*: Όλοι οι βελτιστοποιητές βασίζονται στην SGD, μία μέθοδο προσέγγισης της κλίσης μεταβολής των παραμέτρων του δικτύου που ελέγχει τις υπερπαραμέτρους της ορμής (momentum) και έμμεσα του ρυθμού μάθησης (learning rate). Η SGD υπολογίζει μία εκτίμηση κάθε κλίσης, χωρίς να απαιτείται ο ακριβής υπολογισμός της από όλα τα δεδομένα εισόδου, επιταχύνοντας την ενημέρωση των παραμέτρων άρα και κάθε εποχή της εκπαίδευσης.
- *Adaptive gradient – AdaGrad*: Η μέθοδος AdaGrad διατηρεί διαφορετικό ρυθμό μάθησης για κάθε παράμετρο, τον οποίο προσαρμόζει ανάλογα με την συχνότητα που ενημερώνεται η συγκεκριμένη παράμετρος.
- *AdaDelta*: Η μέθοδος AdaDelta παραλλάσσει την AdaGrad, επιτρέποντας σε περιορισμένο αριθμό τελευταίων ενημερώσεων να επηρεάζουν τους ρυθμούς μάθησης.
- *Root Mean Square Propagation – RMSProp*: Η μέθοδος RMSProp διατηρεί επίσης ρυθμό μάθησης για κάθε παράμετρο, τον οποίο ενημερώνει λαμβάνοντας υπόψη τον κινητό μέσο όρο των τελευταίων υπολογισμών των κλίσεων της παραμέτρου.
- *Adaptive Moment Estimation – Adam*: Η μέθοδος Adam παραλλάσσει την RMSProp υπολογίζοντας και τον κινητό μέσο όρο της κλίσης δεύτερης τάξης.
- *Adamax*: Εκδοχή της Adam που βασίζεται στην ομοιόμορφη νόρμα.
- *Nadam*: Εκδοχή της Adam που υπολογίζει τις κλίσεις κατά Nesterov και συγκλίνει ταχύτερα.

Το μοντέλο ΤΝΔ Περδικούλας δοκιμάστηκε με κάθε έναν από αυτούς τους βελτιστοποιητές και τα αποτελέσματα του πειράματος παρουσιάζονται στο Σχήμα 5.5.



Σχήμα 5.5 : $MAPE_{test}$ ανά βελτιστοποιητή

Ο βελτιστοποιητής με το μικρότερο σφάλμα είναι ο Nadam και, συνεπώς, είναι αυτός που επιλέγεται για το βέλτιστο μοντέλο ΤΝΔ.

5.4 ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΣΥΓΚΡΙΣΗ ΜΟΝΤΕΛΩΝ

5.4.1 Μοντέλα ΤΝΔ

Τα μοντέλα ΤΝΔ κρίνονται η πλέον κατάλληλη μέθοδος για την πρόβλεψη παραγωγής ισχύος, καθότι επιτρέπουν την δημιουργία μοντέλων με χαμηλά σφάλματα και μεγάλη ταχύτητα. Όπως φαίνεται στον Πίνακα 5.4 για το μοντέλο της Λαμπρινής (ανά τέταρτο), το $MAPE_{test}$ παρουσιάζει μικρή διακύμανση τόσο μεταξύ του γενικού συνόλου ελέγχου και των εποχιακών συνόλων, όσο και μεταξύ των τεσσάρων εποχών, διατηρώντας το σφάλμα εκπαίδευσής του στο διάστημα 5,5–6%. Το μοντέλο της Λαμπρινής (ανά λεπτό) παρουσιάζει παρόμοια συμπεριφορά με το μοντέλο ανά τέταρτο, με λίγο μικρότερα σφάλματα, ενώ αντίθετα, το μοντέλο της Περδικούλας έχει αισθητά χαμηλότερη απόδοση στα εποχιακά μοντέλα (Πίνακας 5.5) και μεγάλη απόκλιση μεταξύ απλού μοντέλου και μοντέλου κυκλικών χρόνων.

Πίνακας 5.4: $MAPE_{test}$ (%) ανά σύνολο ελέγχου για το μοντέλο της Λαμπρινής (ανά τέταρτο)

$MAPE_{test}$ (%)	Γενικό	Χειμώνας	Άνοιξη	Καλοκαίρι	Φθινόπωρο
Απλό	11,26	13,70	12,77	12,63	13,59
Κυκλικών Χρόνων	11,12	13,44	12,09	12,37	13,22

Πίνακας 5.5: $MAPE_{test}$ (%) ανά σύνολο ελέγχου για το μοντέλο της Περδικούλας

$MAPE_{test}$ (%)	<i>Γενικό</i>	<i>Χειμώνας</i>	<i>Άνοιξη</i>	<i>Καλοκαίρι</i>	<i>Φθινόπωρο</i>
<i>Απλό</i>	12,09	14,96	19,61	10,09	14,03
<i>Κυκλικών Χρόνων</i>	14,65	18,81	19,13	12,24	15,67

Η διαφορετική συμπεριφορά των μοντέλων των δύο πάρκων μπορεί να οφείλεται σε πολλούς παράγοντες, με κυριότερο το γεγονός ότι έχουν εντελώς διαφορετικό δείγμα δεδομένων. Η αξιοπιστία των αισθητήρων κάθε πάρκου, οι διαφορετικές περίοδοι δειγματοληψίας και οι περιβαλλοντικές συνθήκες σε δύο μη γειτονικές γεωγραφικές περιοχές της Ελλάδας συντελούν στην δημιουργία διαφορετικών δειγμάτων εκπαίδευσης και ελέγχου, τα οποία μετέπειτα εφαρμόζονται σε σύνολα ελέγχου που αναφέρονται σε διαφορετικές ημερομηνίες και ώρες. Ως αποτέλεσμα, η αιτία της απόκλισης των σφαλμάτων των μοντέλων και της διαφορετικής τους συμπεριφοράς παραμένει απροσδιόριστη.

Η μεγάλη αδυναμία των μοντέλων ΤΝΔ είναι η τυχαιότητα στην οποία βασίζονται για την δημιουργία συσχετίσεων μεταξύ εισόδων και εξόδων. Ο τρόπος της αρχικοποίησης των βαρών και πολώσεών τους, οι επιλεγμένες υπερπαράμετροι και η δομή του δικτύου συμβάλουν στην μείωση των σφαλμάτων, αλλά δεν εμποδίζουν την παγίδευση του εκπαιδευμένου μοντέλου σε κάποιο τοπικό ελάχιστο σφάλματος. Συνεπώς, δύο πανομοιότυπα μοντέλα ΤΝΔ μπορούν να παρουσιάσουν αποκλίνοντα σφάλματα, όπως φαίνεται στον Πίνακα 5.6, και για αυτόν τον λόγο κάθε μοντέλο ΤΝΔ εκτελείται πολλές φορές πριν επιλεγεί η εκτέλεση με το μικρότερο σφάλμα. Για την αποφυγή της παγίδευσης σε τοπικό ελάχιστο ενός ΤΝΔ σε εφαρμογή πραγματικού χρόνου θα πρέπει να οριστεί μεγάλος ρυθμός μάθησης και να επαναλαμβάνονται συχνά οι εκπαιδεύσεις του.

Πίνακας 5.6: $MAPE$ (%) για το μοντέλο ΤΝΔ της Λαμπρινής (ανά λεπτό) σε διαφορετικές εκτελέσεις του

	<i>1^η Εκτέλεση</i>	<i>2^η Εκτέλεση</i>	<i>3^η Εκτέλεση</i>	<i>4^η Εκτέλεση</i>
$MAPE_{train}$ (%)	5,11	5,10	7,27	5,07
$MAPE_{test}$ (%)	12,17	13,51	14,28	15,26

5.4.2 Μοντέλα ΜΔΥ

Τα μοντέλα ΜΔΥ αποδεικνύονται εφάμιλλα των μοντέλων ΤΝΔ, όπως φαίνεται στα Σχήματα 5.4α και 5.4β και στον Πίνακα 5.7. Η επιλογή των υπερπαραμέτρων των μοντέλων, με βάση τις προτεινόμενες τιμές τους από τον αλγόριθμο Firefly, βελτιώνει την απόδοση των μοντέλων, ιδιαίτερα στην περίπτωση των μοντέλων κυκλικών χρόνων (Πίνακας 5.7). Στον Πίνακα 5.8 φαίνονται τα σφάλματα ελέγχου των τριών βέλτιστων μοντέλων κυκλικών χρόνων δοκιμασμένα στα πέντε διαφορετικά σύνολα ελέγχου, τα οποία παρουσιάζουν μεγαλύτερες αποκλίσεις από τα αντίστοιχα μοντέλα ΤΝΔ, αλλά επιδεικνύουν παρόμοια συμπεριφορά.

Η αδυναμία των μοντέλων ΜΔΥ είναι η δυσκολία βελτιστοποίησής τους μέσω της εύρεσης της ιδανικής τιμής των υπερπαραμέτρων C και γ . Όπως φαίνεται στον Πίνακα 5.1, ο αλγόριθμος FFA ορίζει διαφορετικές τιμές στις δύο μεταβλητές για κάθε μοντέλο. Δεδομένης της απουσίας κάποιας κοινής πρακτικής για τον προσδιορισμό αυτών των μεταβλητών, προτείνεται η δοκιμή πολλών διαφορετικών τιμών για καθεμία από αυτές, είτε μέσω αλγορίθμων βελτιστοποίησης όπως ο Firefly, είτε χειροκίνητα από τον χρήστη, μια πολύ χρονοβόρα και απαιτητική υπολογιστικά διαδικασία για να υλοποιηθεί επιτόπου σε ένα Φ/Β πάρκο, στο οποίο συνεχώς δειγματοληπτούνται νέα δεδομένα που επηρεάζουν τις τιμές αυτές. Ο λόγος αυτός επιβάλλει την επιλογή τιμών C και γ που λειτουργούν καλά ανεξαρτήτως δείγματος εκπαίδευσης, αλλά πιθανώς δεν είναι ιδανικά για κάθε περίπτωση.

Πίνακας 5.7: $MAPE_{test}$ (%) ανά μοντέλο ΜΔΥ (Γενικό σύνολο ελέγχου)

$MAPE_{test}$ (%)	<i>Απλό</i>	<i>Κυκλικών Χρόνων</i>	<i>Βέλτιστο Απλό</i>	<i>Βέλτιστο Κυκλικών Χρόνων</i>
<i>Λαμπρινή ανά λεπτό</i>	14,04	23,50	12,74	11,77
<i>Λαμπρινή ανά τέταρτο</i>	11,11	11,67	10,90	11,21
<i>Περδικούλα</i>	13,78	14,65	13,08	12,67

Πίνακας 5.8: $MAPE_{test}$ (%) ανά σύνολο ελέγχου για τα βέλτιστα μοντέλα ΜΔΥ κυκλικών χρόνων

$MAPE_{test}$ (%)	<i>Γενικό</i>	<i>Χειμώνας</i>	<i>Άνοιξη</i>	<i>Καλοκαίρι</i>	<i>Φθινόπωρο</i>
<i>Λαμπρινή ανά λεπτό</i>	11,77	16,76	14,80	12,76	14,29
<i>Λαμπρινή ανά τέταρτο</i>	11,21	15,13	12,37	12,75	13,41
<i>Περδικούλα</i>	12,67	16,41	19,03	12,12	14,26

5.4.3 Σύγκριση μεθόδων στο Γενικό σύνολο ελέγχου

Αν και οι δύο μέθοδοι (στην καλύτερη μορφή τους) εξάγουν προβλέψεις με παραπλήσια σφάλματα, τα ΤΝΔ προσφέρουν συστηματικά αποδοτικότερα μοντέλα πρόβλεψης, όπως υποδεικνύεται από τους Πίνακες 5.4, 5.7 και 5.8. Ωστόσο, παρά τις διαφορές τους στις τιμές των σφαλμάτων και τον τρόπο που αξιοποιούν τα δεδομένα εισόδου, όλα τα μοντέλα αποκτούν την ικανότητα, μέσα από την εκπαίδευσή τους, να εντοπίζουν συσχετισμούς μεταξύ των δεδομένων εισόδου και εξόδου και να τους αντιμετωπίζουν με παρεμφερή τρόπο.

Αυτή η συμπεριφορά τους γίνεται έκδηλη στα παραδείγματα των Σχημάτων 5.6, 5.7 και 5.8, όπου συγκρίνονται οι προβλέψεις των βέλτιστων μοντέλων του πάρκου Λαμπρινής σε σχέση με την παρατηρούμενη τιμή της ενεργού ισχύος. Ο Πίνακας 5.9 συνοψίζει τις πληροφορίες που αφορούν τις συγκεκριμένες υποθέσεις ελέγχου (18, 4 και 16) του Γενικού συνόλου ελέγχου, για τις οποίες το μοντέλο ΜΔΥ της Λαμπρινής (ανά λεπτό) παρουσιάζει το μέγιστο σφάλμα του, σφάλμα περίπου ίσο με το $MMAPE_{test}$ του και το ελάχιστο σφάλμα του, αντίστοιχα. Να σημειωθεί ότι το Γενικό σύνολο δοκιμάζει τα μοντέλα σε διάστημα ενός ολόκληρου χρόνου και σε ποικίλες καιρικές συνθήκες, με έμφαση σε ημέρες Σ και Μ.

Η Υπόθεση 18 αφορά στο θερινό ηλιοστάσιο στις 21/06/2021, μία απρόσμενα συννεφιασμένη ημέρα στα μέσα του Ιουνίου. Με βάση τα δεδομένα μέχρι τις 2 μ.μ., τα μοντέλα προβλέπουν την ομαλή μείωση της παραγόμενης ισχύος από το μέγιστό της μέχρι την δύση του ηλίου, η οποία πρόβλεψη δεν επιβεβαιώνεται λόγω της χειροτέρευσης των καιρικών συνθηκών. Ως αποτέλεσμα, οι προβλέψεις υπερτιμούν την παραγωγή ισχύος, αναμένοντας υψηλή ηλιοφάνεια, και παρουσιάζουν σφάλματα ελέγχου μεγαλύτερα του 25%.

Η Υπόθεση 4 αναφέρεται σε μία ηλιόλουστη ημέρα στις αρχές Φεβρουαρίου, συγκεκριμένα στις 4/2/2021. Αν και τα μοντέλα ορθά προβλέπουν σταθερή μείωση της ισχύος μέχρι το τέλος της ημέρας, υποτιμούν την τιμή της ισχύος, επειδή ανέμεναν χαμηλότερη παραγωγή κατά τη διάρκεια μίας χειμωνιάτικης ημέρας. Όλα τα μοντέλα σημειώνουν μέτρια σφάλματα, περίπου 10–13%.


Η Υπόθεση 16 εξετάζει την απόκριση των μοντέλων σε μία καλοκαιρινή ημέρα με ιδανικές συνθήκες ηλιοφάνειας, τις 26/6/2021. Και τα τέσσερα μοντέλα επιτυγχάνουν πολύ χαμηλό σφάλμα, με τρία από αυτά να αποκλίνουν μόνο 1–2% κατά MAPE. Αξίζει να σημειωθεί η χρονική εγγύτητα των Υποθέσεων 16 και 18, οι οποίες, αν και απέχουν μόλις πέντε ημέρες, αποτελούν παραδείγματα αντίθετων περιπτώσεων. Η Υπόθεση 16 ελέγχει τα μοντέλα σε μία από τις ηλιόλουστες ημέρες του καλοκαιριού του 2021, οι οποίες ημέρες αποτελούν το 54,5% των ημερών ολόκληρης της εποχής και το 27,1% ολόκληρου του χρόνου. Η Υπόθεση 18 ελέγχει τα μοντέλα σε μία από τις ημέρες με μέτρια συννεφιά, οι οποίες, αν και αποτελούν το 36,4% ολόκληρου του χρόνου, είναι αρκετά λιγότερες κατά τη διάρκεια του καλοκαιριού (18,2%). Επομένως, είναι λογικό οι προβλέψεις που αφορούν ηλιοφάνεια να είναι πολύ ακριβέστερες από τις προβλέψεις που αφορούν χειρότερες καιρικές συνθήκες.

Τα πλέον βέλιστα μοντέλα των δύο μεθόδων δίνουν παραπλήσιες τιμές ως προς την εκτίμηση του σφάλματος, όμως αυτό το επιτυγχάνουν με προσεκτική επιλογή των υπερπαραμέτρων τους, εκπαίδευση σε επαρκή δείγματα εισόδου και ανοχή στον χρόνο εκτέλεσής τους. Σε μία εφαρμογή τέτοιων μοντέλων σε πραγματικό χρόνο μπορούν να εμφανιστούν πολλά διαφορετικά προβλήματα σχετικά με την λειτουργία τους. Για


παράδειγμα, ο χρόνος εκτέλεσής τους επηρεάζεται πρωτίστως από το μέγεθος του δείγματος εκπαίδευσής τους, το οποίο αποτελεί μεγάλο ελάττωμα των μοντέλων Λαμπρινής ανά λεπτό, ειδικά του μοντέλου ΜΔΥ του οποίου η εκπαίδευση μπορεί να διαρκέσει από μερικές δεκάδες λεπτά έως και αρκετές ώρες για να επιτύχει το επιθυμητό επίπεδο σφαλμάτων.

Πίνακας 5.9: Σύνοψη των Υποθέσεων Ελέγχου 18,4 και 16 για την Λαμπρινή


Υπόθεση Ελέγχου	Καιρικές Συνθήκες	Διάστημα δεδομένων εισόδου		Διάστημα πρόβλεψης		MAPE _{test} (%) Λαμπρινής			
		Από	Έως	Από	Έως	TNΔ ανά 1	TNΔ ανά 15	ΜΔΥ ανά 1	ΜΔΥ ανά 15
18 (21/6/2021)	Μ	10:30	14:00	14:15	17:45	30,12	31,26	28,43	27,83
4 (4/2/2021)	Λ	10:15	13:45	14:00	17:30	10,27	12,08	12,19	13,12
16 (26/6/2021)	Λ	12:30	16:00	16:15	19:45	6,05	1,63	0,66	1,74



Σχήμα 5.6 : Προβλέψεις για την Υπόθεση Ελέγχου 18



Σχήμα 5.7 : Προβλέψεις για την Υπόθεση Ελέγχου 4



Σχήμα 5.8 : Προβλέψεις για την Υπόθεση Ελέγχου 16

5.4.4 Σύγκριση μοντέλων στα Εποχιακά σύνολα ελέγχου

Έπειτα από την σύγκριση των μοντέλων στο Γενικό σύνολο, τα μοντέλα δοκιμάζονται στα εποχιακά σύνολα, τα οποία περιλαμβάνουν ίσο αριθμό από περιπτώσεις στις τέσσερις διαφορετικές κατηγορίες καιρικών συνθήκων (Λ, Σ, Μ και Β) ανά εποχή. Στον Πίνακα 5.10 παρουσιάζονται οι μέσοι όροι ανά είδος ημέρας και εποχής των σφαλμάτων $MMAPE_{test}$ στα εποχιακά σύνολα για το μοντέλο ΤΝΔ Λαμπρινής (ανά λεπτό), το οποίο παρουσιάζει την μικρότερη διακύμανση από όλα τα υπόλοιπα. Ακόμα, στον Πίνακα 5.11 συνοψίζονται οι μέσοι όροι ανά είδος ημέρας σε εύρος ολόκληρου χρόνου για όλα τα μοντέλα.

Πίνακας 5.10: $MMAPE_{test}$ (%) ανά είδος ημέρας για το μοντέλο ΤΝΔ Λαμπρινής (ανά λεπτό)

	<i>Λιακάδα</i>	<i>Σποραδικά Σύννεφα</i>	<i>Μέτρια Σύννεφα</i>	<i>Βαριά Σύννεφα</i>	<i>Μέσο Σφάλμα ανά εποχή</i>
<i>Χειμώνας</i>	3,12	14,91	28,36	7,66	13,51
<i>Ανοιξη</i>	2,52	9,66	27,03	9,42	12,16
<i>Καλοκαίρι</i>	1,78	8,49	26,07	X	12,11
<i>Φθινόπωρο</i>	3,59	9,03	26,98	10,90	12,63
<i>Μέσο Σφάλμα ανά είδος καιρού</i>	2,75	10,52	27,11	9,33	12,43

Πίνακας 5.11: $MMAPE_{test}$ (%) ανά είδος ημέρας σε εύρος ολόκληρου χρόνου


	<i>Λιακάδα</i>	<i>Σποραδικά Σύννεφα</i>	<i>Μέτρια Σύννεφα</i>	<i>Βαριά Σύννεφα</i>	<i>Μέσο Σφάλμα ανά έτος</i>
<i>ΤΝΔ Λαμπρινή ανά λεπτό</i>	2,75	10,52	27,11	9,33	12,43
<i>ΤΝΔ Λαμπρινή ανά τέταρτο</i>	3,14	10,35	26,62	10,57	12,67
<i>ΤΝΔ Περγικούλα</i>	4,13	11,28	24,79	20,73	15,23
<i>ΜΔΥ Λαμπρινή ανά λεπτό</i>	7,00	11,21	25,82	15,18	14,80
<i>ΜΔΥ Λαμπρινή ανά τέταρτο</i>	4,32	10,87	24,99	13,72	13,47
<i>ΜΔΥ Περγικούλα</i>	7,62	11,73	23,23	22,14	16,18

Αναμενόμενα, οι ημέρες με μεγάλη ηλιοφάνεια είναι και οι ευκολότερες για την εξαγωγή πρόβλεψης. Στην πλειοψηφία των υποθέσεων ελέγχου σε ημέρες Λ, τα περισσότερα μοντέλα επιτυγχάνουν να δημιουργήσουν προβλέψεις που ακολουθούν την κανονική κατανομή, και τα όποια σφάλματά τους έγκεινται στην υποτίμηση (ή υπερίμηση) της ικανότητας παραγωγής ισχύος κάθε πάρκου την χρονική περίοδο που πραγματοποιείται η υπόθεση. Χαρακτηριστικά ξεχωρίζουν τα σφάλματα ημερών Λ κατά την διάρκεια του καλοκαιριού, τα οποία είναι ελάχιστα. Τον υπόλοιπο χρόνο, τα σφάλματα ημερών Λ αυξάνονται, καθώς παρατηρείται μεγαλύτερη ποικιλομορφία καιρικών συνθηκών και αναμένονται συχνές κακοκαιρίες, γεγονός που οδηγεί τα μοντέλα (συνήθως) στην υποτίμηση της παραγωγής ισχύος.

Στα περισσότερα μοντέλα, οι ημέρες Σ και Β έχουν απροσδόκητα παραπλήσια σφάλματα. Αυτό, πιθανώς, οφείλεται σε αντιδιαμετρικά αντίθετους λόγους: οι ημέρες με σποραδική συννεφιά συχνά ξεκινούν με παρόμοιο τρόπο με τις ηλιόλουστες ημέρες και προβλέπεται υψηλή παραγωγή ισχύος, ενώ οι ημέρες με έντονη συννεφιά παρουσιάζουν από το πρωί χαμηλές ενδείξεις ηλιακής ακτινοβολίας και προβλέπεται χαμηλή παραγωγή. Και στις δύο περιπτώσεις η παραγόμενη ισχύς παρουσιάζει αυξομειώσεις που δεν ακολουθούνται εύκολα από τα μοντέλα, τα οποία, όμως, καταφέρνουν να προσεγγίσουν την μέση τιμή της.

Σε καθένα από τα μοντέλα πρόβλεψης, οι πλέον δύσκολες ημέρες να πραγματοποιηθεί έγκυρη πρόβλεψη είναι οι ημέρες με μέτρια σύννεφα, κατά τις οποίες παρατηρούνται σχεδόν διπλάσια σφάλματα από ότι τις ημέρες με σποραδική ή βαριά συννεφιά. Τις ημέρες Μ η παραγόμενη ισχύς ακολουθεί τμηματικά μόνο την κανονική κατανομή, σημειώνοντας απότομες πτώσεις σε διαφορετικές στιγμές της ημέρας, συμπεριλαμβανομένων και των ωρών αιχμής. Αυτές οι μεταβάσεις δύσκολα προβλέπονται από τα μοντέλα, τα οποία αποτυγχάνουν είτε να προβλέψουν τις απότομες πτώσεις είτε να υποθέσουν ότι θα υπάρχουν ηλιόλουστες ώρες με υψηλή παραγωγή.


Στα Σχήματα 5.9 έως 5.12 παρουσιάζεται η πορεία των σφαλμάτων σε όλες τις υποθέσεις ελέγχου των εποχιακών μοντέλων για το έτος 2020 του μοντέλου ΜΔΥ Περδικούλας.




Σχήμα 5.9 : Σφάλματα προβλέψεων ημερών Λ για το μοντέλο ΜΔΥ Περδικούλας



Σχήμα 5.10 : Σφάλματα προβλέψεων ημερών Σ για το μοντέλο ΜΔΥ Πεردικούλα



Σχήμα 5.11 : Σφάλματα προβλέψεων ημερών Μ για το μοντέλο ΜΔΥ Πεردικούλα



Σχήμα 5.12 : Σφάλματα προβλέψεων ημερών Β για το μοντέλο ΜΔΥ Περδικούλα

5.4.5 Σύγκριση μοντέλων ως προς το δείγμα εισόδου

Ένας από τους κυριότερους παράγοντες που καθορίζουν την ποιότητα και πολυπλοκότητα μιας εκπαίδευσης είναι το δείγμα εισόδου, που αποτελείται από χιλιάδες σειρές δεδομένων. Σε κάθε σειρά βρίσκονται τα ιστορικά δεδομένα από τους μετρητές και αισθητήρες του επιλεγμένου Φ/Β πάρκου για κάθε μεταβλητή εισόδου που έχει ορίσει ο χρήστης. Τα δεδομένα αυτά εισάγονται στο μοντέλο, το οποίο αναλαμβάνει να τα συσχετίσει με την μεταβλητή εξόδου, την παρατηρούμενη ενεργό ισχύ που παράγει το πάρκο και προωθεί προς το δίκτυο ενέργειας. Ο όγκος των δεδομένων είναι καθοριστικός του χρόνου εκτέλεσης ενός μοντέλου και επηρεάζει την ακρίβεια των προβλέψεων, με κίνδυνο την υπερπροσαρμογή του μοντέλου στα δείγμα εκπαίδευσης για μεγάλο δείγμα εισόδου ή την ελλιπή εκπαίδευση του μοντέλου για μικρό δείγμα εισόδου. Σε κάθε εκπαίδευση που έχει παρουσιαστεί το δείγμα εκπαίδευσης αποτελούνταν από έναν ολόκληρο χρόνο δεδομένων για το κάθε πάρκο.

Στον Πίνακα 5.12 παρουσιάζονται τα αποτελέσματα ενός πειράματος όπου τα βέλτιστα μοντέλα πρόβλεψης δοκιμάστηκαν σε πολύ μικρό δείγμα εκπαίδευσης, το οποίο περιείχε τα δεδομένα μόνο από τον Δεκέμβρη του 2020 για το πάρκο Λαμπρινή. Οι ημέρες αυτού του μήνα κατηγοριοποιούνται ως εξής:

- 6 ημέρες Λ
- 1 ημέρα Σ
- 15 ημέρες Μ
- 5 ημέρες Β


Οι υπόλοιπες 4 ημέρες έχουν ελλιπή δεδομένα και αφαιρέθηκαν από το δείγμα εισόδου.

Αν και πράγματι μειώθηκε εξαιρετικά ο χρόνος εκτέλεσης των μοντέλων, κυρίως των μοντέλων ΜΔΥ, μόνο το μοντέλο Λαμπρινής ανά τέταρτο μπορεί να θεωρηθεί σχετικά

αξιόπιστο. Το μικρό χρονικό διάστημα εκπαίδευσης, ειδικά κατά την διάρκεια ενός μήνα με άστατο καιρό, δεν είναι αρκετό για να εξαχθεί επιτυχής πρόβλεψη, όπως συμβαίνει στην περίπτωση του μοντέλου ΜΔΥ Λαμπρινής ανά λεπτό, το οποίο προβλέπει *κατανάλωση* ισχύος (και όχι παραγωγή) άνω των 2 MW (Σχήμα 5.13) στην υπόθεση ελέγχου 22 του Γενικού συνόλου!

Πίνακας 5.12: Δοκιμή μοντέλων σε μικρό δείγμα εισόδου

	<i>Χρόνος Εκτέλεσης</i>	<i>MAPE_{train} (%)</i>	<i>Mean MAPE_{test} (%)</i>	<i>Max MAPE_{test} (%)</i>	<i>Min MAPE_{test} (%)</i>
<i>TNA Λαμπρινή ανά λεπτό</i>	60"	4,10	25,06	75,09 (YE 10)	3,27 (YE 11)
<i>TNA Λαμπρινή ανά τέταρτο</i>	13"	5,06	13,25	32,27 (YE 18)	1,42 (YE 11)
<i>ΜΔΥ Λαμπρινή ανά λεπτό</i>	39"	5,60	63,67	199,38 (YE 22)	3,64 (YE 36)
<i>ΜΔΥ Λαμπρινή ανά τέταρτο</i>	3"	6,54	27,51	54,48 (YE 20)	4,92 (YE 10)



Σχήμα 5.13 : Προβλέψεις για την Υπόθεση Ελέγχου 22

Με αφορμή αυτό το πείραμα, κάθε μοντέλο δοκιμάστηκε σε διαφορετικό αριθμό ημερών εκπαίδευσης, προκειμένου να βρεθεί ο αριθμός ημερών που είναι ικανός για επιτυχή πρόβλεψη παραγωγής ισχύος. Για αυτό το πείραμα χρησιμοποιήθηκαν τα βέλτιστα μοντέλα ανά μέθοδο πρόβλεψης και πάρκο, τα οποία δοκιμάστηκαν σε διαφορετικούς αριθμούς ημερών εκπαίδευσης με βήμα 30 ημέρες. Τα αποτελέσματα του πειράματος φαίνονται στον Πίνακα 5.13.

Όπως φαίνεται από τον Πίνακα 5.13, ένα δείγμα εισόδου αποτελούμενο από δεδομένα τριών μηνών (90 ημέρες) είναι πολύ μικρό για την εξαγωγή επιτυχών προβλέψεων, καθότι τα σφάλματα ξεπερνούν το 20% για τα περισσότερα μοντέλα. Για αριθμό ημερών ίσο με 120–210 σημειώνεται σημαντική βελτίωση σε κάθε μοντέλο, έως ότου τα σφάλματα πλησιάσουν τα ελάχιστα σφάλματα που σημειώνονται στα πλήρως εκπαιδευμένα βέλτιστα μοντέλα (Σχήματα 5.3–5.4β), δηλαδή μεταξύ 11% με 12,5%, στο δείγμα των 240 ημερών. Επομένως, ένα δείγμα 240 ημερών μπορεί να αποφέρει εξίσου καλά αποτελέσματα με δείγματα που περιέχουν έναν ολόκληρο χρόνο δεδομένων, με τις διαφορές που αναγράφονται στον Πίνακα 5.14. Στον ίδιο πίνακα φαίνεται η μικρή βελτίωση στην απόδοση κάθε μοντέλου όταν αξιοποιεί 360 ημέρες στην εκπαίδευση του σε βάρος του χρόνου που εκτελείται, με εξαίρεση το μοντέλο Λαμπρινής ανά λεπτό, το οποίο δεν σημειώνει βελτίωση και ζημιώνεται αρκετά στον χρόνο εκτέλεσής του. Επίσης, αξιοσημείωτη είναι η περίπτωση του μοντέλου Λαμπρινής ανά τέταρτο της ώρας, το οποίο έχει από τα μικρότερα σφάλματα $MMAPE_{test}$, το μικρότερο μέγιστο σφάλμα υπόθεσης και ολοκληρώνει τα στάδια εκπαίδευσης και ελέγχου σε λιγότερο από μισό λεπτό.

Στον Πίνακα 5.15 παρουσιάζονται πληροφορίες για τις υποθέσεις ελέγχου που έχουν αναφερθεί.

Πίνακας 5.13: $MMAPE_{test}$ (%) ανά αριθμό ημερών εκπαίδευσης

	Αριθμός Ημερών Εκπαίδευσης						
	60	90	120	150	180	210	240
<i>TNΔ</i>							
<i>Λαμπρινή ανά λεπτό</i>	19,18	23,97	17,37	13,51	13,49	12,72	12,12
<i>TNΔ</i>							
<i>Λαμπρινή ανά τέταρτο</i>	22,86	22,88	15,18	12,50	12,94	12,52	11,60
<i>TNΔ</i>							
<i>Περδικούλα</i>	21,23	20,02	15,07	12,11	11,54	11,50	11,30
<i>ΜΔΥ</i>							
<i>Λαμπρινή ανά λεπτό</i>	22,75	72,88	17,25	12,44	15,24	11,90	11,52
<i>ΜΔΥ</i>							
<i>Λαμπρινή ανά τέταρτο</i>	18,29	34,73	17,06	11,92	11,33	11,35	11,30
<i>ΜΔΥ</i>							
<i>Περδικούλα</i>	23,39	13,86	15,20	13,47	12,57	12,62	12,42

Πίνακας 5.14: Σύγκριση μοντέλων με 240 και 360 ημέρες στο δείγμα εκπαίδευσης για τα μοντέλα Λαμπρινής

	<i>Χρόνος Εκτέλεσης</i>		<i>Mean MAPE_{test} (%)</i>		<i>Max MAPE_{test} (%)</i>		<i>Min MAPE_{test} (%)</i>	
	240	360	240	360	240	360	240	360
<i>TNA</i> <i>Λαμπρινή</i> <i>ανά λεπτό</i>	347"	517"	12,12	11,61	31,26 (YE 18)	30,12 (YE 18)	1,10 (YE 22)	1,23 (YE 11)
<i>TNA</i> <i>Λαμπρινή</i> <i>ανά τέταρτο</i>	52"	93"	11,60	11,12	38,45 (YE 10)	31,26 (YE 18)	0,77 (YE 25)	0,72 (YE 25)
<i>ΜΔΥ</i> <i>Λαμπρινή</i> <i>ανά λεπτό</i>	~30m	~2h 30m	11,52	11,77	28,63 (YE 18)	28,44 (YE 18)	0,62 (YE 16)	0,66 (YE 16)
<i>ΜΔΥ</i> <i>Λαμπρινή</i> <i>ανά τέταρτο</i>	11"	25"	11,30	11,21	28,24 (YE 18)	27,84 (YE 18)	0,82 (YE 25)	1,01 (YE 25)

Πίνακας 5.15: Σύνοψη Υποθέσεων Ελέγχου – YE

	<i>YE 10</i>	<i>YE 11</i>	<i>YE 16</i>	<i>YE 18</i>	<i>YE 20</i>	<i>YE 22</i>	<i>YE 25</i>	<i>YE 36</i>
<i>Ημ/νία</i>	24/04/21	21/04/21	26/6/21	21/6/21	17/07/21	01/08/21	25/9/21	13/12/21
<i>Καιρικές Συνθήκες</i>	B	Σ	Λ	M	Σ	Λ	Λ	M

Εκτός από τον αριθμό ημερών εκπαίδευσης, το δείγμα εισόδου κάθε μοντέλου καθορίζεται από την ποσότητα και το είδος των μεταβλητών του. Κάθε μεταβλητή που αξιοποιείται πρέπει να συνεισφέρει στην πρόβλεψη, συμπληρώνοντας τις υπόλοιπες στην δημιουργία της επιθυμητής πρόβλεψης με χαμηλά σφάλματα. Μία μεταβλητή που δεν σχετίζεται με το αντικείμενο της εκπαίδευσης επιβαρύνει το μοντέλο τόσο με περιττό φόρτο δεδομένων όσο και με λανθασμένους συσχετισμούς μεταξύ αυτής και της εξόδου του μοντέλου, ζημιώνοντας την ακρίβεια των προβλέψεων. Σε κάθε εκπαίδευση που έχει παρουσιαστεί έχουν αξιοποιηθεί οι μεταβλητές που αναφέρονται στην Ενότητα 5.3.2.

Στον Πίνακα 5.16 παρουσιάζονται τα αποτελέσματα ενός πειράματος όπου χρησιμοποιήθηκαν εννέα διαφορετικά δείγματα εισόδου, συντιθέμενα από μοναδικούς συνδυασμούς διαθέσιμων μεταβλητών, για εννέα εκπαιδεύσεις του μοντέλου TNA Περδικούλας. Σκοπός του πειράματος ήταν η εύρεση του καταλληλότερου συνδυασμού μεταβλητών για την ακριβέστερη δυνατή πρόβλεψη του μοντέλου. Οι διαθέσιμες μεταβλητές, και οι σχετικοί συμβολισμοί τους στο πείραμα, είναι οι ακόλουθοι:

- Χρονοσήμανση – X
- Ολική πυκνότητα Ηλιακής Ακτινοβολίας – I
- Περιβαλλοντική Θερμοκρασία – T
- Θερμοκρασία Φ/Β μονάδας – T_m
- Σχετική Υγρασία – H_r
- Υετός – Y
- Ταχύτητα Ανέμου – W_s
- Κατεύθυνση Ανέμου – W_d

Κάθε δείγμα που περιέχει κάποια μεταβλητή περισσότερες από μία φορά (από διαφορετικούς αισθητήρες) θα συμβολίζεται με δείκτη τον αριθμό του πλήθους της.

Κάθε διαφορετικό δείγμα, ακόμα και εκείνο που δεν περιέχει καμία μεταβλητή ηλιακής ακτινοβολίας, κρίνεται ικανό για πρόβλεψη. Οι μεταβλητές των περιβαλλοντικών ποσοτήτων είναι στενά συνδεδεμένες και αλληλεξαρτώμενες, που ακόμα και ελλείψει της κύριας ποσότητας που συνδέεται με το φωτοβολταϊκό φαινόμενο, της ηλιακής ακτινοβολίας, μπορεί να επιτευχθεί ένα σφάλμα ~14%. Ωστόσο, αν και με μικρή διαφορά, τα δείγματα που περιέχουν ηλιακή ακτινοβολία από πολλαπλούς αισθητήρες σημειώνουν το μικρότερο σφάλμα, και επομένως, αφού δεν επιβαρύνουν τα μοντέλα Περδικούλας με πολύ μεγαλύτερους χρόνους εκτέλεσης, είναι καταλληλότερα.

Για τα μοντέλα Λαμπρινής παρατηρείται παρόμοια βελτίωση με την συμπερίληψη περισσότερων μεταβλητών στο δείγμα εισόδου, αλλά με μεγάλη ζημίωση στον χρόνο εκτέλεσης των μοντέλων ΜΔΥ, ειδικά αυτού της Λαμπρινής ανά λεπτό. Για αυτόν τον λόγο επιλέχθηκαν μόνο οι μεταβλητές εισόδου που αναφέρονται στην Ενότητα 5.3.2: χρονοσήμανση, πυκνότητα ηλιακής ακτινοβολίας, θερμοκρασία περιβάλλοντος και θερμοκρασία Φ/Β μονάδας.

Πίνακας 5.16: $MMAPE_{test}$ (%) ανά δείγμα εισόδου

	<i>Σύνθεση δείγματος εισόδου</i>				
	X/I	$X/I/T$	$X/I/W_s$	$X/I/T/W_d/W_s$	$X/I/T/H_r/Y$
<i>Σφάλμα MMAPE_{test} (%)</i>	12,10	12,20	12,20	11,96	13,27

	X/I_4	$X/T/W_d/W_s/H_r/Y$	$X/I/T/W_d/W_s/H_r/Y$	$X/I_4/T/H_r/T_m4$
<i>Σφάλμα MMAPE_{test} (%)</i>	11,99	13,93	12,36	11,93

ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΜΕΛΛΟΝΤΙΚΕΣ ΕΠΕΚΤΑΣΕΙΣ

6.1 Ανασκόπηση εργασίας

Σκοπός αυτής της εργασίας είναι η αξιοποίηση δύο μεθόδων μηχανικής μάθησης, των Τεχνητών Νευρωνικών Δικτύων και των Μηχανών Διανυσμάτων Υποστήριξης, για την δημιουργία μοντέλων τεχνητής νοημοσύνης που εξάγουν βραχυπρόθεσμες προβλέψεις για την παραγωγή ενεργού ισχύος δύο φωτοβολταϊκών πάρκων, αξιοποιώντας ιστορικά δεδομένα από μετρητές και αισθητήρες των πάρκων αυτών. Τα αποτελέσματα για κάθε μοντέλο που παρουσιάστηκαν στο Κεφάλαιο 5 υποδεικνύουν ότι και οι δύο μέθοδοι, τα Τεχνητά Νευρωνικά Δίκτυα και οι Μηχανές Διανυσμάτων Υποστήριξης, είναι κατάλληλες για την δημιουργία μοντέλων βραχυπρόθεσμης πρόβλεψης ενεργού ισχύος φωτοβολταϊκού πάρκου. Κάθε μοντέλο εμφανίζει μικρό σφάλμα εκπαίδευσης ($MAPE_{train} < 8\%$) στο δείγμα εισόδου διάρκειας ενός χρόνου και έχει εξαιρετική απόδοση ελέγχου στις ηλιόλουστες ημέρες ($MMAPE_{test} \sim 4\%$), μέσο σφάλμα στις ημέρες με σποραδικά ή βαριά σύννεφα ($MMAPE_{test} \sim 10\text{--}15\%$) και μεγάλο σφάλμα στις ημέρες με μέτρια συννεφιά ($MMAPE_{test} \sim 25\%$). Το μέσο σφάλμα κάθε μοντέλου σε δείγμα πολλών ημερών, με την πλειονότητά τους να είναι ημέρες με παρουσία σύννεφων, υπολογίζεται στο εύρος 11–13%. Επομένως, τα μοντέλα που παρουσιάστηκαν στην παρούσα εργασία διαθέτουν την ικανότητα πρόβλεψης της παραγωγής ισχύος με χαμηλό μέσο σφάλμα, ωστόσο χωρίς να ανταπεξέρχονται επιτυχώς σε ημέρες με νεφοκάλυψη μεγάλης διάρκειας που συμπίπτει με τις ώρες αιχμής.

Ανά εποχή, τα μοντέλα ανταποκρίνονται με μεγάλη επιτυχία στις τυπικές θερινές συνθήκες της Κορινθίας και της Βοιωτίας, με λίγο χειρότερη απόδοση την άνοιξη και το φθινόπωρο όπου εμφανίζεται μεγαλύτερη ποικιλία στα καιρικά φαινόμενα. Τον χειμώνα εμφανίζονται μεγαλύτερα μέσα σφάλματα, κυρίως όταν επικρατούν ευνοϊκότερες καιρικές συνθήκες για την λειτουργία των Φ/Β, καθώς τα μοντέλα υποτιμούν την ικανότητα παραγωγής ισχύος των Φ/Β πάρκων κατά τις μικρότερες και πιο ψυχρές ημέρες του έτους. Αντίστοιχα, οι αραιές δυσχερείς συνθήκες το καλοκαίρι εμφανίζουν μεγάλα σφάλματα, καθότι δεν αναγνωρίζονται εύκολα από τα μοντέλα.

Μεταξύ των δύο μεθόδων υπό μελέτη, τα ΤΝΔ εμφανίζουν σαφέστατα μικρότερα σφάλματα και είναι, εκ πρώτης όψεως, τα καταλληλότερα για τέτοιου είδους εφαρμογές. Χαρακτηρίζονται από μεγάλη ευκολία στην υλοποίησή τους με κώδικα, καθώς υπάρχουν ελεύθερες βιβλιοθήκες με συναρτήσεις που τα αφορούν και άφθονο βοηθητικό υλικό για κάθε βήμα κατασκευής, αντιμετώπισης και επίλυσης σφαλμάτων, και ελέγχου τους. Η διαδικασία της εκπαίδευσης είναι σύντομη, ακόμα και με την εισαγωγή μεγάλου όγκου δεδομένων, και διαθέτουν την ικανότητα προσαρμογής σε οποιοδήποτε πρόβλημα, μέσω της ρύθμισης των πολλών υπερπαραμέτρων τους. Ωστόσο, όπως υποδεικνύεται από την μεγάλη απόκλιση σφαλμάτων εκπαίδευσης ($\sim 5\text{--}6\%$) και ελέγχου ($\sim 11\text{--}12\%$), τα μοντέλα ΤΝΔ

εύκολα υπερπροσαρμόζονται στα δεδομένα εκπαίδευσής τους και δεν γενικεύουν καλά σε άγνωστα δεδομένα.

Οι ΜΔΥ φαινομενικά υστερούν των ΤΝΔ, όμως διαθέτουν αρκετά σημαντικά πλεονεκτήματα και μειονεκτήματα. Σε αντίθεση με τα ΤΝΔ, η λειτουργία τους δεν βασίζεται καθόλου στον παράγοντα της τύχης, καθώς επαναλαμβάνουν με συνέπεια τα ίδια αποτελέσματα για δύο πανομοιότυπες εκπαιδευσεις. Είναι πολύ ευαίσθητα σε αλλαγές, καθώς παρουσιάζουν μεγάλες αποκλίσεις μεταξύ εκτελέσεών τους με διαφορετικές τιμές στις υπερπαραμέτρους τους, με αλλαγές στο δείγμα εκπαίδευσης ή στις μεταβλητές εισόδου, το οποίο δημιουργεί την ανάγκη για προσεκτική μελέτη τους κατά την υλοποίηση, αλλά και προοπτικές για ακόμα καλύτερα αποτελέσματα με την επιλογή των σωστών συνδυασμών παραμέτρων. Για παράδειγμα, παρά τα σταθερά χαμηλά σφάλματα των μοντέλων ΤΝΔ, το μοντέλο με το μικρότερο σφάλμα ελέγχου είναι το μοντέλο ΜΔΥ Λαμπρινής ανά τέταρτο. Ωστόσο, είναι σημαντικό να τονιστεί η μεγάλη επιβάρυνση που επιφέρουν μεγάλα δείγματα εκπαίδευσης, καθότι η εκτέλεση ενός μοντέλου ΜΔΥ μπορεί να διαρκέσει λιγότερο από λεπτό για μικρά σύνολα δεδομένων, αλλά πολλές ώρες για σύνολα με δεκαπλάσιο όγκο δεδομένων.

Για το πάρκο Λαμπρινής, το οποίο διαθέτει δεδομένα με συχνότητα δειγματοληψίας μία μέτρηση ανά λεπτό, δημιουργήθηκαν δύο μοντέλα για κάθε μέθοδο, ένα λαμβάνοντας υπόψη όλα τα διαθέσιμα δεδομένα και ένα λαμβάνοντας υπόψη δεδομένα που απέχουν μεταξύ τους ένα τέταρτο της ώρας. Τα δύο μοντέλα και για τις δύο μεθόδους έχουν παραπλήσια σφάλματα, αν και τα μοντέλα ανά τέταρτο αποδίδουν καλύτερες προβλέψεις σχεδόν σε κάθε απευθείας σύγκριση των μοντέλων. Ο κύριος λόγος αυτού του φαινομένου πιθανώς συνδέεται και με την παρατήρηση ότι τα μοντέλα ανά λεπτό έχουν χαμηλότερα σφάλματα εκπαίδευσης: μικρότερα σφάλματα εκπαίδευσης και μεγαλύτερα σφάλματα ελέγχου αποτελούν χαρακτηριστικό υπερπροσαρμογής του μοντέλου στα δεδομένα εκπαίδευσής του. Διαθέτοντας δεκαπέντε φορές περισσότερα δεδομένα στο δείγμα εκπαίδευσης, τα μοντέλα ανά λεπτό έχουν πολύ μεγαλύτερη διάρκεια.

Στο μοντέλο ΤΝΔ ανά λεπτό, επιτυγχάνεται σύγκλιση πολύ πιο σύντομα σε σχέση με το μοντέλο ανά τέταρτο, γεγονός που επιτρέπει την μείωση του αριθμού των εποχών και, κατά συνέπεια, την μείωση του αυξημένου χρόνου εκτέλεσης. Και στο γενικό και στα εποχιακά σύνολα, το μοντέλο ανά λεπτό έχει ελαφρά χειρότερη απόδοση από το μοντέλο ανά τέταρτο. Αν και δεν γενικεύει εξίσου καλά, το μοντέλο ανά λεπτό δεν έχει ουσιαστικές διαφορές από το μοντέλο ανά τέταρτο, με τις αποκλίσεις να είναι μικρότερες από 0,5%.

Δεν ισχύει, όμως, το ίδιο για το μοντέλο ΜΔΥ ανά λεπτό, το οποίο σε κάθε σύνολο έχει 0,1–2,5% μεγαλύτερο σφάλμα ελέγχου από το μοντέλο ανά τέταρτο. Όπως υποδηλώνεται και από το γεγονός ότι το μοντέλο ανά λεπτό αποδίδει καλύτερα για μικρότερο δείγμα εκπαίδευσης, 240 ημέρες έναντι 365 ημερών των δειγμάτων εκπαίδευσης των υπόλοιπων μοντέλων, η περιττή πληροφορία οδηγεί το μοντέλο σε μη απαραίτητους υπολογισμούς οι οποίοι δυσχεραίνουν τόσο την ίδια την εκτέλεση του μοντέλου όσο και την ποιότητα της προβλεπόμενης ισχύος. Πιθανώς λόγω της μεγαλύτερης συμβολής του θορύβου στις μετρήσεις που απέχουν μόνο ένα λεπτό μεταξύ τους, των μικρών αυξομειώσεων των μεταβλητών εισόδου που πρέπει να συνυπολογίσει το μοντέλο στην εκπαίδευσή του και σποραδικών φαινομένων μικρής διάρκειας που δεν μπορούν να αναγνωριστούν στη δειγματοληψία ανά τέταρτο, οι υπολογισμοί του μοντέλου ανά λεπτό οδηγούνται σε μεγαλύτερα σφάλματα.

Η προσθήκη των μεταβλητών κυκλικών χρόνων είχε μεικτά αποτελέσματα στο σύνολο των μοντέλων. Τα μοντέλα ΤΝΔ εμφανίζουν πολύ μικρές διαφορές μετά την εφαρμογή των κυκλικών χρόνων, παρουσιάζοντας αυξήσεις και μειώσεις μέχρι 0,5% μεταξύ των διάφορων συνόλων ελέγχου, με εξαίρεση το μοντέλο Λαμπρινής ανά τέταρτο που σημειώνει μόνο βελτίωση. Τα μοντέλα ΜΔΥ επηρεάζονται πολύ αρνητικά με την εφαρμογή των κυκλικών χρόνων, αυξάνοντας τα σφάλματά τους από μερικές μονάδες έως και δεκάδες. Μετά την βελτιστοποίησή τους, η μεταβολή αυτή αντιστρέφεται και επιτυγχάνουν μικρότερα σφάλματα στις περισσότερες περιπτώσεις, από ότι τα μοντέλα με την απλή εκδοχή των χρόνων. Συνεπώς, η μετατροπή των μεταβλητών χρόνου σε ημιτονική μορφή κρίνεται ωφέλιμη κυρίως για τα μοντέλα ΜΔΥ στην βέλτιστη μορφή τους.

Εν κατακλείδι, τα ΤΝΔ και τα ΜΔΥ αποτελούν δύο μεθόδους που μπορούν να υλοποιηθούν πάρα πολύ εύκολα σε Η/Υ, διαθέτουν αρκετό βοηθητικό υλικό για κάθε στάδιο της διαδικασίας εφαρμογής τους και είναι ικανές να αποφέρουν επιτυχή πρόβλεψη ενεργού ισχύος ακόμα και στην απλούστερη μορφή τους. Ωστόσο, για την εφαρμογή τους απαιτείται προσεκτική επιλογή του δείγματος εκπαίδευσής τους, προσαρμογή των δεδομένων εισόδου και εξόδων τους και ενδελεχής μελέτη για την εύρεση των ιδανικών υπερπαραμέτρων τους. Τα μοντέλα και των δύο μεθόδων μπορούν να υπολογίσουν πολύ χαμηλά σφάλματα, με εξαίρεση τις ημέρες με έντονες εναλλαγές νεφών και ηλιοφάνειας. Τα ΤΝΔ έχουν την δυνατότητα για τις ακριβέστερες προβλέψεις, χωρίς όμως να τις επιτυγχάνουν με συνέπεια. Τα ΜΔΥ έχουν λίγο μεγαλύτερα σφάλματα, αλλά μπορούν, κατόπιν προσεκτικής επιλογής των υπερπαραμέτρων τους, να εξάγουν συστηματικά καλές προβλέψεις. Ανάλογα με τις απαιτήσεις και δυνατότητες της εκάστοτε εφαρμογής, καθεμία από τις μεθόδους έχει τα δικά της πλεονεκτήματα και μειονεκτήματα, αλλά και οι δύο μέθοδοι μπορούν να εφαρμοστούν με θετικά αποτελέσματα.

6.2 Μελλοντικές Επεκτάσεις

Η παρούσα διπλωματική εργασία περιορίστηκε σε δύο μόνο μεθόδους μηχανικής μάθησης και τεχνητής νοημοσύνης για την πρόβλεψη της παραγόμενης ισχύος Φ/Β πάρκων. Από την οικογένεια των Νευρωνικών Δικτύων επιλέχθηκαν για μελέτη τα απλά δίκτυα εμπρόσθιας τροφοδότησης (feedforward networks) που αποτελούν μόνο μία κατηγορία τους. Ένα ενδιαφέρον θέμα, θα ήταν η δημιουργία περισσότερων μοντέλων ΤΝΔ, όπως είναι τα Radial basis function neural networks (RBF NN), τα Recurrent neural networks (RNN), ή τα Convolutional neural networks (CNN), τα οποία θα ήταν ιδιαίτερα χρήσιμα στην περίπτωση όπου στο δείγμα εισόδου περιέχονται δεδομένα απεικόνισης ουρανού για τον εντοπισμό και παρακολούθηση των νεφών.

Τα μοντέλα που υλοποιήθηκαν σε αυτήν την εργασία χαρακτηρίζονταν από επιβλεπόμενη μάθηση. Άλλες πιθανές επεκτάσεις του θέματος της εργασίας θα μπορούσαν να εξετάσουν μεθόδους μη επιβλεπόμενης μάθησης ή και ενισχυμένης μάθησης. Ακόμα, θα μπορούσαν να δοκιμαστούν διαφορετικού είδους δεδομένα εισόδου ή θα μπορούσε να υλοποιηθεί διαφορετικά οι προεπεξεργασία των δεδομένων αυτών. Τέλος, η δοκιμή περισσότερων βελτιστοποιητών, όπως ο Firefly αλγόριθμος, θα μπορούσε να οδηγήσει στην δημιουργία ακόμα αποδοτικότερων μοντέλων.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] M. Dreidy, H. Mokhlis, and S. Mekhilef, “Inertia response and frequency control techniques for renewable energy sources: A review,” *Renewable and Sustainable Energy Reviews*, vol. 69, pp. 144–155, Mar. 2017, doi: 10.1016/J.RSER.2016.11.170.
- [2] F. Blaabjerg, R. Teodorescu, M. Liserre, and A. v. Timbus, “Overview of control and grid synchronization for distributed power generation systems,” *IEEE Transactions on Industrial Electronics*, vol. 53, no. 5, pp. 1398–1409, Oct. 2006, doi: 10.1109/TIE.2006.881997.
- [3] Κωνσταντίνος Θ. Δέρβος, *Φωτοβολταϊκά Συστήματα από την Θεωρία στην Πράξη*. Πανεπιστημιακές Εκδόσεις Ε.Μ.Π., 2013.
- [4] Μιχ. Π. Παπαδόπουλος, *Παραγωγή ηλεκτρικής ενέργειας από ανανεώσιμες πηγές*. Αθήνα: Έκδοση Εθνικού Μετσόβιου Πολυτεχνείου, 1997.
- [5] Ö. Ayvazoğluyüksel and Ü. B. Filik, “Estimation methods of global solar radiation, cell temperature and solar power forecasting: A review and case study in Eskişehir,” *Renewable and Sustainable Energy Reviews*, vol. 91, pp. 639–653, Aug. 2018, doi: 10.1016/J.RSER.2018.03.084.
- [6] U. K. Das *et al.*, “Forecasting of photovoltaic power generation and model optimization: A review,” *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 912–928, Jan. 2018, doi: 10.1016/J.RSER.2017.08.017.
- [7] L. Yan, C. Yongning, T. Haiyan, T. Xinshou, Z. Zhankui, and J. Jianqing, “Common Focus and New Requirement on Technical Standards of Renewable Energy Grid Integration,” in *2019 Chinese Automation Congress (CAC)*, Nov. 2019, pp. 3719–3723. doi: 10.1109/CAC48633.2019.8996943.
- [8] C. Rahmann and A. Castillo, “Fast Frequency Response Capability of Photovoltaic Power Plants: The Necessity of New Grid Requirements and Definitions,” *Energies* 2014, Vol. 7, Pages 6306-6322, vol. 7, no. 10, pp. 6306–6322, Sep. 2014, doi: 10.3390/EN7106306.
- [9] R. Yan, T. K. Saha, N. Modi, N. al Masood, and M. Mosadeghy, “The combined effects of high penetration of wind and PV on power system frequency response,” *Appl Energy*, vol. 145, pp. 320–330, May 2015, doi: 10.1016/J.APENERGY.2015.02.044.
- [10] S. Eftekharnjad, V. Vittal, G. T. Heydt, B. Keel, and J. Loehr, “Impact of increased penetration of photovoltaic generation on power systems,” *IEEE Transactions on Power Systems*, vol. 28, no. 2, pp. 893–901, 2013, doi: 10.1109/TPWRS.2012.2216294.

- [11] Π. Σ. Γεωργιλάκης, *Σύγχρονα Συστήματα Μεταφοράς και Διανομής Ηλεκτρικής Ενέργειας*. Αθήνα: Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών (ΣΕΑΒ), 2015.
- [12] P. S. Georgilakis and N. D. Hatziargyriou, “Optimal distributed generation placement in power distribution networks: Models, methods, and future research,” *IEEE Transactions on Power Systems*, vol. 28, no. 3, pp. 3420–3428, 2013, doi: 10.1109/TPWRS.2012.2237043.
- [13] B. Pillot, M. Muselli, P. Poggi, and J. B. Dias, “Historical trends in global energy policy and renewable power system issues in Sub-Saharan Africa: The case of solar PV,” *Energy Policy*, vol. 127, pp. 113–124, Apr. 2019, doi: 10.1016/J.ENPOL.2018.11.049.
- [14] P. S. Georgilakis, “Technical challenges associated with the integration of wind power into power systems,” *Renewable and Sustainable Energy Reviews*, vol. 12, no. 3, pp. 852–863, Apr. 2008, doi: 10.1016/J.RSER.2006.10.007.
- [15] F. Rodríguez, A. Fleetwood, A. Galarza, and L. Fontán, “Predicting solar energy generation through artificial neural networks using weather forecasts for microgrid control,” *Renew Energy*, vol. 126, pp. 855–864, Oct. 2018, doi: 10.1016/J.RENENE.2018.03.070.
- [16] M. Diagne, M. David, P. Lauret, J. Boland, and N. Schmutz, “Review of solar irradiance forecasting methods and a proposition for small-scale insular grids,” *Renewable and Sustainable Energy Reviews*, vol. 27, pp. 65–76, 2013, doi: 10.1016/J.RSER.2013.06.042.
- [17] Simon Haykin, *Neural Networks and Learning Machines*, Third. Upper Saddle River, New Jersey 07458: Pearson Education, Inc., 2009.
- [18] H. T. C. Pedro and C. F. M. Coimbra, “Assessment of forecasting techniques for solar power production with no exogenous inputs,” *Solar Energy*, vol. 86, no. 7, pp. 2017–2028, Jul. 2012, doi: 10.1016/J.SOLENER.2012.04.004.
- [19] R. C. Deo, X. Wen, and F. Qi, “A wavelet-coupled support vector machine model for forecasting global incident solar radiation using limited meteorological dataset,” *Appl Energy*, vol. 168, pp. 568–593, Apr. 2016, doi: 10.1016/J.APENERGY.2016.01.130.
- [20] P. S. Georgilakis and N. D. Hatziargyriou, “A review of power distribution planning in the modern power systems era: Models, methods and future research,” *Electric Power Systems Research*, vol. 121, pp. 89–100, Apr. 2015, doi: 10.1016/J.EPSR.2014.12.010.
- [21] L. F. Simmons, “Time-series decomposition using the sinusoidal model,” *Int J Forecast*, vol. 6, no. 4, pp. 485–495, Dec. 1990, doi: 10.1016/0169-2070(90)90025-7.