

Εθνικό Μετσοβίο Πολύτεχνειο Σχολή Ηλεκτρολογών Μηχανικών και Μηχανικών Υπολογιστών Τομέας Ηλεκτρικής Ισχυός

Σύγκριση Μεθόδων Πρόβλεψης Παραγωγής από Ανανεώσιμες Πηγές Ενέργειας

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Ευαγγελία Γκίκα

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

Αθήνα, Οκτώβριος 2024



Εθνικό Μετσοβίο Πολύτεχνειο Σχολή Ηλεκτρολογών Μηχανικών και Μηχανικών Υπολογιστών Τομέας Ηλεκτρικής Ισχυός

Σύγκριση Μεθόδων Πρόβλεψης Παραγωγής από Ανανεώσιμες Πηγές Ενέργειας

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Ευαγγελία Γκίκα

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

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή στις 18 Οκτωβρίου 2024

..... Παύλος Γεωργιλάκης Καθηγητής Ε.Μ.Π. Άρης–Ευάγγελος Δημέας Επίκ. Καθηγητής Ε.Μ.Π.

Νικολαΐδης Βασίλειος Επίκ. Καθηγητής Ε.Μ.Π.

.....

Αθήνα, Οκτώβριος 2024

.....

Ευαγγελία Γκίκα

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

Copyright © Ευαγγελία Γκίκα, 2024. Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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

ΠΕΡΙΛΗΨΗ

Σκοπός της παρούσας διπλωματικής εργασίας είναι η σύγκριση διαφόρων μοντέλων μηχανικής μάθησης για την βραχυπρόθεσμη πρόβλεψη της παραγωγής ισχύος από Φωτοβολταϊκά (Φ/Β) και ανεμογεννήτριες. Όλα τα μοντέλα βασίζονται σε τεχνητά νευρωνικά δίκτυα, συγκεκριμένα συγκρίνονται νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης, νευρωνικά δίκτυα με ανάδραση (NARX), καθώς και νευρωνικά δίκτυα μακράς βραχύχρονης μνήμης (LSTM).

Η εκπαίδευση και η αξιολόγηση των μοντέλων πραγματοποιείται με πραγματικά δεδομένα Φ/Β και αιολικής παραγωγής, καθώς και μετρήσεις μετεωρολογικών δεδομένων. Για την εκπαίδευση των μοντέλων χρησιμοποιείται αλγόριθμος βελτιστοποίησης που βασίζεται στη μείωση της κλίσης, ενώ δύο από τα μοντέλα επανεκπαιδεύονται με τον αλγόριθμο βελτιστοποίησης σμήνους σωματιδίων (particle swarm optimization). Τα μοντέλα συγκρίνονται βάσει ικανότητας πρόβλεψης Φ/Β και αιολικής παραγωγής, χρησιμοποιώντας ένα σύνολο κατάλληλων μετρητικών αξιολόγησης, καθώς και βάσει της υπολογιστικής πολυπλοκότητάς τους.

Η παρούσα διπλωματική εργασία καινοτομεί στην σύγκριση μοντέλων μηχανικής μάθησης, επεκτείνοντας την διαδικασία πρόβλεψης σε δύο διαφορετικές μεταβλητές (Φ/Β παραγωγή – αιολική παραγωγή), αλλά και εισάγοντας μεταευρετικούς αλγορίθμους βελτιστοποίησης και αρχιτεκτονικές βαθιάς μάθησης. Μέσω της αξιολόγησης και σύγκρισης των μοντέλων πρόβλεψης εξάγονται σημαντικά συμπεράσματα για τις ομοιότητες και τις διαφορές της Φ/Β και της αιολικής παραγωγής, καθώς και για τις αρχιτεκτονικές των νευρωνικών δικτύων και την ικανότητά τους στην βραχυπρόθεσμη πρόβλεψη παραγωγής ισχύος.

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ

Μηχανική μάθηση, τεχνητά νευρωνικά δίκτυα, φωτοβολταϊκή παραγωγή, αιολική παραγωγή, βραχυπρόθεσμη πρόβλεψη

ABSTRACT

The purpose of this thesis is to compare various machine learning models for shortterm power production forecasting from Photovoltaic (PV) systems and wind turbines. All models are based on artificial neural networks, specifically comparing feedforward neural networks, non-linear autoregressive networks with exogenous inputs (NARX), as well as Long Short-Term Memory (LSTM) networks.

The training and evaluation of the models are conducted using real data from PV and wind power production, as well as meteorological measurements. A gradient descent-based optimization algorithm is used for the training of the models, while two of the models are retrained using the particle swarm optimization algorithm. The models are compared based on their ability to predict PV and wind power production, using a set of appropriate evaluation metrics, as well as on their computational complexity.

This thesis innovates in the comparison of machine learning forecasting models, by extending the forecasting process to two different target variables (PV production – wind production), and by introducing metaheuristic optimization algorithms and deep learning architectures. Through the evaluation and comparison of the forecasting models, important conclusions are drawn regarding the similarities and differences between PV and wind production, as well as the architectures of neural networks and their ability in short-term power production forecasting.

KEY WORDS

Machine learning, artificial neural networks, photovoltaic power, wind power, short-term forecasting

ΕΥΧΑΡΙΣΤΙΕΣ

Η παρούσα διπλωματική εργασία εκπονήθηκε κατά το ακαδημαϊκό έτος 2023–2024 υπό την επίβλεψη του κ. Παύλου Γεωργιλάκη, Καθηγητή της σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Ε.Μ.Π. στον οποίο οφείλω ιδιαίτερες ευχαριστίες για την ανάθεσή της, δίνοντάς μου την ευκαιρία να ασχοληθώ με ένα τόσο ενδιαφέρον και δημιουργικό θέμα. Επίσης, θα ήθελα να ευχαριστήσω θερμά τον υποψήφιο διδάκτορα Μάρκο Κουσουνάδη – Κνούσεν, Υποψήφιος Διδάκτορας ΕΜΠ, για την υπομονή και την πολύτιμη βοήθεια και καθοδήγηση που μου παρείχε σε όλη τη διάρκεια εκπόνησης της εργασίας, καθώς και για τον πολύτιμο χρόνο που μου αφιέρωσε.

Τέλος, θα ήθελα να ευχαριστήσω τους γονείς μου Ιωάννη και Δέσποινα για τη στήριξή τους σε όλη τη διάρκεια των σπουδών μου στο Ε.Μ.Π., τους φίλους μου που ήταν πάντα δίπλα μου, καθώς και τον Γιάννη για τη συμπαράσταση και την αγάπη του σε όλες τις δυσκολίες που αντιμετώπισα.

ΠΕΡΙΕΧΟΜΕΝΑ

КЕФ	АЛАІО 1:	ΕΙΣΑΓΩΓΗ	17
1.1	Αντικείμεν	νο της διπλωματικής εργασίας	17
1.2	Βιβλιογρα	φική ανασκόπηση	19
1.3	Δομή διπλ	ωματικής εργασίας	20
КЕФ	АЛАІО 2:	ΠΡΟΒΛΕΨΗ Φ/Β ΚΑΙ ΑΙΟΛΙΚΗΣ ΠΑΡΑΓΩΓΗΣ	21
2.1	Γενικά		21
2.2	Φωτοβολι	ταϊκή παραγωγή	23
	2.2.1 Kú	ρια μέρη και τρόπος λειτουργίας Φ/Β συστημάτων	23
	2.2.2 По	αράγοντες που επηρεάζουν την Φ/Β παραγωγή	24
2.3	Αιολική π	αραγωγή	26
	2.3.1 Kú	όρια μέρη και τρόπος λειτουργίας ανεμογεννητριών	26
	2.3.2 Av	/εμογεννήτριες και ταχύτητα ανέμου	27
2.4	Αξία πρόβ	βλεψης Φ/Β και αιολικής παραγωγής	28
2.5	Μέθοδοι 1	τρόβλεψης Φ/Β και αιολικής παραγωγής	30
	2.5.1 D u	οσικές μέθοδοι	30
	2.5.2 Στ	ατιστικές μέθοδοι	30
	2.5.3 M	οντέλα μηχανικής μάθησης	31
2.6	Χρονική τ	αξινόμηση μοντέλων πρόβλεψης	31
	2.6.1 Bp	ναχυπρόθεσμη πρόβλεψη	31
	2.6.2 Ma	εσοπρόθεσμη πρόβλεψη	32
	2.6.3 M	ακροπρόθεσμη πρόβλεψη	32
КЕФ	АЛАІО 3:	ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ ΚΑΙ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	33
3.1	Γενικά		33
3.2	Δίκτυα FF	7NN	35
	3.2.1 Δc	ομή και τρόπος λειτουργίας FFNN	35
3.3	Δίκτυα ΝΑ	ARX	37
	3.3.1 Δα	ομή και τρόπος λειτουργίας NARX	37
3.4	Δίκτυα LS	STM	39
	3.4.1 Δc	ομή και τρόπος λειτουργίας LSTM	39
3.5	Αλγόριθμ	οι βελτιστοποίησης Αλγόριθμοι βελτιστοποίησης	41

3.5.1	Αλγόριθμοι μείωσης της κλίσης	41
3.5.2	Μεταευρετικοί αλγόριθμοι	
	3.5.2.1 Αλγόριθμος PSO	44

ΚΕΦΑΛΑΙΟ 4: ΑΝΑΛΥΣΗ ΚΑΙ ΑΞΙΟΛΟΓΗΣΗ ΤΩΝ ΜΟΝΤΕΛΩΝ 47 ΠΡΟΒΛΕΨΗΣ ΠΑΡΑΓΩΓΗΣ ΙΣΧΥΟΣ

4.1	Περιγραφή μοντέλων και κριτηρίων αξιολόγησης		47
4.2	Ανάλυ	ση και επεξεργασία Φ/Β και αιολικών δεδομένων	47
	4.2.1 4.2.2	Προέλευση δεδομένων Φ/Β και αιολικής παραγωγής Επεξεργασία δεδομένων	48 48
4.3	Μετρη	τικά αξιολόγησης	50
4.4	Βελτισ	ποποίηση παραμέτρων	52
	4.4.1	Βελτιστοποίηση παραμέτρων FFNN	53
	4.4.2	Βελτιστοποίηση παραμέτρων NARX	54
	4.4.3	Βελτιστοποίηση παραμέτρων LSTM	55
	4.4.4	Βελτιστοποίηση παραμέτρων ΑΝΝ – PSO	56
	4.4.5	Βελτιστοποίηση παραμέτρων NARX - PSO	57

КЕФА	ΛΑΙΟ 5: ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΣΥΓΚΡΙΣΗ ΜΟΝΤΕΛΩΝ	61
5.1	Αποτελέσματα Φ/Β παραγωγής	61
5.2	Αποτελέσματα αιολικής παραγωγής	69

КЕФА	ΑΑΙΟ 6: ΕΠΙΛΟΓΟΣ	77
6.1	Σύνοψη εργασίας και συμπεράσματα	77
6.2	Προτάσεις μελλοντικής επέκτασης	78

ΚΕΦΑΛΑΙΟ 7: ΒΙΒΛΙΟΓΡΑΦΙΑ 81

Κατάλογος Σχημάτων

Σχήμα 2.1: Η συνολική εγκατεστημένη Φ/Β ισχύς στην Ελλάδα.	21
Σχήμα 2.2: Η συνολική σωρευτική εγκατεστημένη αιολική ισχύς στην Ελλάδα ανά έτος	22
Σχήμα 2.3: Παραγωγή Φ/Β ισχύος για ημέρα με ηλιοφάνεια και για ημέρα με νεφοκάλυψη	25
Σχήμα 2.4: Κύρια μέρη ανεμογεννήτριας	27
Σχήμα 2.5: Θεωρητική καμπύλη αιολικής ισχύος – ταχύτητας ανέμου	28
Σχήμα 3.1: (α) Δομή FFNN με Κ μεταβλητές εισόδου, ένα κρυφό στρώμα, και ένα νευρώνα στο στρώμα εξόδου. (β) Μοντέλο νευρώνα FFNN.	36
Σχήμα 3.2: Διαγράμματα βασικών συναρτήσεων ενεργοποίησης. (α) Σιγμοειδής Συνάρτηση. (β) Υπερβολική Εφαπτομένη. (γ) Συνάρτηση ReLU. (δ) Ακτινική Συνάρτηση Βάσης	37
Σχήμα 3.3: Δομή του μοντέλου NARX με <i>Κ</i> εξωγενείς εισόδους και Ι ανατροφοδοτήσεις από προηγούμενες τιμές εξόδου	38
Σχήμα 3.4: Κελί LSTM χωρίς επιλεκτική πύλη	40
Σχήμα 3.5: Κελί LSTM με επιλεκτική πύλη	40
Σχήμα 3.6: Τιμές αντικειμενικής συνάρτησης κατά τη βελτιστοποίηση βάσει αλγορίθμου μείωσης της κλίσης για διαφορετικά μεγέθη βήματος	42
Σχήμα 5.1: Σύγκριση των πραγματικών τιμών ισχύος με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης Φ/Β παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με πλήρη ηλιοφάνεια.	62
Σχήμα 5.2: Σύγκριση των πραγματικών τιμών ισχύος με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης Φ/Β παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με ηλιοφάνεια και λίγες νεφώσεις κατά την διάρκεια των μεσημεριανών ωρών.	63
Σχήμα 5.3: Σύγκριση των πραγματικών τιμών ισχύος με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης Φ/Β παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με έντονες διακυμάνσεις στην παραγωγή και πλήρη νεφοκάλυψη κατά τις μεσημεριανές ώρες.	63
Σχήμα 5.4: Σύγκριση των πραγματικών τιμών ισχύος με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης Φ/Β παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με έντονες διακυμάνσεις στην παραγωγή και γεφοκάλυψη καθόλη τη διάρκεια της ημέρας	05
Σχήμα 5.5: Σύγκριση της πραγματικής παραγωγής με τις τιμές των προβλέψεων των μοντέλων της Φ/Β παραγωγής σε γρονική διάρκεια 24 ωρών.	64 65
Σχήμα 5.6: Σύγκριση των πραγματικών τιμών ισχύος, με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης αιολικής παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με χαμηλή	00
παραγωγη. Στάτου 5.7 Σάτου το	69
Σχημα 5.7: Συγκριση των πραγματικών τιμών ισχύος, με τις προρλεπομενες τιμές των μοντελών πρόβλεψης αιολικής παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με μέση παραγωγή.	70
Σχήμα 5.8: Σύγκριση των πραγματικών τιμών ισχύος, με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης αιολικής παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με υψηλή	
παραγωγη.	70
Σχημα 5.9: Συγκριση της πραγματικής παραγωγής με τις τιμές των προβλέψεων των μοντέλων της αιολικής παραγωγής σε χρονική διάρκεια 24 ωρών.	71

Κατάλογος Πινάκων

Πίνακας 3.1: Συχνά χρησιμοποιούμενες συναρτήσεις ενεργοποίησης των FFNN.	36
Πίνακας 4.1: Βέλτιστες τιμές των παραμέτρων του μοντέλου FFNN για την πρόβλεψη Φ/Β και αιολικής παραγωγής.	54
Πίνακας 4.2: Βέλτιστες τιμές των παραμέτρων του μοντέλου ΝΑRΧ για την πρόβλεψη Φ/Β και αιολικής παραγωγής	55
Πίνακας 4.3: Βέλτιστες τιμές των παραμέτρων του μοντέλου LSTM για την πρόβλεψη Φ/Β και αιολικής παραγωγής	56
Πίνακας 4.4: Βέλτιστες τιμές των παραμέτρων του μοντέλου FFNN-PSO για την πρόβλεψη Φ/Β και αιολικής παραγωγής.	57
Πίνακας 4.5: Βέλτιστες τιμές των παραμέτρων του μοντέλου NARX-PSO για την πρόβλεψη Φ/Β και αιολικής παραγωγής.	58
Πίνακας 5.1: Τελικά αποτελέσματα των μοντέλων πρόβλεψης Φ/Β παραγωγής	67
Πίνακας 5.2: Τελικά αποτελέσματα των μοντέλων πρόβλεψης αιολικής παραγωγής	74

ΚΕΦΑΛΑΙΟ 1

ΕΙΣΑΓΩΓΗ

1.1 ΑΝΤΙΚΕΙΜΕΝΟ ΤΗΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία εστιάζει στην πρόβλεψη της παραγωγής από φωτοβολταϊκά (Φ/Β) και αιολικά συστήματα, χρησιμοποιώντας μοντέλα που βασίζονται στα τεχνητά νευρωνικά δίκτυα. Η επιτακτική ανάγκη μείωσης των εκπομπών CO₂ για την καταπολέμηση της κλιματικής αλλαγής, καθώς και η πιθανή εξάντληση των ορυκτών καυσίμων στο μέλλον, έχουν οδηγήσει σε αυξανόμενη διείσδυση Ανανεώσιμων Πηγών Ενέργειας (ΑΠΕ) στα Συστήματα Ηλεκτρικής Ενέργειας [1]. Τα τελευταία χρόνια, η παραγωγή ηλεκτρικής ενέργειας από Φ/Β και αιολικούς σταθμούς έχει αποκτήσει σημαντικό μερίδιο. Ωστόσο, η διείσδυση των Φ/Β και αιολικών συστημάτων αυξάνει την αβεβαιότητα και τη μεταβλητότητα των ΣΗΕ. Η παραγωγή ενέργειας από Φ/Β και ανεμογεννήτριες (Α/Γ) εξαρτάται από τις καιρικές συνθήκες, κυρίως την προσπίπτουσα ηλιακή ακτινοβολία και την ταχύτητα του ανέμου, αντίστοιχα. Εξαιτίας της ασταθούς φύσης των καιρικών συνθηκών, η παραγωγή Φ/Β και αιολικής ενέργειας είναι εν μέρει ανεξέλεγκτη και χαρακτηρίζεται από υψηλή στοχαστικότητα [2].

Οι μεταβολές στην προσπίπτουσα ηλιακή ακτινοβολία αλλά και στην ταχύτητα του ανέμου είναι συνεχείς και μη ελεγχόμενες, και σε συνδυασμό με την αβεβαιότητα των βραχυπρόθεσμων μετεωρολογικών προβλέψεων, καθιστούν την πρόβλεψη της Φ/Β και της αιολικής παραγωγής μία μεγάλη πρόκληση. Η ορθή πρόβλεψη της Φ/Β και της αιολικής παραγωγής έχει μεγάλη σημασία, καθώς όσο μεγαλύτερο ποσοστό καταλαμβάνει η παραγωγή από Φ/Β και Α/Γ στο μερίδιο της συνολικής παραγωγής ηλεκτρικής ισχύος, τόσο περισσότερο επηρεάζει τον προγραμματισμό για την κάλυψη των εθνικών ενεργειακών αναγκών [3]. Η απόκλιση των προβλέψεων από τις πραγματικές τιμές της παραγώμενης Φ/Β και αιολικής ισχύος οδηγούν στη μείωση της απόδοσης του συστήματος, στην εξάρτηση από συμβατικές μονάδες παραγωγής, στη σπατάλη περίσσειας παραγώμενης ενέργειας και στην αύξηση του κόστους παραγωγής της ηλεκτρικής ενέργειας [4].

Στην προσπάθεια να περιοριστούν τα μειονεκτήματα που απορρέουν από τη στοχαστικότητα της Φ/Β και αιολικής παραγωγής, έχουν αναπτυχθεί πολυάριθμες μεθόδοι πρόβλεψης που έχουν ως στόχο την προσέγγιση της πραγματικής Φ/Β και αιολικής παραγωγής. Οι μέθοδοι πρόβλεψης παραγωγής ταξινομούνται στις φυσικές μεθόδους, που αξιοποιούν μαθηματικές εξισώσεις και προσομοιώσεις του φυσικού περιβάλλοντος, στις στατιστικές μεθόδους, οι οποίες εξάγουν σχέσεις από ιστορικά δεδομένα με σκοπό την προσέγγιση της μελλοντικής μεταβολής των μεγεθών, και στα μοντέλα μηχανικής μάθησης, που αξιοποιούν αλγορίθμους για να βρουν μοτίβα και συσχετίσεις σε μεγάλα σύνολα δεδομένων, ώστε να παράγουν τις βέλτιστες προβλέψεις [5]. Η παραγωγή προβλέψεων δύναται να προκύψει για διαφορετικούς χρονικούς ορίζοντες. Εκτός από τους μακροπρόθεσμους και μεσοπρόθεσμους χρονικούς ορίζοντες, τα τελευταία χρόνια έχει δοθεί ιδιαίτερη έμφαση στην βραχυπρόθεσμη πρόβλεψη. Αυτού του είδους η πρόβλεψη αφορά χρονικούς ορίζοντες έως και 24 ωρών, και είναι ιδιαίτερα σημαντική για τον βέλτιστο χειρισμό και έλεγχο των Φ/Β και αιολικών συστημάτων σε πραγματικό χρόνο. Η βραχυπρόθεσμη πρόβλεψη συνδέεται άμεσα με τη χρήση μοντέλων μηχανικής μάθησης, τα οποία είναι ικανά να αποτυπώνουν πολύπλοκες σχέσεις μεταξύ εισόδου και εξόδου με υψηλή αποδοτικότητα και λεπτομέρεια, χωρίς να απαιτούν υπερβολικά μεγάλους υπολογιστικούς πόρους [6].

Στην παρούσα διπλωματική εργασία συγκρίνονται πέντε μοντέλα μηχανικής μάθησης, τα οποία εκπαιδεύονται αποκλειστικά με ιστορικά δεδομένα παραγωγής ισχύος και μετεωρολογικών μεταβλητών, με σκοπό την βραχυπρόθεσμη πρόβλεψη της Φ/Β και αιολικής παραγωγής σε χρονικό ορίζοντα μίας ώρας. Όλα τα μοντέλα βασίζονται σε τεχνητά νευρωνικά δίκτυα και εκπαιδεύονται με χρήση αλγορίθμου βελτιστοποίησης μείωσης της κλίσης, ενώ δύο από αυτά επανεκπαιδεύονται με τον αλγόριθμο βελτιστοποίησης σμήνους σωματιδίων (Particle Swarm Optimization – PSO). Στα συγκρινόμενα μοντέλα συμπεριλαμβάνεται μοντέλο που βασίζεται στη βαθιά μάθηση, συγκεκριμένα, το δίκτυο μακράς βραχύχρονης μνήμης (Long Short-Term Memory – LSTM). Για την εξασφάλιση της αποτελεσματικής εκπαίδευσης των μοντέλων πρόβλεψης Φ/Β και αιολικής παραγωγής και την επίτευξη των καλύτερων δυνατών προβλέψεων, γίνεται χρήση δεδομένων που προέρχονται από πραγματικούς σταθμούς Φ/Β και αιολικής παραγωγής. Τα δεδομένα είναι αντιπροσωπευτικά του υπό εξέταση προβλήματος, υπάρχει επαρκής όγκος δείγματος, και υπόκεινται στην κατάλληλη προ-επεξεργασία ώστε να μην περιέχουν ακραίες ή κενές τιμές.

Αρχικά γίνεται βελτιστοποίηση των υπερπαραμέτρων του κάθε μοντέλου, ξεχωριστά, ώστε να εξασφαλιστεί η βέλτιστη απόδοση. Στη συνέχεια, κάθε μοντέλο εκπαιδεύεται βάσει των βέλτιστων υπερπαραμέτρων σε δεδομένα Φ/Β και αιολικής παραγωγής. Με το πέρας της εκπαίδευσης, γίνεται η παραγωγή προβλέψεων Φ/Β και αιολικής ισχύος από κάθε μοντέλο με χρονικό ορίζοντα μίας ώρας. Για την ολοκληρωμένη και αξιόπιστη σύγκριση όλων των μοντέλων πρόβλεψης χρησιμοποιούνται μία σειρά από μετρητικά αξιολόγησης, ώστε να προκύψουν τα μοντέλα με την βέλτιστη απόδοση στην βραχυπρόθεσμη πρόβλεψη Φ/Β και αιολικής παραγωγής. Ταυτόχρονα, τα μοντέλα αξιολογούνται και συγκρίνονται βάσει της υπολογιστικής πολυπλοκότητάς τους.

Βασική καινοτομία στην παρούσα διπλωματική εργασία είναι η σύγκριση της βραχυπρόθεσμης πρόβλεψης Φ/Β και αιολικής παραγωγής, δηλαδή εκτός από την σύγκριση των μοντέλων μηχανικής μάθησης για την κάθε παραγωγή ξεχωριστά, γίνεται και σύγκριση της πρόβλεψης μεταξύ των δύο παραγωγών. Επιπλέον, στην παρούσα διπλωματική γίνεται χρήση και ενός μεταευρετικού αλγορίθμου βελτιστοποίησης, καθώς δύο από τα μοντέλα μηχανικής μάθησης επανεκπαιδεύονται με αυτόν τον αλγόριθμο ώστε να αξιολογηθούν οι δυνατότητες εκπαίδευσής τους έναντι των κλασικών αλγορίθμων που βασίζονται στη μείωση της κλίσης. Τέλος, γίνεται δοκιμή ενός νέου μετρητικού αξιολόγησης [7], το οποίο προτάθηκε πρόσφατα για την ποσοτικοποίηση του μέσου ποσοστιαίου σφάλματος, με σκοπό τον έλεγχο της συμπεριφοράς του.

1.2 ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ

Η ακριβής πρόβλεψη της Φ/Β και αιολικής παραγωγής, ιδιαίτερα σε βραχυπρόθεσμους χρονικούς ορίζοντες, είναι ζωτικής σημασίας για την αποδοτική λειτουργία των ΣΗΕ και την απρόσκοπτη ένταξη των ΑΠΕ στο ενεργειακό μείγμα. Τα τελευταία χρόνια, τα μοντέλα μηχανικής μάθησης έχουν σημειώσει σημαντική πρόοδο, χάρη στην ικανότητά τους να ανακαλύπτουν περίπλοκα μοτίβα συσχετίσεων μεταξύ των δεδομένων. Σε αυτό το πλαίσιο, παρουσιάζονται ενδεικτικά ορισμένες εργασίες από τη διαθέσιμη βιβλιογραφία που εστιάζουν στην σύγκριση μοντέλων μηχανικής μάθησης για την βραχυπρόθεσμη πρόβλεψη της Φ/Β και αιολικής παραγωγής.

Στην εργασία των D. Markovics και M.J. Mayer [8], οι συγγραφείς συγκρίνουν 24 μοντέλα μηχανικής μάθησης για την πρόβλεψη της παραγωγής ενέργειας από Φ/Β συστήματα βασισμένα σε αριθμητικές προβλέψεις καιρού (Numerical Weather Predictions - NWP). Τα δεδομένα καλύπτουν δύο χρόνια με χρονική ανάλυση 15 λεπτών, από 16 Φ/Β πάρκα στην Ουγγαρία. Τα πιο ακριβή μοντέλα που εντοπίστηκαν, ήταν η παλινδρόμηση τύπου kernel ridge και το πολυεπίπεδο perceptron (Multilayer Perceptron - MLP), με αύξηση της ακρίβειας πρόβλεψης κατά 44,6% σε σχέση με τα μοντέλα εμμονής (Persistence). Η επιλογή των κατάλληλων δεδομένων εισόδου και η βελτιστοποίηση των υπερπαραμέτρων έπαιξαν καθοριστικό ρόλο στη μείωση των σφαλμάτων πρόβλεψης, με τη Ρίζα του Μέσου Τετραγωνικού Σφάλματος (Root Mean Squared Error - RMSE) να μειώνεται κατά 13,9% σε σύγκριση με απλά γραμμικά μοντέλα.

Στην εργασία των U.K. Das, K.S. Tey, M. Seyedmahmoudian, S. Mekhilef, M.Y. Idris, W. Van Deventer, B. Horan, και A. Stojcevski [9], οι συγγραφείς παρέχουν μια λεπτομερή επισκόπηση των μοντέλων πρόβλεψης παραγωγής ενέργειας από Φ/Β συστήματα. Εξετάζουν την άμεση πρόβλεψη παραγωγής Φ/Β ισχύος με τη χρήση ιστορικών δεδομένων και μετεωρολογικών παραμέτρων, όπως η ηλιακή ακτινοβολία και η θερμοκρασία. Παρουσιάζονται και αναλύονται τόσο στατιστικά όσο και μοντέλα μηχανικής μάθησης, ενώ ιδιαίτερη έμφαση δίνεται στη βελτιστοποίηση των μοντέλων πρόβλεψης για τη βελτίωση της ακρίβειας, λαμβάνοντας υπόψη τις προκλήσεις και τα οφέλη της ενσωμάτωσης των Φ/Β συστημάτων στα ΣΗΕ.

Στην εργασία των Aditya Chaudhary, Akash Sharma, Ayush Kumar, Karan Dikshit και Neeraj Kumar [10], οι συγγραφείς προτείνουν τη χρήση τριών μοντέλων μηχανικής μάθησης, του Support Vector Machine (SVM), των δέντρων αποφάσεων, και του Random Forest, για τη βραχυπρόθεσμη πρόβλεψη της αιολικής ισχύος. Τα δεδομένα που χρησιμοποιήθηκαν για την εκπαίδευση και τη δοκιμή των μοντέλων προέρχονται από την περιοχή της Καλκούτας. Τα αποτελέσματα δείχνουν ότι το Random Forest και τα δέντρα αποφάσεων παρέχουν μεγαλύτερη ακρίβεια πρόβλεψης, με τις τιμές του Μέσου Απόλυτου Ποσοστιαίου Σφάλματος (Mean Absolute Percentage Error – MAPE) να είναι 1,889% και 1,126% για το Random Forest και τα δέντρα αποφάσεων, αντίστοιχα, σε σύγκριση με το SVM που παρουσίασε MAPE ίσο με 20,8346%.

Στην εργασία των Qin Chen και Komla A. Folly [11], οι συγγραφείς συγκρίνουν τρεις μεθόδους βραχυπρόθεσμης πρόβλεψης αιολικής ενέργειας. Οι μέθοδοι που συγκρίθηκαν είναι η μέθοδος χρονοσειρών Auto-Regressive Moving Average (ARMA), τα τεχνητά νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης (Feed Forward Neural Networks – FFNNs), και ένα υβριδικό μοντέλο νευρωνικών δικτύων και ασαφούς (fuzzy) λογικής, το σύστημα Adaptive Neuro-Fuzzy Inference Systems (ANFIS). Τα αποτελέσματα δείχνουν ότι για υπερ-βραχυπρόθεσμη πρόβλεψη (χρονικός ορίζοντας μικρότερος της μίας ώρας), όλες οι μέθοδοι έχουν παρόμοια

απόδοση. Ωστόσο, για βραχυπρόθεσμη πρόβλεψη, η μέθοδος ARMA αποδείχθηκε πιο ακριβής από τα FFNNs και ANFIS, με μικρότερα σφάλματα RMSE. Τα αποτελέσματα υποδεικνύουν ότι η βελτιστοποίηση των παραμέτρων της μεθόδου ARMA έπαιξε καθοριστικό ρόλο στη βελτίωση της απόδοσης για μικρά χρονικά διαστήματα.

1.3 ΔΟΜΗ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία οργανώνεται σε 7 κεφάλαια:

- Στο Κεφάλαιο 2 παρουσιάζεται η πρόβλεψη της Φ/Β και αιολικής παραγωγής, η αξία της πρόβλεψης της παραγωγής από ΑΠΕ, οι μέθοδοι πρόβλεψης και η ταξινόμησή τους βάσει του χρονικού ορίζοντα πρόβλεψης.
- Στο Κεφάλαιο 3 δίνεται το θεωρητικό υπόβαθρο γύρω από τα τεχνητά νευρωνικά δίκτυα. Παρουσιάζεται το μαθηματικό μοντέλο τους και αναλύεται ο τρόπος λειτουργίας τους. Περιγράφεται ο ρόλος των αντικειμενικών συναρτήσεων και των αλγορίθμων βελτιστοποίησης. Γίνεται παρουσίαση του αλγορίθμου μείωσης της κλίσης και του αλγορίθμου βελτιστοποίησης σμήνους σωματιδίων.
- Στο Κεφάλαιο 4 περιγράφονται τα μοντέλα πρόβλεψης, τα κριτήρια αξιολόγησης, καθώς και η διαδικασία ανάλυσης και επεξεργασίας των δεδομένων. Περιγράφονται επίσης τα μετρητικά αξιολόγησης και παρουσιάζονται τα αποτελέσματα της βελτιστοποίησης παραμέτρων για όλα τα μοντέλα.
- Στο Κεφάλαιο 5 παρουσιάζονται τα αποτελέσματα της πρόβλεψης Φ/Β και αιολικής παραγωγής, γίνεται σύγκριση της απόδοσης των μοντέλων, και καταγράφονται τα συμπεράσματα για την Φ/Β και την αιολική παραγωγή.
- Στο Κεφάλαιο 6 γίνεται η σύνοψη της παρούσας διπλωματικής εργασίας, καταγράφονται τα συνολικά συμπεράσματα της, και προτείνονται ορισμένες πιθανές επεκτάσεις της.
- Στο Κεφάλαιο 7 περιλαμβάνει τη βιβλιογραφία που χρησιμοποιήθηκε για την εκπόνηση της παρούσας διπλωματικής εργασίας.

ΚΕΦΑΛΑΙΟ 2

ΠΡΟΒΛΕΨΗ Φ/Β ΚΑΙ ΑΙΟΛΙΚΗΣ ΠΑΡΑΓΩΓΗΣ

2.1 ΓΕΝΙΚΑ

Τα τελευταία χρόνια, λόγω της σοβαρής κλιματικής αλλαγής και της αυξανόμενης ανάγκης για βιώσιμες μεθόδους παραγωγής ηλεκτρικής ενέργειας, παρατηρείται μια σαφής στροφή προς τις Ανανεώσιμες Πηγές Ενέργειας (ΑΠΕ) ως κύρια πηγή παραγωγής. Σε αυτό το πλαίσιο, υπάρχει μια ξεκάθαρη προτίμηση για την υδροηλεκτρική, αιολική και ηλιακή ενέργεια, καθώς το 2022 αυτές οι τρεις τεχνολογίες αντιπροσώπευσαν το 99,15% της συνολικής εγκατεστημένης ισχύος παγκοσμίως μεταξύ των ΑΠΕ [12], ενώ το 2023 οι ΑΠΕ συνεισέφεραν το 30,2% της συνολικής παγκόσμιας παραγωγής ηλεκτρικής ενέργειας [13]. Μέχρι το 2028, η ηλιακή και αιολική παραγωγή θα αποτελούν το 95% της παγκόσμιας αύξησης παραγωγής ενέργειας που προέρχεται από ΑΠΕ [14]. Πολλά παραδείγματα δείχνουν Συστήματα Ηλεκτρικής Ενέργειας (ΣΗΕ) που βασίζονται σε ΑΠΕ και λειτουργούν αξιόπιστα με μερίδια ηλεκτρικής ενέργειας από ανανεώσιμες πηγές έως και 100%. Η Ελλάδα λειτουργούσε με 100% ανανεώσιμες πηγές ενέργειας για 5 ώρες τον Οκτώβριο του 2022 και τον Ιούλιο του 2023 σημείωσε 87 συνεχόμενες ώρες χωρίς λιγνίτη και με μερίδια ΑΠΕ έως και 84% [15]. Στην Ελλάδα, το 2021 οι Φ/Β σταθμοί συνέβαλαν κατά 23,72% στη συνολική παραγόμενη ενέργεια από ΑΠΕ, το 2022 το ποσοστό της εγχώριας εγκατεστημένης ισχύος από Φ/B σταθμούς έφτασε το 39,78% της συνολικής ισχύος ΑΠΕ [16], ενώ το 2023, παρατηρήθηκε σημαντική αύξηση της παραγωγής ηλεκτρικής ενέργειας μέσω Φ/Β στην Ελλάδα, φτάνοντας στο 19% της συνολικής εγχώριας παραγωγής [15]. Στο Σχήμα 2.1 φαίνεται η εξέλιξη της συνολικής εγκατεστημένης Φ/Β ισχύος στην Ελλάδα από το 2010 έως το 2023 [17].



Σχήμα 2.1: Η συνολική εγκατεστημένη Φ/Β ισχύς στην Ελλάδα.



Συνολική Ισχύς στο δίκτυο ανά ετός

Σχήμα 2.2: Η συνολική σωρευτική εγκατεστημένη αιολική ισχύς στην Ελλάδα ανά έτος

Η εκμετάλλευση της ενέργειας του ανέμου από τον άνθρωπο αποτελεί μία πρακτική που βρίσκει τις ρίζες της στην αρχαιότητα. Χαρακτηριστικά παραδείγματα εκμετάλλευσης της αιολικής ενέργειας είναι τα ιστιοφόρα και οι ανεμόμυλοι. Σήμερα, για την αξιοποίηση της αιολικής ενέργειας χρησιμοποιούνται οι ανεμογεννήτριες (Α/Γ). Οι ανεμογεννήτριες είναι μηχανές οι οποίες μετατρέπουν την κινητική ενέργεια του ανέμου σε ηλεκτρική ενέργεια. Η ενέργεια αυτή αποτελεί μια ελκυστική λύση στο πρόβλημα της ηλεκτροπαραγωγής. Το «καύσιμο» είναι άφθονο, αποκεντρωμένο και δωρεάν. Δεν εκλύονται αέρια θερμοκηπίου και άλλοι ρύποι, και οι επιπτώσεις στο περιβάλλον είναι μικρές σε σύγκριση με τα εργοστάσια ηλεκτροπαραγωγής από συμβατικά καύσιμα. Επίσης, τα οικονομικά οφέλη μιας περιοχής από την ανάπτυξη της αιολικής βιομηχανίας είναι αξιοσημείωτα.

Στο Σχήμα 2.2 φαίνεται η εξέλιξη της συνολικής εγκατεστημένης αιολικής ισχύος στην Ελλάδα από το 2007 έως το 2023 [18]. Στην Ελλάδα, η συνολική εγκατεστημένη αιολική ισχύς το 2020 έφτανε το 15% της συνολικής παραγωγής ηλεκτρικής ισχύος [19]. Η αιολική ενέργεια στην Ελλάδα βρίσκεται σε ανοδική πορεία, καθώς στο τέλος του 2023 η συνολική σωρευτική εγκατεστημένη αιολική ισχύς ξεπέρασε τα 5 GW, σύμφωνα με τα στοιχεία που ανακοίνωσε η Ελληνική Επιστημονική Ένωση Αιολικής Ενέργειας, και σύμφωνα με όσα αποτυπώνονται στο Σχήμα 2.2. Η στατιστική του 2023 καταγράφει τη σύνδεση 153 νέων ανεμογεννητριών, με συνολική ισχύ 542,8 MW, αντιπροσωπεύοντας αύξηση 11,6% σε σχέση με το 2022 [20].

Στο τέλος του 2023, σχεδόν 200 κυβερνήσεις συμφώνησαν για την ανάγκη τριπλασιασμού της παγκόσμιας εγκατεστημένης ισχύος ΑΠΕ και διπλασιασμού των βελτιώσεων ενεργειακής αποδοτικότητας έως το 2030, ώστε να επιτευχθεί η πορεία που περιορίζει την παγκόσμια αύξηση της θερμοκρασίας στους 1,5°C. Η αιολική ενέργεια, η οποία έχει γίνει ολοένα και πιο οικονομικά αποδοτική, αναγνωρίστηκε στο τελικό κείμενο απόφασης ως βασική τεχνολογία μετριασμού της κλιματικής αλλαγής. Το τελευταίο έτος δίνει λόγους για

ελπίδα ότι η αιολική ενέργεια μπορεί να συμβάλει σημαντικά σε αυτόν τον στόχο. Υπάρχει αυξανόμενη πολιτική φιλοδοξία για την παγκόσμια ενεργειακή μετάβαση. Το 2023, εγκαταστάθηκαν παγκοσμίως 117 GW νέας αιολικής ενέργειας, αριθμός ρεκόρ που αντιπροσωπεύει αύξηση 50% σε σχέση με την προηγούμενη χρονιά, γεγονός που αντικατοπτρίζει την ανθεκτικότητα του κλάδου παρά τις παρατεταμένες δυσκολίες στην εφοδιαστική αλυσίδα και τις μακροοικονομικές συνθήκες. Η μετατόπιση της καθαρής ενέργειας στο επίκεντρο της εθνικής βιομηχανικής πολιτικής για τις μεγάλες οικονομίες, σε συνδυασμό με την αυξανόμενη δυναμική στην υπεράκτια αιολική ενέργεια και τις υποσχόμενες φιλοδοξίες μεταξύ των αναδυόμενων αγορών και των αναπτυσσόμενων οικονομιών, έχει προκαλέσει μια πιο αισιόδοξη πρόβλεψη ανάπτυξης για τις συνολικές νέες προσθήκες αιολικής ενέργειας έως το 2030, αυξημένες κατά 107 GW, σε σύγκριση με την πρόβλεψη του 2023 [21].

2.2 ΦΩΤΟΒΟΛΤΑΪΚΗ ΠΑΡΑΓΩΓΗ

2.2.1 Κύρια μέρη και τρόπος λειτουργίας Φ/Β συστημάτων

Τα κύρια μέρη και η λειτουργία ενός Φ/Β συστήματος περιλαμβάνουν τα εξής [22]:

- Φ/Β πάνελ: Ηλιακοί συλλέκτες που απορροφούν την ηλιακή ακτινοβολία. Χρησιμοποιώντας τα ημιαγώγιμα υλικά από τα οποία είναι κατασκευασμένα, όπως το πυρίτιο, μετατρέπουν την ηλιακή ενέργεια σε ηλεκτρικό ρεύμα μέσω του Φ/Β φαινομένου. Όταν η ηλιακή ακτινοβολία προσπίπτει στα ημιαγώγιμα υλικά, διεγείρονται τα ηλεκτρόνια, δημιουργώντας έτσι ηλεκτρικό ρεύμα. Αυτό το συνεχές ρεύμα (DC) στη συνέχεια μεταφέρεται στον αντιστροφέα, όπου μετατρέπεται σε εναλλασσόμενο ρεύμα (AC) για χρήση στο ηλεκτρικό δίκτυο ή σε οικιακές εφαρμογές.
- Αντιστροφέας (inverter): Διαθέτει είσοδο συνεχούς ρεύματος (DC) και έξοδο εναλλασσόμενου ρεύματος (AC), ώστε να είναι δυνατή η έγχυση της παραγόμενης ενέργειας στο δίκτυο μέσω του μετασχηματιστή χαμηλής τάσης/μέσης τάσης (M/Σ XT/MT).
- Μετασχηματιστής Χαμηλής Τάσης/Μέσης Τάσης (Μ/Σ ΧΤ/ΜΤ): Ανυψώνει το επίπεδο τάσης από τη χαμηλή στη μέση τάση για να μπορεί η ενέργεια να εισαχθεί στο δίκτυο.
- Κτίριο τοπικών χειρισμών: Πριν την ανύψωση της τάσης, τα τοπικά φορτία, όπως τα μετρητικά όργανα και ο φωτισμός του σταθμού τροφοδοτούνται από την παραγόμενη ενέργεια. Στο κτίριο αυτό τοποθετείται επίσης ο απαραίτητος εξοπλισμός για τον έλεγχο του Φ/Β σταθμού, όπως διακόπτες ισχύος, αποζεύκτες και συστήματα για την απρόσκοπτη λειτουργία του σταθμού, όπως τα συστήματα αδιάλειπτης παροχής ενέργειας (UPS) και οι τοπικές μπαταρίες.

Επιπλέον, όσον αφορά τα Φ/Β συστήματα στέγης, είναι απλούστερα και σχεδιασμένα για μικρότερη κλίμακα, με την κύρια διαφορά να έγκειται στην έλλειψη μεγάλων υποδομών, όπως οι μετασχηματιστές και τα κτίρια τοπικών χειρισμών που συναντώνται στους μεγάλους Φ/Β σταθμούς. Τα Φ/Β συστήματα στέγης περιλαμβάνουν Φ/Β πάνελ, αντιστροφέα και ένα

μετρητή ενέργειας ο οποίος καταγράφει την παραγόμενη ενέργεια και την ενέργεια που καταναλώνεται από το σπίτι. Σε περίπτωση που το Φ/Β σύστημα είναι διασυνδεδεμένο με το δίκτυο, ο μετρητής μπορεί να μετρά την ενέργεια που διοχετεύεται στο δίκτυο ή που λαμβάνεται από αυτό. Τέλος, στα Φ/Β συστήματα στέγης περιλαμβάνεται ο πίνακας διανομής όπου το παραγόμενο εναλλασσόμενο ρεύμα (AC) διανέμεται στα διάφορα κυκλώματα του σπιτιού και σε περίπτωση περίσσειας παραγόμενης ηλεκτρικής ενέργειας αυτή διοχετεύεται πίσω στο ηλεκτρικό δίκτυο.

2.2.2 Παράγοντες που επηρεάζουν την Φ/Β παραγωγή

Η παραγωγή ενός Φ/Β σταθμού εξαρτάται από πολλούς ανεξέλεγκτους εξωτερικούς παράγοντες, όπως οι μετεωρολογικές συνθήκες που μεταβάλλονται δυναμικά. Η πρόβλεψη της Φ/Β παραγωγής είναι απαραίτητη αλλά και δύσκολη λόγω της φύσης αυτών των παραγόντων. Οι βασικότεροι από αυτούς περιγράφονται παρακάτω:

- Ηλιακή Ακτινοβολία: Η ηλιακή ακτινοβολία είναι η πιο κρίσιμη μεταβλητή για την παραγωγή ενός Φ/Β σταθμού, επηρεαζόμενη έντονα από την ηλιοφάνεια και τις τοπικές νεφώσεις. Η απόδοση των ηλιακών συλλεκτών μεγιστοποιείται όταν η επιφάνειά τους είναι κάθετη στις ηλιακές ακτίνες, συνθήκη που ικανοποιείται σπάνια λόγω της συνεχούς μεταβολής της θέσης του ήλιου. Για την μεγιστοποίηση της απορρόφησης της ηλιακής ακτινοβολίας έχουν αναπτυχθεί Φ/Β πάνελ νέας τεχνολογίας με δυνατότητα περιστροφής, που διατηρούν την κατάλληλη γωνία πρόσπτωσης και αυξάνουν την παραγωγή έως και 50% το καλοκαίρι και 300% το χειμώνα [23].
- Θερμοκρασία: Η θερμοκρασία επηρεάζει σημαντικά την απόδοση των Φ/Β πάνελ, τα οποία λειτουργούν ιδανικά στους 25°C. Όταν η θερμοκρασία υπερβαίνει αυτή την τιμή, η παραγωγή ισχύος μειώνεται λόγω της αύξησης του ρυθμού ανασυνδυασμού των φορέων στον ημιαγωγό. Αυτό προκαλεί μια μικρή αύξηση στο ρεύμα, αλλά συνοδεύεται από μεγαλύτερη πτώση τάσης, οδηγώντας σε χαμηλότερη ισχύ εξόδου. Σε ηλιόλουστες ημέρες, ειδικά το καλοκαίρι, η θερμοκρασία των συλλεκτών μπορεί να υπερβεί τους 65°C, προκαλώντας μείωση της απόδοσης έως και 0,5% για κάθε βαθμό πάνω από τους 25°C [23].
- Νεφοκάλυψη: Η νεφοκάλυψη είναι ένας από τους σημαντικότερους παράγοντες που επηρεάζει την απόδοση των Φ/Β συστημάτων, καθώς επηρεάζει την ποσότητα της ηλιακής ακτινοβολίας που φτάνει στα πάνελ. Όταν ο ουρανός καλύπτεται από σύννεφα, η άμεση ηλιακή ακτινοβολία μειώνεται σημαντικά, περιορίζοντας την αποδοτικότητα των ηλιακών κυψελών. Παρόλο που τα σύννεφα διαχέουν το φως δημιουργώντας διάχυτη ακτινοβολία, αυτή είναι λιγότερο αποδοτική από την άμεση ακτινοβολία. Η σύνθεση των νεφών παίζει επίσης ρόλο, με τα λεπτά νέφη να επιτρέπουν περισσότερη ακτινοβολία σε σχέση με τα παχιά, χαμηλού υψομέτρου νέφη, τα οποία μπορούν να μειώσουν δραστικά την παραγωγή ενέργειας. Επιπλέον, γρήγορες αλλαγές στη νεφοκάλυψη μπορεί να προκαλέσουν απότομες διακυμάνσεις στην παραγόμενη ισχύ, δημιουργώντας προκλήσεις στην ευστάθεια του δικτύου. Τέλος, σε περιοχές με συχνή και έντονη νεφοκάλυψη, η μακροπρόθεσμη απόδοση των Φ/Β



Σχήμα 2.3: Παραγωγή Φ/Β ισχύος για ημέρα με ηλιοφάνεια και για ημέρα με νεφοκάλυψη

συστημάτων μπορεί να μειωθεί σημαντικά, καθιστώντας τη νεφοκάλυψη καθοριστικό παράγοντα για την εκτίμηση της αποδοτικότητας αυτών των συστημάτων [24]. Στο Σχήμα 2.3 φαίνεται χαρακτηριστικά το πως επηρεάζεται η Φ/Β παραγωγή από την νεφοκάλυψη.

- Ταχύτητα ανέμου: Η ταχύτητα του ανέμου επηρεάζει αρκετά την παραγωγή μέσω της θερμοκρασίας, καθώς ο άνεμος όχι μόνο ψύχει τα πάνελ, αλλά οδηγεί και σε διαφορετικές τιμές θερμοκρασίας στην επιφάνεια του πάνελ. Η θερμοκρασία κατανέμεται ανομοιόμορφα στην επιφάνεια των πάνελ λόγω της θερμικής αγωγιμότητας, η οποία υπάρχει έτσι και αλλιώς και τονώνεται από τον άνεμο [25].
- Υποβάθμιση Φ/Β μονάδας: Οι κατασκευαστές ηλιακών Φ/Β πάνελ συνήθως προσφέρουν εγγύηση 25 ετών, με την υπόσχεση ότι η απόδοση θα είναι τουλάχιστον 90% της ονομαστικής ισχύος για τα πρώτα 10 χρόνια και περίπου 80% για τα επόμενα 10 έως 15 χρόνια. Η υποβάθμιση των πάνελ είναι πιο γρήγορη στα πρώτα χρόνια και τυπικά ανέρχεται σε 0,5% ετησίως. Οι περισσότερες αποτυχίες προέρχονται από ζημιές λόγω μακροχρόνιας έκθεσης σε σκληρές συνθήκες. Επίσης, η γήρανση του τεχνολογικού εξοπλισμού ενός Φ/Β σταθμού επηρεάζει αρνητικά την απόδοσή του λόγω εξωτερικών παραγόντων ακόμα και με καλή συντήρηση.
- Σκόνη: Η σκόνη πάνω από τα Φ/Β πάνελ μειώνει σημαντικά την απόδοσή τους, καθώς εμποδίζει τη διείσδυση της ηλιακής ακτινοβολίας. Συσσώρευση σκόνης μπορεί να μειώσει την αποδοτικότητα του πάνελ κατά 50% σε ένα μήνα. Μελέτες δείχνουν ότι η σκόνη μειώνει την ενέργεια που παράγεται από το πάνελ, αλλά η επίδραση μειώνεται σε συνθήκες υψηλότερης ηλιακής ακτινοβολίας [23].

2.3 ΑΙΟΛΙΚΗ ΠΑΡΑΓΩΓΗ

2.3.1 Κύρια μέρη και τρόπος λειτουργίας ανεμογεννητριών

Τα κύρια μέρη μιας Α/Γ, τα οποία φαίνονται στο Σχήμα 2.4, είναι τα εξής:

- Δρομέας ή ρότορας: αποτελείται από δύο ή τρία πτερύγια και την πλήμνη. Ο άνεμος πάνω στα πτερύγια δημιουργεί άνωση που έχει σαν αποτέλεσμα μια ροπή γύρω από τον άξονα περιστροφής και αναγκάζει τα πτερύγια να περιστρέφονται. Τα πτερύγια διαθέτουν έλεγχο βήματος, δηλαδή στρέφονται, ή στρίβουν γύρω από τον άξονά τους, ανεξάρτητα από τον άνεμο, ώστε να ελέγχουν την ταχύτητα του δρομέα (ηλεκτρικού κινητήρα) και να εμποδίζουν τον δρομέα από το να στρίβει σε ανέμους οι οποίοι είναι υπερβολικά ισχυροί ή υπερβολικά ασθενείς για να παραγάγουν ηλεκτρισμό.
- Σύστημα μετάδοσης της κίνησης: αποτελείται από τον κύριο άξονα χαμηλής ταχύτητας, ο οποίος περιστρέφεται με 30 έως 60 στροφές ανά λεπτό, και τα έδρανά του, το σύστημα πέδησης, το οποίο είναι ένα συνηθισμένο δισκόφρενο/φρένο που τοποθετείται στον κύριο άξονα ή στον άξονα της γεννήτριας και το οποίο μπορεί να λειτουργεί μηχανικά, ηλεκτρικά ή υδραυλικά για να σταματήσει τον κινητήρα σε περίπτωση ανάγκης, καθώς και το κιβώτιο ταχυτήτων/πολλαπλασιασμού στροφών, το οποίο προσαρμόζει την ταχύτητα περιστροφής του δρομέα στη σύγχρονη ταχύτητα της ηλεκτρογεννήτριας. Η ταχύτητα περιστροφής παραμένει σταθερή κατά την κανονική λειτουργία της μηχανής μέσω ενός ελεγκτή.
- Ηλεκτρική γεννήτρια: μετατρέπει τη μηχανική ενέργεια σε ηλεκτρική και βρίσκεται συνήθως πάνω στον πύργο της Α/Γ.
- Κέλυφος: περιλαμβάνει το σύστημα μετάδοσης της κίνησης, τους άξονες και την ηλεκτρική γεννήτρια. Μερικά κελύφη είναι αρκετά μεγάλα ώστε να μπορεί ένας τεχνικός να κάθεται όρθιος μέσα σε αυτό ενώ δουλεύει.
- Σύστημα προσανατολισμού: αναγκάζει συνεχώς τον άξονα περιστροφής του δρομέα να βρίσκεται παράλληλα με τη διεύθυνση του ανέμου μέσω ενός ανεμομέτρου, το οποίο μετράει την ταχύτητα του ανέμου και μεταβιβάζει τα ανεμολογικά δεδομένα σε έναν ελεγκτή.
- Πύργος: στηρίζει όλη την παραπάνω ηλεκτρομηχανολογική εγκατάσταση, το ύψος του οποίου μπορεί να φτάσει και τα 130 μέτρα. Επειδή η ταχύτητα του ανέμου αυξάνει με το ύψος, οι υψηλότεροι πύργοι δίνουν τη δυνατότητα στις τουρμπίνες να «αιχμαλωτίσουν» περισσότερη ενέργεια και να παραγάγουν περισσότερο ηλεκτρισμό.
- Ηλεκτρονικός πίνακας και πίνακας ελέγχου: είναι τοποθετημένοι στη βάση του πύργου. Ο πίνακας ελέγχου παρακολουθεί, συντονίζει και ελέγχει όλες τις λειτουργίες της ανεμογεννήτριας, φροντίζοντας για την απρόσκοπτη λειτουργία της.



Σχήμα 2.4: Κύρια μέρη ανεμογεννήτριας

2.3.2 Ανεμογεννήτριες και ταχύτητα ανέμου

Η σχέση μεταξύ Α/Γ και ταχύτητας ανέμου είναι θεμελιώδης για τη λειτουργία και την αποδοτικότητα των Α/Γ. Η παραγωγή ηλεκτρικής ενέργειας από μια Α/Γ εξαρτάται άμεσα από την ταχύτητα του ανέμου, αλλά επηρεάζεται επίσης από άλλους καιρικούς και γεωγραφικούς παράγοντες, όπως η κατεύθυνση του ανέμου, η υγρασία και το φαινόμενο της σκίασης. Στο Σχήμα 2.5 φαίνεται η άμεση σχέση της αιολικής ισχύος με την ταχύτητα ανέμου [19]. Όταν η ταχύτητα του ανέμου κυμαίνεται εντός ενός συγκεκριμένου εύρους, η Α/Γ παράγει ηλεκτρική ενέργεια. Σε χαμηλές ταχύτητες ανέμου, η παραγωγή είναι περιορισμένη, ενώ σε υψηλές ταχύτητες, η παραγωγή αυξάνεται σημαντικά. Η καμπύλη απόδοσης μιας Α/Γ έχει τρία κρίσιμα σημεία που αφορούν την λειτουργία της: 1) Το σημείο μετά από το οποίο η Α/Γ ξεκινά να λειτουργεί, επομένως και να παράγει ενέργεια (ελάχιστη ταχύτητα ανέμου). 2)Το σημείο μετά το οποίο η Α/Γ ξεκινά να παράγει την μέγιστη ισχύ (ταχύτητα ανέμου για την ονομαστική ισχύ). 3) Το σημείο μετά το οποίο η Α/Γ σταματά για λόγους αυτοπροστασίας της λειτουργία της, επομένως και την παραγωγή ενέργειας, επειδή η ταχύτητα του ανέμου είναι υπερβολικά αυξημένη (ταχύτητα αποκοπής). Για ταχύτητες ανέμου χαμηλότερες από την ονομαστική, μικρές αλλαγές στην ταχύτητα του ανέμου οδηγούν σε μεγάλες αλλαγές στην παραγωγή ισχύος. Η στοχαστική φύση του ανέμου και της ατμόσφαιρας προκαλεί συνεχείς μεταβολές στην αιολική ισχύ που παράγεται. Ταυτόχρονα, η δυσκολία στον έλεγχο της αιολικής παραγωγής αυξάνεται λόγω της αβεβαιότητας που υπάρχει στις βραχυπρόθεσμες καιρικές προβλέψεις. Επιπλέον, η παραγωγή αιολικής ενέργειας εξαρτάται από πολλούς τυχαίους



Σχήμα 2.5: Θεωρητική καμπύλη αιολικής ισχύος – ταχύτητας ανέμου

παράγοντες, οι οποίοι την καθιστούν μια στοχαστική διαδικασία. Αυτό σημαίνει ότι, ακόμη και αν είναι γνωστή η αρχική κατάσταση και οι εξισώσεις που διέπουν τη διαδικασία, δεν είναι δυνατόν να προβλεφθεί με ακρίβεια η εξέλιξή της. Έτσι, ακόμη και αν οι συνθήκες για μια συγκεκριμένη Α/Γ είναι ίδιες σε δύο διαφορετικές χρονικές στιγμές, δεν είναι βέβαιο ότι θα παραχθεί η ίδια ποσότητα αιολικής ισχύος.

Οι διακυμάνσεις της ταχύτητας του ανέμου καταπονούν την κύρια δομή και τα υποσυστήματα μιας Α/Γ, προκαλούν φθορές, και μειώνουν τη διάρκεια ζωής των υποσυστημάτων. Επομένως, η ακριβής παρακολούθηση της ταχύτητας του ανέμου και η προσαρμογή των λειτουργιών της Α/Γ είναι κρίσιμες για την αποδοτική και ασφαλή λειτουργία της. Η Α/Γ πρέπει να σχεδιαστεί για να αντέχει διάφορους τύπους φορτίων λόγω αυτών των επιδράσεων, περιλαμβάνοντας [26]:

- Μεγάλα στιγμιαία φορτία, από τα οποία εξάγεται ενέργεια, προκαλώντας καταπονήσεις που υπερβαίνουν την απόλυτη αντοχή σε εφελκυσμό των εξαρτημάτων των υποσυστημάτων.
- Μακροπρόθεσμα κυμαινόμενα φορτία, τα οποία μπορεί, σε μέγεθος και χρόνο, να υπερβαίνουν την αντοχή σε κόπωση των εξαρτημάτων των υποσυστημάτων.

2.4 ΑΞΙΑ ΠΡΟΒΛΕΨΗΣ Φ/Β ΚΑΙ ΑΙΟΛΙΚΗΣ ΠΑΡΑΓΩΓΗΣ

Η ενσωμάτωση των ΑΠΕ στο ηλεκτρικό δίκτυο αποκτά ολοένα και μεγαλύτερη σημασία, δημιουργώντας παράλληλα περισσότερες προκλήσεις για τους ηλεκτρολόγους μηχανικούς και τους ερευνητές. Η διαλείπουσα και μη ελεγχόμενη φύση της ηλιακής ενέργειας και αιολικής ενέργειας αυξάνει την πολυπλοκότητα της διαχείρισης του δικτύου και προσθέτει δυσκολίες στην εξισορρόπηση της παραγωγής και κατανάλωσης ενέργειας. Η εξισορρόπηση μεταξύ παραγωγής και κατανάλωσης έχει γίνει μια μεγάλη πρόκληση για τους διαχειριστές των συστημάτων ηλεκτρικής ενέργειας. Οι διακυμάνσεις της τάσης, η χαμηλή ποιότητα ισχύος και τα προβλήματα ευστάθειας είναι μερικά από τα άλλα προβλήματα που προκύπτουν λόγω της μη ελεγχόμενης φύσης της ηλιακής και αιολικής ενέργειας. Η μεταβλητότητα, η αβεβαιότητα και οι ασύγχρονες λειτουργίες είναι οι κύριες τεχνικές προκλήσεις που πρέπει να αντιμετωπίσουν οι διαχειριστές των συστημάτων ηλεκτρικής ενέργειας κατά την ενσωμάτωση των ΑΠΕ στο ηλεκτρικό δίκτυο. Έτσι, για τη βέλτιστη διαχείριση του ηλεκτρικού δικτύου, απαιτείται ακριβής πρόβλεψη της παραγόμενης Φ/Β και αιολικής ισχύος. Η πρόβλεψη της παραγόμενης Φ/Β και αιολικής ισχύος είναι κρίσιμη για διάφορες πτυχές της ενεργειακής διαχείρισης και της λειτουργίας του ηλεκτρικού συστήματος.

Παρακάτω αναλύονται περισσότερο οι λόγοι για τους οποίους αυτή η πρόβλεψη της Φ/B και της αιολικής ισχύος είναι απαραίτητη [27]:

- Προγραμματισμός: Η ακριβής πρόβλεψη της παραγωγής ενέργειας από Φ/Β και Α/Γ επιτρέπει στους διαχειριστές του ηλεκτρικού δικτύου και στους παρόχους ενέργειας να προγραμματίζουν καλύτερα την παραγωγή και τη διανομή της ηλεκτρικής ενέργειας. Αυτό περιλαμβάνει τον προγραμματισμό της παραγωγής από άλλες πηγές ενέργειας για να καλυφθούν τα κενά ή οι υπερβάσεις στην παραγωγή από Φ/Β και Α/Γ λόγω καιρικών συνθηκών.
- Εκτίμηση των αποθεμάτων: Η διαχείριση των ενεργειακών αποθεμάτων είναι απαραίτητη για τη διασφάλιση της επάρκειας ενέργειας σε περιόδους χαμηλής παραγωγής από Φ/Β και Α/Γ. Η πρόβλεψη βοηθά στον προγραμματισμό της χρήσης ενεργειακών αποθεμάτων, όπως είναι τα συστήματα αποθήκευσης ενέργειας (π.χ. μπαταρίες), και εξασφαλίζει ότι υπάρχει επαρκής ενέργεια για την κάλυψη της ζήτησης.
- Διαχείριση της παραγόμενης ηλεκτρικής ενέργειας: Η πρόβλεψη της Φ/Β και αιολικής ισχύος επιτρέπει την πιο αποδοτική και ισορροπημένη χρήση της παραγόμενης ενέργειας από ΑΠΕ στο δίκτυο. Αυτό σημαίνει ότι μπορεί να αποφεύγονται οι περιπτώσεις υπερπαραγωγής όπου η παραγόμενη ενέργεια δεν μπορεί να απορροφηθεί στο σύνολό της από το δίκτυο ή περιπτώσεις έλλειψης ενέργειας που θα απαιτούσαν τη χρήση εφεδρικών πηγών.
- Βελτίωση της λειτουργίας του ηλεκτρικού δικτύου: Η πρόβλεψη συμβάλλει στην ευστάθεια και την αξιοπιστία του ηλεκτρικού δικτύου, καθώς οι διαχειριστές μπορούν να λάβουν προληπτικά μέτρα για να διαχειριστούν τις διακυμάνσεις στην παραγωγή από Φ/Β και Α/Γ. Αυτό μπορεί να περιλαμβάνει ρυθμίσεις στις ροές ενέργειας ή την ενεργοποίηση εφεδρικών πηγών.
- Μείωση του κόστους της παραγόμενης ηλεκτρικής ενέργειας: Η ακριβής πρόβλεψη της Φ/Β και αιολικής ισχύος βοηθά στη μείωση του συνολικού κόστους παραγωγής ηλεκτρικής ενέργειας, καθώς επιτρέπει την καλύτερη αξιοποίηση των διαθέσιμων πηγών και την αποφυγή δαπανηρών λύσεων, όπως η ανάγκη για γρήγορη ενεργοποίηση εφεδρικών μονάδων παραγωγής ή η αγορά ενέργειας από άλλες πηγές σε υψηλότερες τιμές.
- Διαχείριση της συμφόρησης: Σε περιπτώσεις όπου η παραγωγή από Φ/Β και Α/Γ υπερβαίνει τη ζήτηση ή την ικανότητα του δικτύου να μεταφέρει αυτήν την ενέργεια, μπορεί να προκύψουν προβλήματα συμφόρησης. Η πρόβλεψη επιτρέπει στους διαχειριστές του δικτύου να λάβουν μέτρα, όπως η αποθήκευση της ενέργειας ή η διοχέτευσή της σε άλλες περιοχές, ώστε να αποφευχθεί η υπερφόρτωση του δικτύου.

Επιπλέον, σε μια φιλελευθεροποιημένη αγορά ηλεκτρικής ενέργειας, η ικανότητα πρόβλεψης της Φ/Β και αιολικής ισχύος θα βοηθήσει στην ενίσχυση της θέσης τους σε σύγκριση με άλλες

μορφές ενέργειας. Η πρόβλεψη της Φ/Β και αιολικής παραγωγής σε ένα ΣΗΕ επηρεάζει την ασφάλεια και τη διαχείρισή του. Βελτίωση της πρόβλεψης σημαίνει αύξηση στην ασφάλεια του συστήματος και στην αποδοτικότητα των επενδύσεων σε Φ/Β και αιολικούς σταθμούς [28]. Η ακριβής γνώση της ισχύος που παράγεται από Φ/Β και αιολικούς σταθμούς σε πραγματικό χρόνο είναι ζωτικής σημασίας για την κάλυψη των εθνικών ενεργειακών αναγκών και την αποφυγή διακοπών ή άλλων ανεπιθύμητων συμβάντων στο δίκτυο. Οι παραγωγοί πρέπει να μπορούν να προβλέπουν με ακρίβεια την Φ/Β αιολική παραγωγή, ώστε να υποβάλουν έγκαιρα και αξιόπιστα τις προσφορές τους και να διευκολύνουν τον κεντρικό σχεδιασμό του συστήματος.

- Όταν οι προβλέψεις για την Φ/Β και αιολική παραγωγή είναι χαμηλότερες από την πραγματική παραγωγή, οι συμβατικές μονάδες παραγωγής αναγκάζονται να λειτουργούν σε χαμηλότερη ισχύ, μειώνοντας έτσι την αποδοτικότητα του συστήματος. Εάν τα σφάλματα στην πρόβλεψη είναι σημαντικά, όπως όταν η πραγματική παραγωγή των Φ/Β και αιολικών σταθμών είναι πολύ μεγαλύτερη από την προβλεπόμενη, η επιπλέον παραγόμενη αιολική ενέργεια μπορεί να παραμείνει ανεκμετάλλευτη.
- Όταν οι προβλέψεις για την Φ/Β και την αιολική παραγωγή είναι υψηλότερες από την πραγματική παραγωγή, οι συμβατικές μονάδες παραγωγής πρέπει να αυξήσουν την παραγωγή τους για να καλύψουν τη διαφορά, κάτι που οδηγεί σε αυξημένες εκπομπές αέριων ρύπων. Σε αυτές τις περιπτώσεις, το κόστος λειτουργίας του συστήματος αυξάνεται και η αποδοτικότητα μειώνεται [29].

2.5 ΜΕΘΟΔΟΙ ΠΡΟΒΛΕΨΗΣ Φ/Β ΚΑΙ ΑΙΟΛΙΚΗΣ ΠΑΡΑΓΩΓΗΣ

Για την αντιμετώπιση των μειονεκτημάτων της ασταθούς Φ/Β και αιολικής παραγωγής, έχουν αναπτυχθεί πολλές μέθοδοι πρόβλεψης. Αυτές οι μέθοδοι χρησιμοποιούν διάφορες τεχνικές για να εκτιμήσουν την πραγματική Φ/Β και αιολική παραγωγή σε συγκεκριμένο χρονικό ορίζοντα, με κάθε μέθοδο να έχει τα δικά της πλεονεκτήματα και αδυναμίες.

2.5.1 Φυσικές μέθοδοι

Τα φυσικά μοντέλα πρόβλεψης της παραγωγής χρησιμοποιούν μαθηματικές εξισώσεις και προσομοιώσεις του περιβάλλοντος για να εκτιμήσουν παράγοντες όπως η ηλιακή ακτινοβολία, η σκίαση, η ρύπανση, ο αέρας και η θερμοκρασία. Τα φυσικά μοντέλα δεν απαιτούν ιστορικά δεδομένα, μπορούν να παρέχουν ακριβείς προβλέψεις σε μικρό χρονικό διάστημα και να αναπαράγουν με ακρίβεια τις αλλαγές στην ισχύ και άλλες μετρήσεις σε πολύ σύντομα χρονικά διαστήματα. Ωστόσο, έχουν υψηλό κόστος υλοποίησης και απαιτούν εξειδικευμένα δεδομένα που συχνά είναι περιορισμένα ή ανακριβή.

2.5.2 Στατιστικές μέθοδοι

Σε αντίθεση με τα φυσικά μοντέλα, οι στατιστικές μέθοδοι δεν χρειάζονται πληροφορίες για την τοπογραφία, τον εξοπλισμό ή τους αισθητήρες του Φ/Β σταθμού και των ανεμογεννητριών. Αντίθετα, εξάγουν σχέσεις από ιστορικά δεδομένα για να προβλέψουν τη

μελλοντική παραγωγή. Η ποιότητα των ιστορικών δεδομένων είναι κρίσιμη για την ακρίβεια της πρόβλεψης. Συνήθως απαιτείται μεγάλο ιστορικό δεδομένων από τη λειτουργία του σταθμού. Τα πλεονεκτήματα των στατιστικών μεθόδων περιλαμβάνουν την απλότητα και το χαμηλό κόστος, καθώς και την έλλειψη ανάγκης ειδικής εξειδίκευσης. Ωστόσο, εξαρτώνται από την ακρίβεια των μετρητικών οργάνων, είναι ευαίσθητες σε ακραίες τιμές και δεν μπορούν να αναλύσουν σύνθετες μη γραμμικές σχέσεις. Αυτό σημαίνει ότι συνήθως καταλήγουν στην υπεραπλούστευση της πραγματικότητας, καθώς οι στατιστικές μέθοδοι υποθέτουν γραμμικές σχέσεις μεταξύ των μεταβλητών. Στην πραγματικότητα, οι παράγοντες που επηρεάζουν την παραγωγή Φ/Β ενέργειας μπορεί να αλληλοεπιδρούν με πολύπλοκους και μη γραμμικούς τρόπους, τους οποίους οι στατιστικές μέθοδοι δυσκολεύονται να συλλάβουν και να αναλύσουν.

2.5.3 Μοντέλα μηχανικής μάθησης

Η πρόοδος στους υπολογιστές και την τεχνητή νοημοσύνη έχει ενισχύσει την ικανότητα ανάλυσης δεδομένων με μεγαλύτερη ταγύτητα και ακρίβεια. Τα μοντέλα μηγανικής μάθησης, που χρησιμοποιούν αλγορίθμους για την ανίχνευση μοτίβων σε μεγάλα σύνολα δεδομένων, έχουν επεκταθεί στην πρόβλεψη της παραγωγής ισχύος από Φ/Β συστήματα και ανεμογεννήτριες. Αυτά τα μοντέλα ανιχνεύουν σύνθετες, μη γραμμικές σχέσεις μεταξύ μετεωρολογικών και τεχνικών παραμέτρων. Τα μοντέλα μηχανικής μάθησης βελτιώνουν τις στατιστικές μεθόδους, αντιμετωπίζοντας ορισμένα από τα μειονεκτήματά τους, και προσφέρουν καλύτερη ανάλυση σύνθετων σχέσεων. Τα μοντέλα μηχανικής μάθησης απαιτούν προσεκτική ρύθμιση των παραμέτρων τους, καθώς ενδέχεται να εμφανίσουν προβλήματα. Εάν ένα μοντέλο έχει λίγα δεδομένα, είναι απλοϊκά εκπαιδευμένο ή έχει υψηλή προκατάληψη, μπορεί να μην μπορεί να συσχετίσει σωστά τις μεταβλητές εισόδου και εξόδου, οδηγώντας σε ανακριβείς προβλέψεις (under-fitting). Αντίθετα, ένα πολύπλοκο μοντέλο που έχει μεγάλη απόκλιση μεταξύ δεδομένων εκπαίδευσης και ελέγχου μπορεί να προσαρμοστεί υπερβολικά στα δεδομένα εκπαίδευσης και να δυσκολευτεί να γενικεύσει σε νέα δεδομένα (overfitting) [30]. Οι αρχές λειτουργίας των μοντέλων μηχανικής μάθησης παρουσιάζονται αναλυτικότερα στο Κεφάλαιο 3.

2.6 ΧΡΟΝΙΚΗ ΤΑΞΙΝΟΜΗΣΗ ΜΟΝΤΕΛΩΝ ΠΡΟΒΛΕΨΗΣ

Παρά την έλλειψη κοινά αποδεκτών χρονικών κλιμάκων για την ταξινόμηση της πρόβλεψης Φ/Β και αιολικής παραγωγής, η διεθνής βιβλιογραφία συνήθως διακρίνει τρεις κύριες κατηγορίες: βραχυπρόθεσμη, μεσοπρόθεσμη και μακροπρόθεσμη πρόβλεψη. Η ακρίβεια της πρόβλεψης επηρεάζεται σημαντικά από τον χρονικό ορίζοντα, με την δυσκολία προσέγγισης της πραγματικής ισχύος να αυξάνεται όσο μεγαλύτερο είναι το διάστημα της πρόβλεψης. Κάθε τύπος πρόβλεψης έχει τη δική του αξία και χρησιμότητα, και όλες οι κατηγορίες είναι αλληλοσυμπληρούμενες τόσο χρονικά όσο και πρακτικά [31].

2.6.1 Βραχυπρόθεσμη πρόβλεψη

Η βραχυπρόθεσμη πρόβλεψη αναφέρεται σε χρονικούς ορίζοντες μικρότερους της μίας ημέρας (ενδοημερήσια πρόβλεψη) και είναι εξαιρετικά χρήσιμη στην πράξη. Συνήθως, χωρίζεται σε δύο υποκατηγορίες:

- Υπέρ-βραχυπρόθεσμη πρόβλεψη: Καλύπτει χρονικό ορίζοντα από μερικά δευτερόλεπτα έως μία ώρα. Χρησιμοποιούνται δεδομένα πέραν των μετεωρολογικών, όπως επίγειες εικόνες του ουρανού. Αυτή η πρόβλεψη είναι κρίσιμη για την ευστάθεια του δικτύου, την αυτόματη αποδέσμευση μονάδων παραγωγής και την παρακολούθηση του δικτύου σε πραγματικό χρόνο, ενώ χρησιμοποιείται, κυρίως, για τον έλεγχο μικροδικτύων σε πραγματικό χρόνο, τον έλεγχο των απότομων διακυμάνσεων και τον προγραμματισμό μπαταριών για απόκριση ζήτησης.
- Βραχυπρόθεσμη πρόβλεψη: Καλύπτει χρονικούς ορίζοντες από μία ώρα έως μία ημέρα. Αυτή η κατηγορία πρόβλεψης είναι η πιο κρίσιμη για την ομαλή λειτουργία των ΣΗΕ καθώς χρησιμοποιείται σε ποικίλες εφαρμογές. Χρησιμοποιούνται κυρίως στατιστικές μέθοδοι και μοντέλα μηχανικής μάθησης καθώς και δορυφορικές εικόνες του ουρανού. Η βραχυπρόθεσμη πρόβλεψη είναι σημαντική σε εφαρμογές για τον βέλτιστο προγραμματισμό ΣΗΕ για απόκριση ζήτησης, την δέσμευση συμβατικών μονάδων παραγωγής και συμμετοχή στην αγορά ηλεκτρικής ενέργειας.

2.6.2 Μεσοπρόθεσμη πρόβλεψη

Η μεσοπρόθεσμη πρόβλεψη καλύπτει χρονικούς ορίζοντες από μία ημέρα έως ένα μήνα. Για την παραγωγή αυτών των προβλέψεων, χρησιμοποιούνται συνήθως σύνθετες φυσικές μέθοδοι, μοντέλα μηχανικής μάθησης και υβριδικά μοντέλα. Αυτές οι προβλέψεις είναι κρίσιμες για τον ενεργειακό προγραμματισμό του δικτύου, τον προγραμματισμό τακτικής συντήρησης των μονάδων παραγωγής και την πρόληψη έναντι ακραίων καιρικών και ενεργειακών φαινομένων. Επιπλέον, η μεσοπρόθεσμη πρόβλεψη βασίζεται έντονα στις μετεωρολογικές προβλέψεις.

2.6.3 Μακροπρόθεσμη πρόβλεψη

Η μακροπρόθεσμη πρόβλεψη καλύπτει χρονικούς ορίζοντες μεγαλύτερους του ενός μήνα. Σε αυτή την κατηγορία χρησιμοποιούνται, κατά βάση, στατιστικά μοντέλα. Αυτή η πρόβλεψη είναι κρίσιμη για τον μακροπρόθεσμο σχεδιασμό του ενεργειακού συστήματος, όπως η κατασκευή νέων υποσταθμών και μονάδων παραγωγής, καθώς και η αναβάθμιση του ηλεκτρικού δικτύου. Επίσης, είναι απαραίτητη για νέες ενεργειακές επενδύσεις, την εθνική ενεργειακή πολιτική και τη χάραξη διεθνών στρατηγικών για τα επόμενα χρόνια ή δεκαετίες. Επιπλέον, χρησιμοποιείται στην ενεργειακή χρηματοπιστωτική αγορά για συμφωνίες προμήθειας ενεργειακών προϊόντων μεταξύ παραγωγών και προμηθευτών ή βιομηχανικών καταναλωτών.

КЕФАЛАІО 3

ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ ΚΑΙ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

3.1 ГЕNIKA

Η ταχεία ανάπτυξη των υπολογιστικών συστημάτων τις τελευταίες δεκαετίες έχει καταστήσει εφικτή την εφαρμογή διαφόρων μεθόδων μηχανικής μάθησης για την πρόβλεψη της Φ/Β και αιολικής παραγωγής. Η μηχανική μάθηση, ως ένας τομέας της τεχνητής νοημοσύνης που βασίζεται σε δεδομένα, απαιτεί μόνο ιστορικά δεδομένα για να ανιχνεύσει τις σχέσεις μεταξύ μεταβλητών. Κατά τη διάρκεια της εκπαίδευσης, οι παράμετροι των μοντέλων μηχανικής μάθησης ρυθμίζονται επαναληπτικά ώστε να εντοπίζονται κρυμμένα πρότυπα και υποκείμενες σχέσεις σε σύνολα δεδομένων, επιτρέποντας έτσι στο σύστημα να γενικεύει σε άγνωστα δεδομένα και να εκτελεί πολύπλοκες λειτουργίες, όπως η ταξινόμηση και η πρόβλεψη. Τα κύρια πλεονεκτήματα που καθιστούν τις μεθόδους μηχανικής μάθησης ελκυστικές είναι οι ισχυρές δυνατότητες εξαγωγής συμπερασμάτων και οι χαμηλές απαιτήσεις σε επίπεδο ανθρώπινης παρέμβασης και εξειδίκευσης. Οι μέθοδοι μηχανικής μάθησης μπορούν να ανιχνεύσουν περίπλοκες μη γραμμικές σχέσεις σε δεδομένα που αλλάζουν δυναμικά με την πάροδο του χρόνου, διατηρώντας παράλληλα υψηλή υπολογιστική αποδοτικότητα.

Τα πλεονεκτήματα της μηχανικής μάθησης βοηθούν στην αντιμετώπιση των προκλήσεων που συνδέονται με πολύπλοκες διαδικασίες, όπως η πρόβλεψη Φ/Β και αιολικής παραγωγής. Η παραγωγή Φ/Β και αιολικής ισχύος είναι μια ιδιαίτερα ασταθής και διαλείπουσα στοχαστική μεταβλητή, με μη γραμμικές εξαρτήσεις από πολλούς μετεωρολογικούς, γεωγραφικούς, και χρονικούς παράγοντες. Οι τεχνικές μηχανικής μάθησης μπορούν να μοντελοποιήσουν αυτές τις μη γραμμικές εξαρτήσεις, εφόσον είναι διαθέσιμα ποιοτικά ιστορικά δεδομένα.

Τα τελευταία είκοσι χρόνια, παρατηρείται εκθετική αύξηση στον αριθμό των δημοσιεύσεων σχετικά με την πρόβλεψη Φ/Β και αιολικής παραγωγής μέσω μηχανικής μάθησης [32]. Η διαθεσιμότητα δεδομένων από έξυπνους μετρητές και συστήματα παρακολούθησης έχει επιτρέψει την ακριβή πρόβλεψη της Φ/Β και αιολικής ισχύος μέσω της μηχανικής μάθησης. Οι περισσότερες προσεγγίσεις επικεντρώνονται σε βραχυπρόθεσμες προβλέψεις. Η επιθυμητή ευελιξία στα ΣΗΕ απαιτεί την ενσωμάτωση διαδικασιών λήψης αποφάσεων με σύντομους χρόνους απόκρισης, όπου η μηχανική μάθηση για την πρόβλεψη Φ/Β και αιολικής ισχύος παίζει καθοριστικό ρόλο. Επιπλέον, η σημαντική αύξηση των τοπικών Φ/Β και αιολικών συστημάτων δημιουργεί πολλές διαφορετικές περιπτώσεις μελέτης, που είναι δύσκολο να μοντελοποιηθούν με φυσικούς τρόπους. Η μηχανική μάθηση προσφέρει την απαραίτητη ευελιξία για επανεκπαίδευση και εφαρμογή σε διάφορες περιπτώσεις.

Τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks - ANN), αποτελούν υποσύνολο της μηχανικής μάθησης και είναι δομές επεξεργασίας πληροφοριών που αποσκοπούν στη μίμηση του τρόπου με τον οποίο τα βιολογικά νευρικά συστήματα

επεξεργάζονται τις πληροφορίες [33]. Οι βασικές μονάδες επεξεργασίας των ANN ονομάζονται νευρώνες και συνδέονται μεταξύ τους μέσω συνάψεων με βάρη.

Τα ANN έχουν το πλεονέκτημα ότι μπορούν να συσχετίζουν τις εισόδους με τις εξόδους ανεξάρτητα, χωρίς την ανάγκη για ανθρώπινη παρέμβαση, ελαττώνοντας έτσι την εισαγόμενη μεροληψία των φυσικών μεθόδων. Ο όρος "νευρωνικά" χρησιμοποιείται επειδή η βασική αρχιτεκτονική και λειτουργία των ANN μοιάζει σε μεγάλο βαθμό με το ανθρώπινο νευρικό σύστημα [34]. Ένα ANN αποτελείται από νευρώνες που είναι οργανωμένοι σε παράλληλα επίπεδα και συνδέονται μεταξύ τους μέσω συνάψεων, οι οποίες αντιπροσωπεύουν τα βάρη και καθορίζουν τον τρόπο λειτουργίας του δικτύου.

Υπάρχει μεγάλη ποικιλία τύπων ANN, καθένας με τη δική του δομή, διαδικασίες υπολογισμού και ιδιαίτερα χαρακτηριστικά. Κάθε τύπος ANN είναι κατάλληλος για εργασίες πρόβλεψης της Φ/Β και αιολικής παραγωγής σε συγκεκριμένες χρονικές και χωρικές κλίμακες. Τα ANN χαρακτηρίζονται από υψηλά επίπεδα ευελιξίας, καθώς ο ίδιος τύπος ANN μπορεί εύκολα να διαμορφωθεί ώστε να ανταποκριθεί στο εύρος διαφορετικών εργασιών Φ/Β και αιολικής παραγωγής τα ANN είναι ιδιαίτερα αποτελεσματικά στη μοντελοποίηση σύνθετων, μη γραμμικών σχέσεων μεταξύ των μεταβλητών [32], [35]. Τα ANN ταξινομούνται σε δύο κύριες κατηγορίες με βάση την κατεύθυνση της ροής της πληροφορίας: τα ANN Εμπρόσθιας Τροφοδότησης (Feed Forward Neural Network - FFNN) και τα Αναδρομικά ANN (Recurent Neural Network - RNN). Στα FFNN, η πληροφορία προχωρά από το στρώμα εισόδου στο στρώμα εξόδου μέσω των κρυφών επιπέδων. Από την άλλη πλευρά, τα RNN περιέχουν βρόχους όπου η πληροφορία ανατροφοδοτείται στο ίδιο ή στα προηγούμενα στρώματα. Δεδομένου ότι η διατήρηση προηγούμενων καταστάσεων των κρυφών επιπέδων συνήθως δημιουργεί μια βαθιά εκτύλιξη στον χρόνο, μειώνοντας την υπολογιστική αποδοτικότητα, τα RNN συνήθως θεωρούνται μέρος της βαθιάς μάθησης.

Ένα από τα κύρια αρνητικά χαρακτηριστικά των ΑΝΝ και γενικά των μοντέλων μηχανικής μάθησης είναι η υπερπροσαρμογή (overfitting). Αυτό συμβαίνει όταν ένα μοντέλο μαθαίνει τόσο καλά τα δεδομένα εκπαίδευσης, που αποτυγχάνει να γενικεύσει καλά σε νέα, μη ορατά δεδομένα. Αυτό σημαίνει ότι το μοντέλο απομνημονεύει τις λεπτομέρειες και τον θόρυβο των δεδομένων εκπαίδευσης αντί να μάθει τις υποκείμενες γενικές τάσεις ή μοτίβα. Δηλαδή, ενώ τα ΑΝΝ, ειδικά αυτά με πολλά στρώματα και νευρώνες, έχουν τεράστια ικανότητα εκμάθησης και μπορούν να προσαρμόζονται πολύ καλά ακόμα και σε πολύπλοκα δεδομένα, αυτή η μεγάλη ικανότητα μπορεί να οδηγήσει στην απομνημόνευση των δεδομένων εκπαίδευσης αντί για τη μάθηση γενικών μοτίβων. Όταν το σύνολο δεδομένων είναι μικρό, τα ΑΝΝ μπορεί να μάθουν πολύ συγκεκριμένες ιδιότητες των δεδομένων αυτών, οι οποίες δεν αντανακλούν τις ιδιότητες του γενικού πληθυσμού από τον οποίο προέργονται τα δεδομένα, ενώ όταν υπάρχουν πολλά χαρακτηριστικά (μεταβλητές εισόδου), το μοντέλο μπορεί να αρχίσει να βρίσκει μοτίβα που οφείλονται σε τυχαίο θόρυβο, αντί να μαθαίνει τις πραγματικές σχέσεις που υπάρχουν στα δεδομένα. Επομένως, σε περιπτώσεις υπερπροσαρμογής το μοντέλο αποδίδει καλά στα δεδομένα εκπαίδευσης, αλλά όταν δοκιμάζεται σε νέα δεδομένα, η απόδοσή του είναι χαμηλή.

Παρακάτω, θα αναλυθούν διάφορα μοντέλα ANN, με έμφαση σε συγκεκριμένους τύπους που είναι ευρέως χρησιμοποιούμενοι στην ανάλυση δεδομένων και στην πρόβλεψη. Συγκεκριμένα, θα εξεταστούν τα νευρωνικά δίκτυα FFNN. Επιπλέον, θα παρουσιαστούν τα νευρωνικά δίκτυα με ανάδραση και εξωγενείς εισόδους (Non-linear Autoregressive networks with eXogenous inputs - NARX) καθώς και τα δίκτυα μακράς βραχύχρονης μνήμης (Long Short-Term Memory - LSTM), που είναι εξειδικευμένα σε χρονοσειρές δεδομένων με μεγάλη χρονική αυτοσυσχέτιση. Αυτά τα μοντέλα θα αναλυθούν και θα συγκριθούν με στόχο την κατανόηση των ιδιαίτερων χαρακτηριστικών και πλεονεκτημάτων τους.

3.2 AIKTYA FFNN

Τα FFNN είναι υπολογιστικά συστήματα επεξεργασίας πληροφοριών που εφαρμόζονται ευρέως για την αντιμετώπιση μη γραμμικών και πολύπλοκων προβλημάτων. Σε τέτοιες περιπτώσεις, όπου η μαθηματική μοντελοποίηση συχνά αποδεικνύεται σχεδόν ανέφικτη, η σχέση μεταξύ μεταβλητών εισόδου και εξόδου μπορεί να είναι ασαφής ή δύσκολο να υπολογιστεί [36].

3.2.1 Δομή και τρόπος λειτουργίας FFNN

Τα FFNN συνήθως οργανώνονται σε πολλαπλά επίπεδα, συνδυάζοντας τόσο σειριακή όσο και παράλληλη διάταξη νευρώνων, προκειμένου να αποτυπωθούν αποτελεσματικά οι πολύπλοκες μη γραμμικές σχέσεις μεταξύ των μεταβλητών. Όταν πολλοί νευρώνες τοποθετούνται παράλληλα, σχηματίζουν ένα στρώμα, το οποίο μπορεί να ανήκει σε μία από τις τρεις κύριες κατηγορίες: το στρώμα εισόδου, ακολουθούμενο από ένα ή περισσότερα κρυφά στρώματα, τα οποία τελικά οδηγούν στο στρώμα εξόδου, όπως φαίνεται και στο Σγήμα 3.1 (α). Για να θεωρηθεί μια υπολογιστική δομή ως FFNN, πρέπει να είναι οργανωμένη σε μορφή κατευθυνόμενου γράφου, και γι' αυτόν τον λόγο στη διεθνή βιβλιογραφία ο όρος "νευρώνας" (neuron) συγνά αντικαθίσταται από τον όρο "κόμβος" (node) [37]. Τα δεδομένα που εισέρχονται σε ένα FFNN εισάγονται μέσω του στρώματος εισόδου, το οποίο είναι παθητικό, καθώς ο βασικός του ρόλος είναι να μεταφέρει τις τιμές των δεδομένων στα κρυφά στρώματα μέσω των αντίστοιχων βαρών. Τα κρυφά στρώματα και το στρώμα εξόδου επιτελούν τις υπολογιστικές δομές του δικτύου, καθιστώντας δυνατή την εκπαίδευση του FFNN. Η έξοδος κάθε κόμβου εξαρτάται αποκλειστικά από την πληροφορία που εισέρχεται στον κόμβο μέσω των συνάψεων. Κάθε νευρώνας από μόνος του δεν έχει μεγάλη υπολογιστική ισχύ, παράγει όμως μια απλή βαθμωτή τιμή εξόδου, η οποία προκύπτει από μια μη γραμμική συνάρτηση των εισόδων του [38]. Συνεπώς, η εξαιρετική απόδοση των FFNN ακόμη και σε πολύπλοκες καταστάσεις οφείλεται στην ολοκληρωμένη αρχιτεκτονική του, η οποία βασίζεται στη συλλογική λειτουργία των εσωτερικών συνάψεων και υπολογισμών.

Στο Σχήμα 3.1 (β) [35], παρουσιάζεται το μαθηματικό μοντέλο ενός νευρώνα και η αλληλεπίδρασή του με τους υπόλοιπους νευρώνες. Κάθε νευρώνας λαμβάνει σήματα εισόδου είτε από άλλους νευρώνες $(inp_1, inp_2, ..., inp_N)$, είτε από εξωτερικές επιρροές (πόλωση b), και παράγει μία έξοδο y. Σε κάθε είσοδο $inp_1, inp_2, ..., inp_N$ αντιστοιχεί ένα βάρος $W_1, W_2, ..., W_N$.

Η είσοδος z, του νευρώνα, στο Σχήμα 3.1 (β), είναι:

$$z = w_1 * inp_1 + w_2 * inp_2 + \dots + w_N * inp_N + b$$
(3.1)

Η έξοδος z του νευρώνα του Σχήματος 3.1 (β), βάσει της συνάρτησης ενεργοποίησης f είναι:

$$y = f(z) \tag{3.2}$$



Σχήμα 3.1: (α) Δομή FFNN με *K* μεταβλητές εισόδου, ένα κρυφό στρώμα, και ένα νευρώνα στο στρώμα εξόδου. (β) Μοντέλο νευρώνα FFNN.

Συνάρτηση Ενεργοποίησης	Τύπος Συνάρτησης
Σιγμοειδής	$f(x) = \frac{1}{1 + e^{-x}}$
Υπερβολική Εφαπτομένη	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
Ακτινική Συνάρτηση Βάσης	$f(x) = e^{-\frac{(x-\mu)^2}{2\sigma^2}}$
Rectified Linear Unit (ReLU)	$f(x) = max\left(0, x\right)$

Πίνακας 3.1: Συχνά χρησιμοποιούμενες συναρτήσεις ενεργοποίησης των FFNN.

Η συνάρτηση ενεργοποίησης (activation function) είναι μια κρίσιμη παράμετρος για τα FFNN, καθώς δίνει στους νευρώνες τη δυνατότητα να επεξεργάζονται μη γραμμικά προβλήματα, προβάλλοντας τα δεδομένα στις κατάλληλες διαστάσεις [39]. Παραδείγματα ευρέως χρησιμοποιούμενων συναρτήσεων ενεργοποίησης παρουσιάζονται στο Πίνακα 3.1 [40], ενώ τα διαγράμματα των συναρτήσεων ενεργοποίησης φαίνονται στο Σχήμα 3.2 [9].


Σχήμα 3.2: Διαγράμματα βασικών συναρτήσεων ενεργοποίησης. (α) Σιγμοειδής Συνάρτηση. (β) Υπερβολική Εφαπτομένη. (γ) Συνάρτηση ReLU. (δ) Ακτινική Συνάρτηση Βάσης.

3.3 **AIKTYA NARX**

Το NARX είναι ένα είδος νευρωνικού δικτύου που χρησιμοποιείται συχνά για την πρόβλεψη χρονοσειρών, ιδιαίτερα σε εφαρμογές όπου υπάρχει ανάγκη για τη μοντελοποίηση της δυναμικής ενός συστήματος με χρονική αυτοσυσχέτιση. Το NARX διαφέρει από τα κλασικά RNN κυρίως λόγω του βρόχου ανατροφοδότησης που έχει. Είναι ιδανικό για εφαρμογές όπου υπάρχει βραχυπρόθεσμη χρονική εξάρτηση, όπως στην πρόβλεψη της παραγωγής φωτοβολταϊκής ενέργειας, καθώς μπορεί να μοντελοποιήσει την χρονοσειρά με ακρίβεια χωρίς να χάνει σε ταχύτητα και απλότητα.

3.3.1 Δομή και τρόπος λειτουργίας NARX

Όπως απεικονίζεται στο Σχήμα 3.3, η βασική δομή του δικτύου NARX είναι πανομοιότυπη με αυτή ενός FFNN, με την προσθήκη ενός βρόχου ανατροφοδότησης εξόδου (ανάδραση) [41]. Σε αντίθεση με τα περισσότερα RNN, τα οποία αναπτύσσουν τις κρυφές καταστάσεις τους βαθιά στον χρόνο, η ανατροφοδότηση που εμπλέκεται σε ένα μοντέλο NARX είναι περιορισμένη. Το μοντέλο NARX επιτρέπει σε κάθε σύνολο δειγμάτων μεταβλητών εισόδου να ενισχύεται με ένα σύνολο παραγόμενων εξόδων με διαφορετικές



Σχήμα 3.3: Δομή του μοντέλου NARX με Κ εξωγενείς εισόδους και Ι ανατροφοδοτήσεις από προηγούμενες τιμές εξόδου

υστερήσεις ανατροφοδότησης. Σε κάθε χρονική στιγμή *t*, η έξοδος *y* του μοντέλου NARX του Σχήματος 3.3 υπολογίζεται ως εξής:

$$y(t) = f_{a,out} \left(b_{out} + \sum_{i=1}^{N} \left(w_i f_{a,hid} \left(b_i + \sum_{j=1}^{K} w_{ji} x_j(t) + \sum_{k=1}^{l} w_{(k+K)i} y(t-d_k) \right) \right) \right)$$
(3.3)

όπου $f_{a,out}$ είναι η συνάρτηση ενεργοποίησης του στρώματος εξόδου, $f_{a,hid}$ είναι η συνάρτηση ενεργοποίησης του κρυφού στρώματος, b_{out} είναι η τιμή πόλωσης (bias) του νευρώνα στο στρώμα εξόδου, b_i είναι η τιμή πόλωσης του νευρώνα i στο κρυφό στρώμα, w_i είναι το βάρος της σύναψης που συνδέει τον νευρώνα i του κρυφού στρώματος με τον νευρώνα στο στρώμα εξόδου, w_{ji} είναι το βάρος της σύναψης που συνδέει τον νευρώνα i του κρυφού στρώματος με τον νευρώνα στο στρώμα εξόδου, w_{ji} είναι το βάρος της σύναψης που συνδέει τον νευρώνα i του στρώματος με τον νευρώνα i του στρώματος εισόδου με τον νευρώνα i του κρυφού στρώματος, $w_{(k+K)i}$ είναι το βάρος της σύναψης που συνδέει την ανατροφοδοτούμενη έξοδο k με τον νευρώνα i του κρυφού στρώματος, και d_k η χρονική υστέρηση της ανατροφοδοτούμενης εξόδου k.

Η βέλτιστη επιλογή του αριθμού των εξόδων ανατροφοδότησης και των αντίστοιχων υστερήσεων εξαρτάται από τα χαρακτηριστικά της χρονοσειράς και τον ορίζοντα πρόβλεψης. Υστερήσεις ανατροφοδότησης που υπερβαίνουν τον ορίζοντα πρόβλεψης δεν έχουν νόημα, καθώς η πραγματική τιμή της χρονοσειράς στόχου θα είναι ήδη διαθέσιμη τη στιγμή που εκδίδεται η πρόβλεψη [41].

Το μοντέλο NARX εκμεταλλεύεται την έξοδο προηγούμενων χρονικών στιγμών. Αυτό καθιστά το μοντέλο NARX κατάλληλη επιλογή για την πρόβλεψη χρονοσειρών με βραχυπρόθεσμες χρονικές συσχετίσεις. Οι χρονοσειρές Φ/Β και αιολικής παραγωγής συνήθως εμφανίζουν ισχυρά διαλείποντα μοτίβα και χρονικές αυτοσυσχετίσεις. Έτσι, μπορεί να είναι ωφέλιμο να περιλαμβάνεται ένας βρόχος ανατροφοδότησης όταν γίνεται πρόβλεψη Φ/Β και αιολικής παραγωγής, ώστε να εισαχθεί μια χρονική διάσταση στο πλαίσιο της πρόβλεψης χωρίς να διακυβεύεται η υπολογιστική αποδοτικότητα. Από την άλλη πλευρά, το μοντέλο NARX τείνει να υπερπροσαρμόζεται στις εξόδους ανατροφοδότησης, ιδιαίτερα σε περιπτώσεις όπου υπάρχουν ισχυρές χρονικές αυτοσυσχετίσεις και οι υστερήσεις ανάδρασης είναι μικρές.

3.4 ΔΙΚΤΥΑ LSTM

Τα δίκτυα LSTM αποτελούν μια εξέλιξη και εξειδίκευση των κλασικών RNN, και αναπτύχθηκαν από τους Hochreiter και Schmidhuber το 1997. Τα LSTM, όπως και τα RNN, αποτελούνται από νευρώνες με ανατροφοδότηση, που συχνά αναφέρονται ως κελιά (cells). Η κυριότερη αιτία που τα LSTM έχουν επικρατήσει μεταξύ των RNN είναι η ικανότητά τους να αναγνωρίζουν και να επεξεργάζονται μακροχρόνιες χρονικές συσχετίσεις στα δεδομένα κατά τη διαδικασία της εκπαίδευσης [42].

3.4.1 Δομή και τρόπος λειτουργίας LSTM

Η αρχιτεκτονική ενός LSTM δεν διαφέρει σημαντικά από εκείνη ενός RNN, αλλά περιλαμβάνει ορισμένα επιμέρους στοιχεία που το καθιστούν πιο αποδοτικό και αποτελεσματικό. Ανάλογα με τη φύση του προβλήματος που εξετάζεται, μπορεί να χρησιμοποιηθεί μία από τις ακόλουθες δύο κατηγορίες LSTM [43]:

 LSTM χωρίς πύλη επιλεκτικής διαγραφής (forget gate): Σε αυτή την αρχιτεκτονική, κάθε κελί διαθέτει μόνο δύο πύλες, την πύλη εισόδου και την πύλη εξόδου. Όπως και στα RNN, καθώς και σε όλες τις δομές LSTM, τα κελιά είναι ανατροφοδοτούμενα. Οι εξισώσεις (3.4) έως (3.8) περιγράφουν ένα LSTM χωρίς πύλη διαγραφής (Σχήμα 3.4):

$$i_t = \sigma(\mathbf{W}_{ih} \cdot \mathbf{h}_{t-1} + \mathbf{W}_{ix} \cdot \mathbf{x}_t + \mathbf{b}_i) \tag{3.4}$$

$$\tilde{c}_{t} = f_{a}(W_{h\tilde{c}} \cdot h_{t} + W_{h\tilde{c}} \cdot x_{t} + b_{\tilde{c}})$$
(3.5)

$$\mathbf{c}_{\mathsf{t}} = \mathbf{c}_{\mathsf{t}-1} + \mathbf{i}_{\mathsf{t}} \cdot \tilde{\mathbf{c}}_{\mathsf{t}} \tag{3.6}$$

$$o_t = \sigma(W_{oh} \cdot h_{t-1} + W_{ox} \cdot x_t + b_o)$$
(3.7)

$$h_t = o_t \cdot f_a(c_t) \tag{3.8}$$

όπου i_t είναι η τελική είσοδος του κελιού, x_t είναι η είσοδος από το προηγούμενο στρώμα, h_t , h_{t-1} είναι η ανατροφοδοτούμενη πληροφορία τη χρονική στιγμή t, t-1 αντίστοιχα, W_{ih} είναι το βάρος σύναψης μεταξύ εισόδου και ανατροφοδότησης, W_{ix} είναι το βάρος σύναψης μεταξύ του τρέχοντος κελιού και του κελιού του προηγούμενου στρώματος, c_t , c_{t-1} η εσωτερική κατάσταση του κελιού (cell state) τη χρονική στιγμή t και t-1 αντίστοιχα, o_t είναι η έξοδος του κελιού προηγούμενου στρώματος, c_t , c_{t-1} η εσωτερική κατάσταση του κελιού (cell state) τη χρονική στιγμή t και t-1 αντίστοιχα, o_t είναι η έξοδος του κελιού, W_{ox} είναι το βάρος σύναψης μεταξύ εξόδου και εισόδου προηγούμενου στρώματος, W_{oh} είναι το βάρος σύναψης μεταξύ εξόδου και ανατροφοδότησης, b_i , b_c , b_o είναι η πόλωση εισόδου, κατάστασης και εξόδου αντίστοιχα και f_a είναι η συνάρτηση ενεργοποίησης



Σχήμα 3.5: Κελί LSTM με επιλεκτική πύλη

2. LSTM με πύλη επιλεκτικής διαγραφής: Το LSTM μπορεί να διατηρεί πληροφορίες από προηγούμενες καταστάσεις, επιτρέποντας έτσι μια πιο αποδοτική διαδικασία εκπαίδευσης. Ωστόσο, αυτή η δυνατότητα ενέχει τον κίνδυνο το κελί να διατηρεί την πληροφορία επ' αόριστον, οδηγώντας σε ανεξέλεγκτη αύξηση της πληροφορίας που αποθηκεύεται. Για να αντιμετωπιστεί αυτό το ζήτημα, οι Gers, Schmidhuber και Cummins (2000) εισήγαγαν την πύλη διαγραφής, η οποία επιτρέπει τη διατήρηση των σημαντικών πληροφοριών και την απόρριψη εκείνων που δεν είναι χρήσιμες [44]. Οι εξισώσεις (3.9) έως (3.14) και το Σχήμα 3.5 περιγράφουν ένα LSTM με πύλη διαγραφής.

$$f_t = \sigma(W_{fh} \cdot h_{t-1} + W_{fx} \cdot x_t + b_f$$
(3.9)

$$\mathbf{i}_{t} = \sigma(\mathbf{W}_{ih} \cdot \mathbf{h}_{t-1} + \mathbf{W}_{ix} \cdot \mathbf{x}_{t} + \mathbf{b}_{i})$$
(3.10)

$$\tilde{c}_{t} = f_{a}(W_{h\tilde{c}} \cdot h_{t} + W_{h\tilde{c}} \cdot x_{t} + b_{\tilde{c}})$$
(3.11)

$$\mathbf{c}_{t} = \mathbf{f}_{t} \cdot \mathbf{c}_{t-1} + \mathbf{i}_{t} \cdot \tilde{\mathbf{c}}_{t} \tag{3.12}$$

$$o_t = \sigma(W_{oh} \cdot h_{t-1} + W_{ox} \cdot x_t + b_o)$$
(3.13)

$$\mathbf{h}_{t} = \mathbf{o}_{t} \cdot \mathbf{f}_{a}(\mathbf{c}_{t}) \tag{3.14}$$

όπου i_t είναι η τελική είσοδος του κελιού, x_t είναι η είσοδος από το προηγούμενο στρώμα, h_t , h_{t-1} είναι η ανατροφοδοτούμενη πληροφορία τη χρονική στιγμή t, t-1

αντίστοιχα, W_{ih} είναι το βάρος σύναψης μεταξύ εισόδου και ανατροφοδότησης, W_{ix} είναι το βάρος σύναψης μεταξύ του τρέχοντος κελιού και του κελιού του προηγούμενου στρώματος, c_t , c_{t-1} η εσωτερική κατάσταση του κελιού (cell state) τη χρονική στιγμή t και t-1 αντίστοιχα, o_t είναι η έξοδος του κελιού, W_{ox} είναι το βάρος σύναψης μεταξύ εξόδου και εισόδου προηγούμενου στρώματος, W_{oh} είναι το βάρος σύναψης μεταξύ εξόδου και ανατροφοδότησης, b_i , b_c , b_o είναι η πόλωση εισόδου, κατάστασης και εξόδου αντίστοιχα και f_a είναι η συνάρτηση ενεργοποίησης. Επίσης, f_t είναι η τιμή της επιλεκτικής πύλης (αν $f_t=1$ η πληροφορία συγκρατείται, αν $f_t=0$ η πληροφορία απορρίπτεται) και b_f είναι η πόλωση της επιλεκτικής πύλης. Αν η πόλωση b_f αρχικοποιηθεί με μια σχετικά μεγάλη τιμή μεταξύ 1 και 2, η γενικότερη απόδοση του LSTM βελτιώνεται, καθώς ανταποκρίνεται καλύτερα στη μέθοδο μείωσης της κλίσης, η οποία παρουσιάζεται παρακάτω[45].

Όπως ήδη αναφέρθηκε το LSTM μπορεί να κρατάει παρελθοντική πληροφορία για πολλές επαναλήψεις κατά την διάρκεια. Οι πληροφορίες περνάνε μέσα από τον νευρώνα του LSTM, ο οποίος αποτελείται από τρεις πύλες. Η πύλη εισόδου, η οποία ρυθμίζει την ροή της πληροφορίας που εισέρχεται στον νευρώνα, η πύλη forget που ρυθμίζει πόση από την πληροφορία της μνήμης μακράς διαρκείας θα περάσει από τον νευρώνα και τέλος η πύλη εξόδου που συνδυάζει την πύλη εισόδου και forget για να παράξει την τελική τιμή h του νευρώνα.

3.5 ΑΛΓΟΡΙΘΜΟΙ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ

Σε κάθε επανάληψη κατά την εκπαίδευση ενός ANN είναι απαραίτητο να γίνει μια σύγκριση μεταξύ των παραγόμενων εξόδων του ANN και των επιθυμητών εξόδων του συνόλου των δειγμάτων εκπαίδευσης. Στη συνέχεια, γίνεται η αναπροσαρμογή των βαρών και των πολώσεων. Πιο συγκεκριμένα, για κάθε δείγμα υπολογίζεται το σφάλμα μεταξύ παραγόμενης και επιθυμητής εξόδου, και στη συνέχεια υπολογίζεται η μέση τιμή αυτών των σφαλμάτων για όλο το σύνολο των δειγμάτων εκπαίδευσης. Σε κάθε επανάληψη κατά την εκπαίδευση ενός ANN, τα βάρη και οι πολώσεις αναπροσαρμόζονται κατάλληλα ώστε να ικανοποιείται η εκάστοτε αντικειμενική συνάρτηση, η οποία έγκειται στην ελαχιστοποίηση της μέσης τιμής της απόκλισης μεταξύ των παραγόμενων και των επιθυμητών εξόδων. Η μέθοδος με την οποία γίνεται αυτή η αναπροσαρμογή καθορίζεται από τον αλγόριθμο βελτιστοποίησης.

3.5.1 Αλγόριθμοι μείωσης της κλίσης

Η μεγιστοποίηση ή η ελαχιστοποίηση μιας συνάρτησης είναι ένα κοινό πρόβλημα σε πολλούς τομείς. Στην επιστήμη των υπολογιστών και στα συστήματα μηχανικής μάθησης υπάρχουν πολλοί αλγόριθμοι βελτιστοποίησης που ορίζουν τον τρόπο με τον οποίο μαθαίνουν τα μοντέλα. Αυτοί οι αλγόριθμοι επιτρέπουν την επιλογή των πιο σημαντικών χαρακτηριστικών, μειώνοντας ταυτόχρονα την ποσότητα των δεδομένων που πρέπει να αποθηκευτούν στη μνήμη, ενώ παράλληλα διατηρούν την ποιότητα των αποτελεσμάτων σε υψηλό επίπεδο. Ανάμεσα σε αυτούς τους αλγορίθμους, οι διάφορες παραλλαγές του αλγορίθμου μείωσης της κλίσης (gradient descent) είναι οι πιο συχνά χρησιμοποιούμενες στη μηχανική μάθηση.





Η μέθοδος της μείωσης της κλίσης χρησιμοποιεί την παράγωγο μιας συνάρτησης για να βρει το ελάχιστό της. Η παράγωγος δηλώνει προς ποια κατεύθυνση πρέπει να κινηθεί η αναζήτηση ώστε να μειωθεί η τιμή της συνάρτησης. Εάν το ζητούμενο είναι η ελαχιστοποίηση της συνάρτησης, η αναζήτηση θα πρέπει να κινηθεί στην αντίθετη κατεύθυνση της κλίσης (δηλαδή εκεί όπου η συνάρτηση μειώνεται).

Υπάρχουν διάφορες παραλλαγές του αλγορίθμου μείωσης της κλίσης:

- Batch Gradient Descent: Ενημερώνει τις παραμέτρους χρησιμοποιώντας ολόκληρο το σύνολο δεδομένων.
- Stochastic Gradient Descent (SGD): Ενημερώνει τις παραμέτρους για κάθε μεμονωμένο δείγμα, επιταχύνοντας την εκπαίδευση αλλά εισάγοντας περισσότερη τυχαιότητα.
- Mini-Batch Gradient Descent: Χρησιμοποιεί μικρές ομάδες δειγμάτων για την ενημέρωση των παραμέτρων, εξισορροπώντας την ακρίβεια και την ταχύτητα σύγκλισης.

Οι αλγόριθμοι που βασίζονται στη μέθοδο μείωσης της κλίσης είναι από τους πιο συνηθισμένους αλγόριθμους βελτιστοποίησης στον τομέα της μηχανικής μάθησης. Για τα ANN, συγκεκριμένα, τα οποία εμπεριέχουν πολλαπλές παραμέτρους οργανωμένες σε επίπεδα, χρησιμοποιούνται οι αλγόριθμοι μείωσης της κλίσης που βασίζονται στην οπίσθια διάδοση του σφάλματος (backpropagation). Οι αλγόριθμοι μείωσης της κλίσης με οπίσθια διάδοση βασίζονται σε δύο κύριες αρχές. Πρώτον, τα βάρη ενημερώνονται έτσι ώστε η παράγωγος της αντικειμενικής συνάρτησης σε σχέση με τις τιμές των βαρών (κλίση) να παραμένει αρνητική, δηλαδή η αντικειμενική συνάρτηση να μειώνεται. Δεύτερον, οι κλίσεις διαδίδονται προς τα πίσω από στρώμα σε στρώμα, ξεκινώντας από το στρώμα εξόδου, μέχρι να ενημερωθούν όλα τα βάρη. Σε κάθε επανάληψη i_t , το βάρος $w_{ji}^{L,L+1}$ που συνδέει τον νευρώνα j του στρώματος L + 1 ενημερώνεται με βάση την εξίσωση (3.15):

$$w_{ji}^{L+1}(it+1) = w_{ji}^{L+1}(it) + \Delta w_{ji}^{L+1}(it+1)$$
(3.15)

$$\Delta w_{ji}^{L+1}(it+1) = a\delta_j^L out_i^{L+1} + m\,\Delta w_{ji}^{L+1}(it)$$
(3.16)

όπου α το μέγεθος βήματος, m η ορμή (momentum), out_i^{L+1} η έξοδος του νευρώνα i του στρώματος L και δ_j^L είναι ο συντελεστής δέλτα για τον νευρώνα j του στρώματος L. Ο συντελεστής δέλτα σχετίζεται με την κλίση και ο τύπος υπολογισμού του εξαρτάται από την αντικειμενική συνάρτηση, τις συναρτήσεις ενεργοποίησης, καθώς και από το στρώμα όπου βρίσκεται ο νευρώνας ενδιαφέροντος. Το μέγεθος βήματος ελέγχει τον βαθμό επίδρασης των κλίσεων στις ενημερώσεις βαρών, ενώ η ορμή αξιοποιεί τις πληροφορίες των προηγούμενων επαναλήψεων για να αποφύγει την παγίδευση σε τοπικά ελάχιστα. Το μέγεθος βήματος είναι καθοριστικής σημασίας για την επιτυχία της σύγκλισης. Ένα πολύ μικρό μέγεθος βήματος οδηγεί σε αργή σύγκλιση, ενώ ένα πολύ μεγάλο μπορεί να εμποδίσει την εύρεση του βέλτιστου σημείου.

Το Σχήμα 3.6 [46] δείχνει τη σύγκριση των καταστάσεων σύγκλισης των αντικειμενικών συναρτήσεων με διαφορετικά μεγέθη βήματος. Στο Σχήμα 3.6 (α) φαίνεται μια ισορροπημένη κατάσταση, όπου το βήμα είναι κατάλληλα επιλεγμένο, επιτρέποντας την ομαλή σύγκλιση προς το ελάχιστο της αντικειμενικής συνάρτησης. Στο Σχήμα 3.6 (β) το βήμα είναι τόσο μικρό που η σύγκλιση είναι αργή. Το σύστημα προσεγγίζει το ελάχιστο πολύ αργά, κάνοντας μικρές αλλαγές σε κάθε επανάληψη, γεγονός που μπορεί να αυξήσει τον χρόνο που απαιτείται για να επιτευχθεί σύγκλιση. Στο Σχήμα 3.6 (γ) το βήμα είναι υπερβολικά μεγάλο, με αποτέλεσμα να προσπερνά το ελάχιστο και να ταλαντώνεται γύρω από αυτό, χωρίς να μπορεί να συγκλίνει. Αυτό μπορεί να προκαλέσει αποσταθεροποίηση του αλγόριθμου και να εμποδίσει τη σωστή σύγκλιση στο ελάχιστο της αντικειμενικής συνάρτησης.

Οι αλγόριθμοι που βασίζονται στη μέθοδο μείωσης της κλίσης χρησιμοποιούνται ευρέως σε εφαρμογές μηχανικής μάθησης, όπως στην εκπαίδευση ANN. Ωστόσο, η μέθοδος αντιμετωπίζει προκλήσεις όπως η εξαφάνιση ή η έκρηξη των κλίσεων και κυρίως η παγίδευση σε τοπικά ελάχιστα. Για τη βελτίωση της σύγκλισης, τεχνικές όπως η χρήση του momentum ή πιο εξελιγμένων αλγορίθμων όπως το Adam [47] μπορούν να χρησιμοποιηθούν. Όπως και άλλοι αλγόριθμοι βελτιστοποίησης, ο Adam χρησιμοποιεί την κλίση της συνάρτησης απώλειας για να ενημερώσει τα βάρη του μοντέλου. Η κλίση αυτή δείχνει την κατεύθυνση και το μέγεθος των αλλαγών που πρέπει να γίνουν στα βάρη για να ελαχιστοποιηθεί η απώλεια.

3.5.2 Μεταευρετικοί αλγόριθμοι

Η τιμή της αντικειμενικής συνάρτησης εξαρτάται από τα βάρη και τις πολώσεις του ANN καθώς και το σύνολο των δειγμάτων εκπαίδευσης. Σκοπός της αντικειμενικής συνάρτησης είναι η ποσοτικοποίηση της απόκλισης μεταξύ παραγόμενων και επιθυμητών εξόδων συνολικά, και η ελαχιστοποίηση αυτής της απόκλισης.

Οι στοχαστικοί αλγόριθμοι βελτιστοποίησης, οι οποίοι χωρίζονται σε ευρετικούς και μεταευρετικούς, δεν απαιτούν τη χρήση παραγώγων [48]. Οι ευρετικοί αλγόριθμοι βασίζονται στη μέθοδο της δοκιμής και του σφάλματος. Αυτοί οι αλγόριθμοι κάνουν ελάχιστες ή καθόλου υποθέσεις για το πρόβλημα που πρόκειται να επιλυθεί. Παρόλο που μπορούν να προσφέρουν ικανοποιητικές λύσεις σε εύλογο χρονικό διάστημα, δεν εξασφαλίζουν την εύρεση της βέλτιστης λύσης, καθώς δεν εξερευνούν εξαντλητικά το πεδίο των πιθανών λύσεων. Χρησιμοποιούνται όταν η εξεύρεση της απόλυτα βέλτιστης λύσης δεν είναι απαραίτητη, αλλά αρκεί μια γρήγορη και επαρκώς καλή λύση [48].

Οι μεταευρετικοί αλγόριθμοι αποτελούν μια προέκταση των ευρετικών. Η διαδικασία αναζήτησης βέλτιστης λύσης μοιάζει με αυτή των ευρετικών, αλλά οι μεταευρετικοί αλγόριθμοι ενσωματώνουν μεθόδους καθολικής (global) αναζήτησης για να αποφεύγεται η παγίδευση σε τοπικά βέλτιστα και μεθόδους τοπικής (local) αναζήτησης για να διασφαλίζεται η σύγκλιση σε μια ικανοποιητική λύση. Αυτό καθιστά τους μεταευρετικούς αλγορίθμους κατάλληλους για προβλήματα καθολικής βελτιστοποίησης, όμως δεν εξασφαλίζουν πάντα την εύρεση καλής λύσης και η απόδοσή τους δεν είναι σταθερή [48]. Παραδείγματα μεταευρετικών αλγορίθμων και των βασικών χαρακτηριστικών τους παρουσιάζονται στο άρθρο [49].

3.5.2.1 Αλγόριθμος PSO

Ο αλγόριθμος βελτιστοποίησης σμήνους σωματιδίων (Particle Swarm Optimization -PSO) είναι ένας μεταευρετικός αλγόριθμος βασισμένος σε πληθυσμούς [50]. Ανήκει στους αλγόριθμους που αντλούν έμπνευση από τη φύση, μιμούμενος την κοινωνική συμπεριφορά και τις κινήσεις ενός σμήνους πτηνών κατά την αναζήτηση τροφής. Όπως τα πτηνά ακολουθούν συγκεκριμένους κανόνες για να εντοπίσουν τροφή μέσα στο σμήνος, έτσι και τα σωματίδια του αλγορίθμου κινούνται μέσα στο πεδίο ορισμού του προβλήματος για να βρουν τη βέλτιστη λύση. Κάθε σωματίδιο αντιπροσωπεύει μια υποψήφια λύση και προσδιορίζεται από τρεις παραμέτρους: (i) την τρέχουσα θέση του (\vec{x}) , (ii) την ταχύτητά του (\vec{v}) , και (iii) την καλύτερη θέση που έχει καταγραφεί (P_{best}). Η θέση ενός σωματιδίου αντιστοιχεί σε μια υποψήφια λύση. Στην περίπτωση που ο αλγόριθμος PSO χρησιμοποιείται για την εκπαίδευση ενός ANN, η θέση του σωματιδίου αντιστοιχεί στα βάρη και τις πολώσεις της τρέχουσας επανάληψης. Η ταχύτητα του σωματιδίου καθορίζει την κατεύθυνση προς την οποία θα κινηθεί, δηλαδή την μεταβολή στα βάρη και τις πολώσεις. Η ποιότητα της θέσης ενός σωματιδίου αξιολογείται μέσω της αντικειμενικής συνάρτησης. Κάθε σωματίδιο αποθηκεύει την καλύτερη θέση που έχει επισκεφτεί, δηλαδή αυτή που ικανοποιεί καλύτερα την αντικειμενική συνάρτηση. Επιπλέον, σε επίπεδο σμήνους, αποθηκεύεται η συνολικά καλύτερη θέση (G_{best}), η οποία είναι η καλύτερη που έχει καταγραφεί μεταξύ όλων των σωματιδίων μέχρι την τρέχουσα επανάληψη.

Σε κάθε επανάληψη, η κίνηση ενός σωματιδίου καθορίζεται από τρεις παράγοντες:

- Το διάνυσμα της ταχύτητας του σωματιδίου από την προηγούμενη επανάληψη,
- Την ατομικά καλύτερη θέση του (P_{best}),
- Τη συνολικά καλύτερη θέση (G_{best}).

Οι εξισώσεις που χρησιμοποιούνται για την ανανέωση της ταχύτητας και της θέσης του σωματιδίου σε κάθε επανάληψη είναι οι ακόλουθες [50]:

$$\vec{v}(n+1) = w\vec{v}(n) + c_1 r_1 \left(\vec{P}_{best} - \vec{x}(n)\right) + c_2 r_2 \left(\vec{G}_{best} - \vec{x}(n)\right)$$
(3.17)

$$\vec{x}(n+1) + \vec{x}(n) + \vec{v}(n+1)$$
 (3.18)

Οι παραπάνω εξισώσεις αφορούν μία διάσταση. Αν το πρόβλημα είναι πολυδιάστατο, τότε εφαρμόζονται για κάθε διάσταση χωριστά. Οι συντεταγμένες της θέσης \vec{x} αντιπροσωπεύουν τα βάρη και τις πολώσεις, και άρα μια πιθανή λύση. Το βάρος αδράνειας w, το οποίο παίρνει τιμές στο διάστημα [0.1, 1.2], επηρεάζει την ικανότητα ενός σωματιδίου να αλλάζει κατεύθυνση. Όσο μικρότερο είναι το w, τόσο γρηγορότερα συγκλίνουν τα σωματίδια, ενώ όσο μεγαλύτερο είναι, τόσο περισσότερο ακολουθούν την τρέχουσα κατεύθυνσή τους, επιβραδύνοντας τη σύγκλιση. Οι συντελεστές c_1 και c_2 , που παίρνουν τιμές στο διάστημα [1, 2], λειτουργούν ως συντελεστές βαρύτητας. Ο c_1 επηρεάζει την ατομικά καλύτερη θέση κάθε σωματιδίου, ενώ ο c_2 την καλύτερη θέση του σμήνους συνολικά. Οι παράγοντες r_1 και r_2 είναι τυχαίες μεταβλητές στο διάστημα [0, 1] που δημιουργούνται για κάθε επανάληψη και κάθε σωματίδιο. Το n είναι ο αριθμός της τρέχουσας επανάληψης.

Η αρχική θέση και ταχύτητα κάθε σωματιδίου καθορίζονται είτε τυχαία είτε με κάποια μέθοδο αρχικοποίησης. Για κάθε σωματίδιο, η αρχική του θέση ορίζεται ως η καλύτερη θέση του (P_{best}). Στη συνέχεια, υπολογίζεται η συνολικά καλύτερη θέση στο σμήνος (G_{best}). Η ταχύτητα και η θέση κάθε σωματιδίου ανανεώνονται σύμφωνα με τις εξισώσεις (3.17) και (3.18), αντίστοιχα, και γίνεται επανεκτίμηση της νέας τους θέσης. Αν η ταχύτητα ή η θέση βγουν έξω από τα όρια του προβλήματος, επαναφέρονται εντός των ορίων. Αν χρειάζεται, ενημερώνονται οι τιμές P_{best} για κάθε σωματίδιο και G_{best} συνολικά για το σμήνος. Η διαδικασία επαναλαμβάνεται μέχρι να ικανοποιηθεί κάποιο κριτήριο τερματισμού, όπως ο μέγιστος αριθμός επαναλήψεων ή η έλλειψη βελτίωσης του G_{best} για πολλές επαναλήψεις. Η τελική τιμή του G_{best} αντιπροσωπεύει τη λύση του προβλήματος.

Ο αλγόριθμος PSO είναι διαχρονικός, δοκιμασμένος και παρουσιάζει ικανοποιητική απόδοση σε πληθώρα προβλημάτων βελτιστοποίησης [51]. Έχει πολλές πρακτικές και ερευνητικές εφαρμογές και είναι ιδανικός για την επίλυση προβλημάτων βελτιστοποίησης παραμέτρων [52]. Είναι πιο αποδοτικός, ταχύτερος και λιγότερο περίπλοκος από άλλους μεταευρετικούς αλγόριθμους. Οι λίγες υπερπαράμετροι που διαθέτει (π.χ., c₁, c₂, w) τον καθιστούν ευέλικτο και πρακτικό. Τέλος, ένα από τα μειονεκτήματά του είναι ότι, λόγω της ταχύτατης σύγκλισης, τα σωματίδια μπορεί να παγιδευτούν σε τοπικά βέλτιστα αντί για το συνολικά καλύτερο αποτέλεσμα.

ΑΝΑΛΥΣΗ ΚΑΙ ΑΞΙΟΛΟΓΗΣΗ ΜΟΝΤΕΛΩΝ ΠΡΟΒΛΕΨΗΣ ΠΑΡΑΓΩΓΗΣ ΙΣΧΥΟΣ

4.1 ΠΕΡΙΓΡΑΦΗ ΜΟΝΤΕΛΩΝ ΚΑΙ ΚΡΙΤΗΡΙΩΝ ΑΞΙΟΛΟΓΗΣΗΣ

Στην παρούσα διπλωματική εργασία γίνεται σύγκριση πέντε μοντέλων τα οποία εκπαιδεύονται στην πρόβλεψη της Φ/Β και αιολικής παραγωγής. Η πρόβλεψη αυτή γίνεται με χρονικό ορίζοντα μίας ώρας, δηλαδή με τα δεδομένα κάποιας χρονικής στιγμής, η πρόβλεψη αφορά την παραγωγή των Φ/Β και των Α/Γ μετά από μία ώρα. Χρησιμοποιούνται δεδομένα για ένα Φ/Β πάρκο και για μία Α/Γ, τα οποία παρουσιάζονται παρακάτω.

Αρχικά, η διαδικασία εκπαίδευσης των μοντέλων για την σύγκρισή τους έγινε για τα δεδομένα που αφορούν την Φ/Β παραγωγή, ενώ σε δεύτερη φάση έγινε εκπαίδευση των μοντέλων για δεδομένα αιολικής παραγωγής. Το πρώτο μοντέλο που εξετάστηκε ήταν το μοντέλο FFNN, έπειτα το μοντέλο NARX, και τέλος το LSTM. Τα μοντέλα που αναφέρθηκαν εκπαιδεύτηκαν με τον αλγόριθμο «μείωσης της κλίσης» που αναλύθηκε στην Ενότητα 3.5.1, καθώς είναι ένας αλγόριθμος συχνά χρησιμοποιούμενος σε προβλήματα μηχανικής μάθησης. Έπειτα, τα μοντέλα FFNN και NARX επανεκπαιδεύτηκαν με τον αλγόριθμο PSO, που παρουσιάστηκε στην Ενότητα 3.5.2.1, ώστε να ελεγχθούν τα αποτελέσματα ίδιων μοντέλων αλλά με διαφορετικό αλγόριθμο βελτιστοποίησης. Λόγω των υψηλών υπολογιστικών απαιτήσεων του μοντέλου LSTM, η επανεκπαίδευση περιορίστηκε στα μοντέλα μηχανικής μάθησης FFNN και NARX.

Η σύγκριση των αποτελεσμάτων των μοντέλων πρόβλεψης Φ/Β και αιολικής παραγωγής έγινε μέσω μίας σειράς μετρητικών αξιολόγησης, που θα αναλυθούν σε βάθος παρακάτω. Για κάθε μοντέλο πραγματοποιούνται δοκιμές με διαφορετικές ρυθμίσεις παραμέτρων, προκειμένου να βρεθεί ο καλύτερος συνδυασμός για τη βελτιστοποίησή τους. Στόχος είναι να επιτευχθούν τα καλύτερα δυνατά αποτελέσματα στην πρόβλεψη της παραγωγής Φ/Β και αιολικής ισχύος. Αφού ολοκληρωθεί η βελτιστοποίηση για κάθε μοντέλο, υπολογίζεται η απόδοσή τους βάσει μετρητικών αξιολόγησης που αναφέρθηκαν, ώστε να γίνει η σύγκριση των μοντέλων μεταξύ τους. Επιπλέον, είναι σημαντικός ο υπολογισμός των χρόνων εκπαίδευσης και εκτέλεσης για κάθε μοντέλο, καθώς με αυτό τον τρόπο γίνεται αντιληπτό το κόστος και η πολυπλοκότητα των μοντέλων σε θεωρητικό επίπεδο και σε συνθήκες πρακτικής εφαρμογής.

4.2 ΑΝΑΛΥΣΗ ΚΑΙ ΕΠΕΞΕΡΓΑΣΙΑ Φ/Β ΚΑΙ ΑΙΟΛΙΚΩΝ ΔΕΔΟΜΕΝΩΝ

Για την εκπαίδευση και αξιολόγηση των μοντέλων πρόβλεψης Φ/Β και αιολικής παραγωγής, χρησιμοποιήθηκαν δεδομένα παραγωγής και μετεωρολογικές μετρήσεις ενός Φ/Β πάρκου και μιας Α/Γ.

Τα αριθμητικά δεδομένα που αφορούν το Φ/Β πάρκο είναι τα εξής:

- 1) Οριζόντια προσπίπτουσα ηλιακή ακτινοβολία (
 $W\cdot m^{-2})$
- 2) Κεκλιμένη προσπίπτουσα ηλιακή ακτινοβολία ($W \cdot m^{-2}$)
- 3) Θερμοκρασία συλλέκτη (°C)
- 4) Σχετική υγρασία (%)
- 5) Θερμοκρασία περιβάλλοντος (°C)
- 6) Ισχύς εξόδου Φ/Β πάρκου (kW)

Αντίστοιχα, τα αριθμητικά δεδομένα που αφορούν την Α/Γ είναι τα εξής:

- 1) Ταχύτητα ανέμου (m/s)
- Κατεύθυνση ανέμου (°)
- 3) Ισχύς εξόδου Α/Γ (kW)

4.2.1 Προέλευση δεδομένων Φ/Β και αιολικής παραγωγής

Τα δεδομένα που χρησιμοποιήθηκαν στην παρούσα διπλωματική εργασία για την εκπαίδευση και αξιολόγηση των μοντέλων πρόβλεψης Φ/Β παραγωγής προέρχονται από πραγματικό Φ/Β σταθμό συνολικής εγκατεστημένης ισχύος 12 MW, στην Ελλάδα. Πιο συγκεκριμένα, όλα τα αριθμητικά δεδομένα συγκεντρώθηκαν τη χρονική περίοδο από 20/07/2022 στις 12 π.μ. έως 31/07/2023 στις 12 π.μ. Οι μετρήσεις έγιναν σε χρονική ανάλυση ενός λεπτού, επομένως η παραγωγή ισχύος για το Φ/Β πάρκο μετρήθηκε 479.461 φορές.

Όσον αφορά την αιολική παραγωγή, τα δεδομένα που χρησιμοποιήθηκαν στην παρούσα διπλωματική εργασία για την εκπαίδευση και αξιολόγηση των μοντέλων πρόβλεψης αιολικής παραγωγής είναι δημόσια διαθέσιμα και προέρχονται από A/Γ 2 MW, τοποθετημένη σε αιολικό πάρκο στο Ηνωμένο Βασίλειο [53]. Πιο συγκεκριμένα, τα δεδομένα εισόδου συγκεντρώθηκαν τη χρονική περίοδο από 01/01/2017 στις 12 π.μ. έως 31/12/2018 στις 23:40 μ.μ. Οι μετρήσεις έγιναν σε χρονική ανάλυση δέκα λεπτών, επομένως η παραγωγή ισχύος για την Α/Γ μετρήθηκε 104005 φορές.

4.2.2 Επεξεργασία δεδομένων

Για να εξασφαλιστεί η αποτελεσματική εκπαίδευση των μοντέλων πρόβλεψης Φ/Β και αιολικής παραγωγής και να επιτευχθούν οι καλύτερες δυνατές προβλέψεις, είναι απαραίτητο να χρησιμοποιηθούν τα κατάλληλα δεδομένα. Αυτό σημαίνει ότι τα δεδομένα πρέπει να είναι αντιπροσωπευτικά του υπό εξέταση προβλήματος, να μην περιέχουν ακραίες ή κενές τιμές, και να υπάρχει επαρκής όγκος δείγματος. Για να διασφαλιστεί η ακρίβεια των αποτελεσμάτων, τα δεδομένα που χρησιμοποιήθηκαν στην παρούσα διπλωματική εργασία πέρασαν από μια διαδικασία καθαρισμού. Ειδικότερα, έγινε απομάκρυνση κενών τιμών ώστε να διασφαλιστεί η ομοιογένεια των δεδομένων και η βελτιστοποίηση της ποιότητάς τους, εξασφαλίζοντας έτσι ότι τα μοντέλα πρόβλεψης θα μπορούν να αποδώσουν με τη μέγιστη δυνατή ακρίβεια.

Μετά τη διαδικασία εκκαθάρισης των δεδομένων, έγινε αναπλήρωση των διαγραμμένων τιμών. Οπουδήποτε υπήρχε κενό κελί, αυτό συμπληρώθηκε με την αμέσως προηγούμενη μετρούμενη τιμή του αντίστοιχου μεγέθους, έτσι ώστε να υπάρχει πληρότητα και ομοιομορφία στα δεδομένα εισόδου. Αυτή η προσέγγιση θεωρείται αξιόπιστη χάρη στην υψηλή χρονική ανάλυση των δεδομένων που χρησιμοποιούνται. Αντιθέτως, σε άλλες περιπτώσεις, όπου τα δεδομένα συλλέγονται σε μικρότερες χρονικές αναλύσεις, η αξιοπιστία αυτής της μεθόδου θα μειωνόταν σημαντικά. Η λεπτομερής καταγραφή των δεδομένων σε μικρά χρονικά διαστήματα επιτρέπει την ακριβέστερη ανάλυση και πρόβλεψη, ενώ η χρήση δεδομένων με λιγότερο συχνή καταγραφή θα μπορούσε να οδηγήσει σε ελλιπή κατανόηση των δυναμικών του συστήματος και, κατά συνέπεια, σε αναξιόπιστα αποτελέσματα.

Μια άλλη σημαντική και συχνά χρησιμοποιούμενη διαδικασία επεξεργασίας των δεδομένων είναι η κανονικοποίηση των τιμών εισόδου και εξόδου. Η κανονικοποίηση, ειδικά στον τομέα της μηχανικής μάθησης, αναφέρεται στη διαδικασία μετασχηματισμού των δεδομένων ώστε να ενταχθούν σε ένα νέο εύρος τιμών, διατηρώντας ταυτόχρονα την αρχική τους κατανομή. Μέσω αυτής της διαδικασίας, διασφαλίζεται ότι δεν θα προκύψουν μεγάλες αποκλίσεις στην κλίμακα των δεδομένων, μειώνοντας παράλληλα την επίδραση ακραίων τιμών. Συνήθως, η κανονικοποίηση πραγματοποιείται στο διάστημα [-1, 1] ή στο διάστημα [0,1].

Στην παρούσα διπλωματική εργασία, τα δεδομένα κανονικοποιήθηκαν στο διάστημα [0, 1] με τη μέθοδο κανονικοποίησης μεγίστου – ελαχίστου, η οποία βασίζεται στην εξίσωση (4.1) [54]:

$$x_{i,scaled} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \tag{4.1}$$

όπου:

- x_{i,scaled}: Κανονικοποιημένη τιμή του δεδομένου i
- x_i: Τιμή του δεδομένου i πριν την κανονικοποίηση
- x_{min}: Ελάχιστη τιμή της κατηγορίας δεδομένων στην οποία ανήκει το δεδομένο i
- x_{max} : Μέγιστη τιμή της κατηγορίας δεδομένων στην οποία ανήκει το δεδομένο i

Μία ακόμα πολύ σημαντική διαδικασία στο πλαίσιο της προετοιμασίας των δεδομένων, είναι ο καταμερισμός των δεδομένων εισόδου και εξόδου σε δύο κατηγορίες: τα δεδομένα εκπαίδευσης και τα δεδομένα αξιολόγησης. Ο στόχος αυτής της διαδικασίας είναι να εκπαιδευτεί το μοντέλο με το σύνολο δεδομένων X_{train} και Y_{train} , αλλά να αξιολογηθεί σε καινούρια δεδομένα (δεδομένα αξιολόγησης) και να διερευνηθεί η γενίκευσή τους. Για να εξασφαλιστεί η αντικειμενικότητα και η γενίκευση του μοντέλου, ως δεδομένα εκπαίδευσης επιλέχθηκε το 70% του συνόλου των διαθέσιμων δεδομένων, ενώ ως δεδομένα δοκιμής το

υπόλοιπο 30%. Αυτή η κατανομή επιτρέπει στο μοντέλο να έχει αρκετά δεδομένα για να εκπαιδευτεί αποτελεσματικά, ενώ παράλληλα διασφαλίζει ότι τα δεδομένα αξιολόγησης είναι επαρκή για να αξιολογηθεί με ακρίβεια η απόδοση του μοντέλου σε νέα, άγνωστα δεδομένα.

4.3 ΜΕΤΡΗΤΙΚΑ ΑΞΙΟΛΟΓΗΣΗΣ

Η σύγκριση των αποτελεσμάτων των μοντέλων θα γίνει μέσω των παρακάτω μετρητικών αξιολόγησης:

1) Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error - MSE). Το MSE είναι ένα ευρέως χρησιμοποιούμενο μετρητικό για την αξιολόγηση της απόδοσης μοντέλων παλινδρόμησης, δημοφιλές για την ικανότητά του να τονίζει μεγαλύτερα σφάλματα. Μετρά τη μέση τετραγωνική διαφορά μεταξύ των προβλεπόμενων τιμών και των πραγματικών τιμών, δίνοντας μεγαλύτερη έμφαση στα μεγαλύτερα σφάλματα από ό,τι στα μικρότερα. Ένα μεγάλο μέγεθος MSE υποδεικνύει κακή απόδοση, ωστόσο το μέτρο δεν βρίσκεται στην ίδια κλίμακα/μονάδα με τις προβλέψεις και τις πραγματικές τιμές. Τα μεγάλα σφάλματα μπορούν να αυξήσουν σημαντικά το MSE, καθιστώντας το έναν χρήσιμο δείκτη όταν τα μεγάλα σφάλματα είναι ιδιαίτερα ανεπιθύμητα [55]. Επιπλέον το MSE χρησιμοποιείται συχνά ως αντικειμενική συνάρτηση κατά την εκπαίδευση νευρωνικών δικτύων. Το μετρητικό αξιολόγησης MSE μπορεί να εκφραστεί μαθηματικά ως:

$$MSE = \frac{1}{N} \sum_{i=1}^{N} (\hat{y}_i - y_i)^2$$
(4.2)

Όπου y_i η πραγματική τιμή του δείγματος i, \hat{y}_i η προβλεπόμενη τιμή του δείγματος i, και N το πλήθος των δειγμάτων.

2) Ρίζα του Μέσου Τετραγωνικού Σφάλματος (Root Mean Squared Error - RMSE): Το RMSE είναι συχνά χρησιμοποιούμενο καθώς έχει τις ίδιες μονάδες μέτρησης με τη μεταβλητή εξόδου και μπορεί να κυμαίνεται από 0 έως το θετικό άπειρο. Χαμηλές τιμές RMSE δείχνουν ότι το μοντέλο κάνει πιο ακριβείς προβλέψεις και ταιριάζει καλύτερα στα δεδομένα. Από την άλλη, υψηλότερες τιμές υποδηλώνουν πιο σημαντικά σφάλματα και λιγότερο ακριβείς προβλέψεις. Το μετρητικό αξιολόγησης RMSE υπολογίζεται ως εξής:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^{N} (\hat{y}_i - y_i)^2}$$
(4.3)

Όπου y_i η πραγματική τιμή του δείγματος i, \hat{y}_i η προβλεπόμενη τιμή του δείγματος i, και N το πλήθος των δειγμάτων.

3) Μέσο Απόλυτο Σφάλμα (Mean Absolute Error - MAE): Το MAE είναι ένα κρίσιμο στατιστικό στοιχείο απόδοσης για μοντέλα παλινδρόμησης, καθώς είναι ένα εργαλείο εύκολο στην κατανόηση, ερμηνεύσιμο και αξιόπιστο για την αξιολόγηση της ακρίβειας των προβλέψεων [56]. Κάποια από τα πλεονεκτήματα του είναι η ανθεκτικότητα σε ακραίες τιμές, καθώς το MAE δεν επηρεάζεται τόσο από ακραία αποτελέσματα όσο άλλες μετρήσεις, όπως το Μέσο Τετραγωνικό Σφάλμα (MSE). Αυτό το καθιστά κατάλληλο μέτρο για σύνολα

δεδομένων που περιλαμβάνουν ακραίες τιμές ή εξαιρέσεις. Επιπλέον, η ερμηνεία του ΜΑΕ είναι εύκολα κατανοητή, καθώς αντιπροσωπεύει το μέσο μέγεθος των σφαλμάτων των προβλέψεων. Το ΜΑΕ εκφράζεται στις ίδιες μονάδες με τη μεταβλητή απόκρισης, κάνοντας εύκολη την κατανόηση του μεγέθους του σφάλματος πρόβλεψης. Το ΜΑΕ υπολογίζεται με τον παρακάτω τύπο:

$$MAE = \frac{1}{N} \sum_{i=0}^{N} |\hat{y}_i - y_i|$$
(4.4)

Όπου y_i η πραγματική τιμή του δείγματος i, \hat{y}_i η προβλεπόμενη τιμή του δείγματος i, και N το πλήθος των δειγμάτων.

4) Σφάλμα Μέσης Πόλωσης (Mean Bias Error - MBE): Το MBE αντανακλά την τάση των μοντέλων πρόβλεψης να υπερεκτιμούν ή να υποεκτιμούν την μεταβλητή εξόδου. Έχει μία κατεύθυνση, θετική ή αρνητική. Θετική μεροληψία υποδηλώνει ένα υπερεκτιμημένο σφάλμα, ενώ αρνητική μεροληψία υποδηλώνει ένα υποεκτιμημένο σφάλμα. Το MBE υπολογίζει τη μέση διαφορά μεταξύ των προβλεπόμενων και των πραγματικών τιμών, ποσοτικοποιώντας τη συνολική μεροληψία χωρίς να λαμβάνει υπόψη τις απόλυτες τιμές. Χρειάζεται προσοχή με το MBE, καθώς τα θετικά και τα αρνητικά σφάλματα μπορούν να αλληλοεξουδετερωθούν. Λόγω της εξουδετέρωσης, το MBE δεν μπορεί να σταθεί μόνο του ως μετρητικό αξιολόγησης, για αυτό πρέπει πάντα να συνδυάζεται με κάποιο άλλο μετρητικό [57]. Το μετρητικό αξιολόγησης MBE, υπολογίζεται ως εξής:

$$MBE = \frac{1}{N} \sum_{i=1}^{N} (x_i - y_i)$$
(4.5)

Όπου y_i η πραγματική τιμή του δείγματος i, \hat{y}_i η προβλεπόμενη τιμή του δείγματος i, και N το πλήθος των δειγμάτων.

5) Μέση Υπερεφαπτομένη του Απόλυτου Ποσοστιαίου Σφάλματος (Mean Arctangent Absolute Percentage Error - MAAPE): Το MAAPE είναι ένα σύγχρονο μετρητικό που προτάθηκε για να αντιμετωπίσει τα προβλήματα που παρουσιάζει το παραδοσιακό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (Mean Absolute Percentage Error - MAPE). Το MAPE είναι πολύ ευαίσθητο σε πραγματικές τιμές κοντά στο μηδέν, κάτι που μπορεί να οδηγήσει σε πολύ μεγάλες και παραπλανητικές τιμές σφάλματος.. Ο μαθηματικός του τύπος είναι:

$$MAPE = \frac{1}{N} \sum_{i=1}^{N} \left(\left| \frac{y_i - \hat{y}_i}{y_i} \right| \right)$$
(4.6)

Επίσης, από την εξίσωση (4.6) είναι φανερό πως για μηδενικές τιμές της μεταβλητής εξόδου το MAPE δεν μπορεί να οριστεί. Επομένως, σε προβλήματα πρόβλεψης ΦΒ και αιολικής

παραγωγής, όπου αναπόφευκτα θα υπάρχουν μηδενικές μετρήσεις λόγω μη παραγωγής, το MAPE είναι ακατάλληλο.

Το MAAPE επιλύει αυτό το πρόβλημα, προσφέροντας μια πιο σταθερή και αξιόπιστη εναλλακτική για την αξιολόγηση της ποσοστιαίας ακρίβειας των προβλέψεων [58]. Ο υπολογισμός του MAAPE βασίζεται στην εφαρμογή της συνάρτησης υπερεφαπτομένης στην απόλυτη ποσοστιαία διαφορά μεταξύ των προβλεπόμενων και των πραγματικών τιμών. Η εξίσωση του MAAPE είναι:

$$MAAPE = \frac{1}{N} \sum_{i=1}^{N} \left(arc \tan\left(\left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \right)$$

$$(4.7)$$

όπου y_i η πραγματική τιμή του δείγματος i, \hat{y}_i η προβλεπόμενη τιμή του δείγματος i, και N το πλήθος των δειγμάτων .

Η συνάρτηση υπερεφαπτομένης διασφαλίζει ότι οι τιμές του σφάλματος είναι πάντα μέσα σε ένα συγκεκριμένο εύρος (0 έως π/2), αποτρέποντας τη διογκωμένη μέτρηση σφάλματος για πραγματικές τιμές κοντά στο μηδέν. Επιπλέον, εφόσον η τιμή του υπερεφαπτομένης είναι πάντα μεταξύ 0 και π/2, το MAAPE αποφεύγει τις ακραίες αποκλίσεις που μπορεί να προκαλέσουν λανθασμένα συμπεράσματα για την ακρίβεια του μοντέλου. Το MAAPE παρέχει μια κανονικοποιημένη προσέγγιση για την αξιολόγηση του σφάλματος. Αυτό σημαίνει ότι μπορούμε να συγκρίνουμε διαφορετικά μοντέλα ή σύνολα δεδομένων με μεγαλύτερη αξιοπιστία, καθώς τα σφάλματα εκφράζονται με παρόμοιο τρόπο ανεξαρτήτως του μεγέθους των πραγματικών τιμών. Ενώ το MAAPE χρησιμοποιεί τη συνάρτηση υπερεφαπτομένης, παραμένει αρκετά εύκολο στην ερμηνεία και παρέχει μια καθαρή εικόνα του κατά πόσο οι προβλέψεις ενός μοντέλου αποκλίνουν από τις πραγματικές τιμές, λαμβάνοντας υπόψη τόσο τη σχετική διαφορά όσο και την ανάγκη αποφυγής υπερβολικών τιμών. Το MAAPE είναι ιδιαίτερα χρήσιμο σε εφαρμογές όπου οι προβλέψεις πρέπει να είναι παράγει τιμές, και ακριβείς ακόμα και όταν οι πραγματικές τιμές είναι πολύ μικρές ή ακραίες, όπως για παράδειγμα σε εφαρμογές αριθμητικών προβλέψεων καιρού.

4.4 ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΠΑΡΑΜΕΤΡΩΝ

Η βελτιστοποίηση παραμέτρων σε μοντέλα πρόβλεψης που βασίζονται σε ANN αποτελεί έναν από τους πιο κρίσιμους παράγοντες για την επιτυχία των μοντέλων αυτών. Πρόκειται για μια διαδικασία που μπορεί να επηρεάσει σημαντικά την απόδοση, την ακρίβεια και τη δυνατότητα γενίκευσης των μοντέλων. Η βελτιστοποίηση παραμέτρων περιλαμβάνει τη ρύθμιση τόσο των υπερπαραμέτρων των μοντέλων όσο και των παραμέτρων εκπαίδευσης, με στόχο τη βελτιστοποίηση κάθε πτυχής της λειτουργίας των μοντέλων πρόβλεψης.

Οι υπερπαράμετροι είναι εκείνες οι παράμετροι που ορίζονται πριν ξεκινήσει η εκπαίδευση. Αυτές περιλαμβάνουν τον αριθμό των κρυφών στρωμάτων, τον αριθμό των νευρώνων σε κάθε στρώμα, τις συναρτήσεις ενεργοποίησης, παραμέτρους σχετικές με τον αλγόριθμο βελτιστοποίησης, τον αριθμό των επαναλήψεων κατά την εκπαίδευση και πολλά άλλα. Καθεμία από αυτές τις υπερπαραμέτρους επηρεάζει τον τρόπο με τον οποίο το μοντέλο μαθαίνει από τα δεδομένα και επομένως καθορίζει την τελική του απόδοση [59]. Οι παράμετροι εκπαίδευσης, από την άλλη πλευρά, περιλαμβάνουν τις τιμές των βαρών και των πολώσεων

του ΑΝΝ, οι οποίες μαθαίνονται κατά τη διάρκεια της εκπαίδευσης μέσω αλγορίθμων βελτιστοποίησης. Η προσεκτική ρύθμιση αυτών των παραμέτρων μέσω της επιλογής κατάλληλων υπερπαραμέτρων είναι ζωτικής σημασίας για την αποδοτική και αποτελεσματική μάθηση ενός ΑΝΝ. Στην παρούσα ενότητα παρουσιάζονται τα αποτελέσματα της βελτιστοποίησης των υπερπαραμέτρων των μοντέλων πρόβλεψης Φ/Β και αιολικής παραγωγής. Η βελτιστοποίηση παραμέτρων ενός ΑΝΝ είναι μια πολυδιάστατη διαδικασία που μπορεί να είναι εξαιρετικά περίπλοκη και χρονοβόρα. Οι κυριότερες προκλήσεις περιλαμβάνουν την υψηλή διαστατικότητα, όπου η μεγάλη ποικιλία παραμέτρων που πρέπει να ρυθμιστούν δημιουργεί έναν πολυδιάστατο γώρο αναζήτησης, καθιστώντας δύσκολη την εύρεση του βέλτιστου συνδυασμού. Επομένως, συνήθως η βελτιστοποίη γίνεται για τις πιο σημαντικές παραμέτρους σε κάθε περίπτωση. Επίσης, ενώ ένα μοντέλο μπορεί να αποδίδει εξαιρετικά καλά στα δεδομένα εκπαίδευσης, υπάρχει πάντα ο κίνδυνος της υπερπροσαρμογής Άρα, για την αποφυγή υπερπροσμαρμογής και την διασφάλιση της ικανότητας γενίκευσης, η αξιολόγηση κάθε συνδυασμού παραμέτρων πρέπει να γίνεται στο σετ αξιολόγησης. Τέλος, η βελτιστοποίηση μπορεί να απαιτεί πολλαπλές επαναλήψεις εκπαίδευσης και δοκιμών, κάτι που μπορεί να είναι εξαιρετικά χρονοβόρο, ειδικά σε μεγάλα ΑΝΝ με πολλά στρώματα και νευρώνες. Στην παρούσα διπλωματική εργασία, λόγω περιορισμένου χρόνου και υπολογιστικών πόρων, δοκιμάστηκαν μόνο αντιπροσωπευτικές τιμές για κάθε παράμετρο με τη μέθοδο αναζήτησης πλέγματος (grid search).

4.4.1 Βελτιστοποίηση παραμέτρων FFNN

Στο μοντέλο FFNN, οι παράμετροι που επιλέχθηκαν προς βελτιστοποίηση είναι ο αριθμός των νευρώνων και η συνάρτηση ενεργοποίησης του κρυφού στρώματος, οι οποίες παίζουν κρίσιμο ρόλο στην απόδοση και την διαμόρφωση του μοντέλου. Για λόγους απλότητας και εξοικονόμησης πόρων, το μοντέλο FFNN επιλέχθηκε να έχει μόνο ένα κρυφό στρώμα. Ως συνάρτηση ενεργοποίησης του στρώματος εξόδου επιλέχθηκε η σιγμοειδής, καθώς τα δεδομένα εξόδου έχουν κανονικοποιηθεί στο διάστημα [0, 1].

Ο αριθμός των νευρώνων σε ένα κρυφό στρώμα καθορίζει τη δυνατότητα του μοντέλου να μαθαίνει και να αναπαριστά σύνθετα μοτίβα στα δεδομένα [60]. Ένας μεγαλύτερος αριθμός νευρώνων μπορεί να επιτρέψει στο μοντέλο να μάθει πιο περίπλοκα μοτίβα, αλλά ενδέχεται επίσης να αυξήσει την πιθανότητα υπερεκπαίδευσης, όπου θνδαξιολόγησης. Από την άλλη πλευρά, πολύ λίγοι νευρώνες μπορεί να οδηγήσουν σε υποεκπαίδευση (underfitting), όπου το μοντέλο δεν είναι αρκετά ισχυρό για να μάθει τα μοτίβα στα δεδομένα. Οι συναρτήσεις ενεργοποίησης που χρησιμοποιήθηκαν για εκπαίδευση των μοντέλων είναι η υπερβολική εφαπτομένη (tanh), η σιγμοειδής, ReLU και η γραμμική.

Όσον αφορά το πλήθος των νευρώνων κρυφού στρώματος, έγιναν δοκιμές για 5 έως και 20 νευρώνες. Στον Πίνακα 4.1 παρουσιάζονται οι βέλτιστες παράμετροι με βάση το μετρητικό αξιολόγησης MSE. Αμφότερες για την Φ/Β και την αιολική παραγωγή, η βέλτιστη συνάρτηση ενεργοποίησης είναι η ReLU, με πλήθος νευρώνων κρυφού στρώματος ίσο με 6 για την Φ/Β παραγωγή και 16 για την αιολική παραγωγή.

Παρατηρείται ότι για την Φ/Β παραγωγή, ο βέλτιστος αριθμός νευρώνων του κρυφού στρώματος είναι αρκετά μικρότερος, γεγονός που πιθανώς ερμηνεύεται λόγω της αυξημένης δυσκολίας πρόβλεψης της αιολικής παραγωγής σε σχέση με την Φ/Β παραγωγή.

	Μεταβλητή Εξόδου		
Παράμετρος	Φ/Β Ισχύς	Αιολική Ισχύς	
Συνάρτηση Ενεργοποίησης	ReLU	ReLU	
Νευρώνες Κρυφού Στρώματος	6	16	

Πίνακας 4.1: Βέλτιστες τιμές των παραμέτρων του μοντέλου FFNN για την πρόβλεψη Φ/Β και αιολικής παραγωγής.

4.4.2 Βελτιστοποίηση παραμέτρων NARX

Στο μοντέλο NARX, οι παράμετροι που επιλέχθηκαν προς βελτιστοποίηση είναι οι νευρώνες κρυφού στρώματος, η χρονική υστέρηση της ανατροφοδότησης, και η συνάρτηση ενεργοποίησης του κρυφού στρώματος, οι οποίες παίζουν κρίσιμο ρόλο στην απόδοση και στην ικανότητα πρόβλεψης του μοντέλου. Η παράμετρος των αριθμών των νευρώνων κρυφού στρώματος και η παράμετρος της συνάρτησης ενεργοποίησης είναι, ακριβώς οι ίδιες παράμετροι όπως και στο ANN και λειτουργούν για τον ίδιο σκοπό: να επιτρέψουν στο δίκτυο να μάθει από τα δεδομένα με τέτοιο τρόπο που να μπορεί να γενικεύσει καλά σε νέα, δεδομένα. Η τρίτη παράμετρος που εξετάστηκε για βελτιστοποίηση ήταν η χρονική υστέρηση ανάδρασης των παραγόμενων εξόδων, μετρούμενη σε λεπτά.

Η χρονική υστέρηση καθορίζει πόσες προηγούμενες τιμές της εξόδου θα χρησιμοποιήσει το μοντέλο κατά την πρόβλεψη της επόμενης τιμής. Για παράδειγμα αν η τιμή της χρονικής υστέρησης ισούται με 5, τότε το μοντέλο χρησιμοποιεί τις τελευταίες 5 τιμές της εξόδου για να κάνει την πρόβλεψη της επόμενης τιμής εξόδου. Η επιλογή της σωστής τιμής για την χρονική υστέρηση είναι κρίσιμη γιατί μια μικρή τιμή μπορεί να μη δίνει αρκετές πληροφορίες για την ορθή πρόβλεψη της μελλοντικής τιμής της μεταβλητής εξόδου, ενώ μία πολύ μεγάλη τιμή της χρονικής υστέρησης μπορεί να περιπλέξει το μοντέλο χωρίς να προσθέσει ουσιαστικές πληροφορίες, οδηγώντας σε υπερεκπαίδευση.

Η επιλογή της χρονικής υστέρησης επηρεάζει τη δομή του ίδιου του μοντέλου, καθώς μία μεγάλη χρονική υστέρηση αυξάνει τον αριθμό των εισόδων στο μοντέλο. Αυτό αυξάνει τη διαστατικότητα του προβλήματος, κάνοντάς το μοντέλο πιο ικανό να μαθαίνει σύνθετες σχέσεις αλλά ταυτόχρονα αυξάνει την πολυπλοκότητα και τον υπολογιστικό φόρτο. Μία μεγάλη χρονική υστέρηση μπορεί να απαιτήσει μεγαλύτερη υπολογιστική ισχύ και να επιβραδύνει τη διαδικασία εκπαίδευσης.

Το μοντέλο μηχανικής μάθησης NARX, για την πρόβλεψη Φ/Β και αιολικής ισχύος, εκπαιδεύτηκε με συναρτήσεις ενεργοποίησης την υπερβολική εφαπτομένη, τη σιγμοειδή, και τη ReLU, οι οποίες έχουν ήδη παρουσιαστεί, ώστε να βγουν τα βέλτιστα αποτελέσματα. Όσον αφορά το πλήθος των νευρώνων κρυφού στρώματος, έγιναν δοκιμές για αριθμό νευρώνων από 5 έως και 20, ενώ για την τιμή της χρονικής υστέρησης, έγιναν δοκιμές για τιμές από 1 έως 56 λεπτά.

	Μεταβλητή Εξόδου		
Παράμετρος	Φ/B	Αιολική	
Συνάρτηση Ενεργοποίησης	ReLU	Tanh	
Νευρώνες Κρυφού Στρώματος	18	13	
Χρονική Υστέρηση Ανατροφοδότησης (λεπτά)	56	6	

Πίνακας 4.2: Βέλτιστες τιμές των παραμέτρων του μοντέλου NARX για την πρόβλεψη Φ/Β και αιολικής παραγωγής.

Στον Πίνακα 4.2 παρουσιάζονται οι βέλτιστες παράμετροι με βάση το μετρητικό αξιολόγησης MSE. Για την Φ/Β παραγωγή η βέλτιστη συνάρτηση ενεργοποίησης είναι η ReLU, με βέλτιστο αριθμό νευρώνων κρυφού στρώματος 18 και βέλτιστη χρονική υστέρηση τα 56 λεπτά. Για την αιολική παραγωγή η βέλτιστη συνάρτηση ενεργοποίησης είναι η Tanh, με βέλτιστο αριθμό νευρώνων κρυφού στρώματος 13 και βέλτιστη χρονική υστέρηση τα 6 λεπτά. Η βέλτιστη χρονική υστέρηση είναι αρκετά μεγαλύτερη για την πρόβλεψη Φ/Β παραγωγής σε σχέση με την πρόβλεψη αιολικής παραγωγής, πιθανώς λόγω της μεγαλύτερης χρονικής αυτοσυσχέτισης που χαρακτηρίζει την Φ/Β παραγωγή. Ο μεγαλύτερος βέλτιστος αριθμός νευρώνων κρυφού στρώματος για την πρόβλεψη Φ/Β παραγωγής πιθανώς οφείλεται στην μεγάλη αύξηση των νευρώνων του στρώματος εισόδου λόγω της μεγάλης χρονικής υστέρησης που αντιστοιχεί στην πρόβλεψη Φ/Β παραγωγής.

4.4.3 Βελτιστοποίηση παραμέτρων LSTM

Στο μοντέλο LSTM, οι παράμετροι που επιλέχθηκαν προς βελτιστοποίηση είναι ο αριθμός νευρώνων κρυφού στρώματος και το μέγεθος της ακολουθίας εισόδου (input sequence), οι οποίες παίζουν κρίσιμο ρόλο στην απόδοση και την διαμόρφωση του μοντέλου. Οι νευρώνες κρυφού στρώματος, είναι ακριβώς η ίδια παράμετρος όπως στο ANN και NARX.

Το μέγεθος της ακολουθίας εισόδου, στο μοντέλο LSTM, αναφέρεται στον αριθμό των προηγούμενων χρονικών βημάτων που χρησιμοποιούνται από το μοντέλο για την παραγωγή μίας πρόβλεψης. Αυτή η παράμετρος αποτελεί κρίσιμο στοιχείο για τον σωστό σχεδιασμό και την αποδοτικότητα του LSTM μοντέλου, ιδιαίτερα όταν αυτό εφαρμόζεται στην ανάλυση χρονοσειρών ή σε δεδομένα με ακολουθιακή δομή.

Μία μικρή ακολουθία εισόδου επιτρέπει στο μοντέλο να λαμβάνει υπόψη μόνο έναν περιορισμένο αριθμό προηγούμενων τιμών. Αντίθετα, μία μεγαλύτερη ακολουθία εισόδου δίνει τη δυνατότητα στο μοντέλο να εξετάζει περισσότερα προηγούμενα δεδομένα, κάτι που μπορεί να αποδειχθεί χρήσιμο σε τέτοιες περιπτώσεις. Ταυτόχρονα, όμως, η αύξηση του

Παράμετρος	Μεταβλητή Εξόδου		
	Φ/B	Αιολική	
Μέγεθος Ακολουθίας Εισόδου	40	15	
Νευρώνες Κρυφού Στρώματος	15	19	

Πίνακας 4.3: Βέλτιστες τιμές των παραμέτρων του μοντέλου LSTM για την πρόβλεψη Φ/Β και αιολικής παραγωγής.

μήκους της ακολουθίας εισόδου ενδέχεται να επιβαρύνει την υπολογιστική πολυπλοκότητα του μοντέλου, καθιστώντας την εκπαίδευσή του πιο δύσκολη και αυξάνοντας τον κίνδυνο υπερεκπαίδευσης.

Το μοντέλο μηχανικής μάθησης LSTM, για την πρόβλεψη Φ/Β και αιολικής ισχύος, εκπαιδεύτηκε με την συνάρτηση ενεργοποίησης Sigmoid. Επιπλέον, όσον αφορά το πλήθος των νευρώνων κρυφού στρώματος, για την Φ/Β και αιολική παραγωγή, έγιναν δοκιμές, για αριθμό νευρώνων από 5 έως 20 με βήμα 1 και για το μέγεθος της ακολουθίας εισόδου έγιναν δοκιμές από 5 έως 40 με βήμα 5.

Στον Πίνακα 4.3 παρουσιάζονται οι βέλτιστοι παράμετροι με βάση το μετρητικό αξιολόγησης MSE. Για την Φ/Β παραγωγή, η βέλτιστη τιμή για το μέγεθος της ακολουθίας εισόδου είναι 40, με βέλτιστο αριθμό νευρώνων κρυφού στρώματος 15. Για την αιολική παραγωγή, η βέλτιστη τιμή για το μέγεθος της ακολουθίας εισόδου είναι 15, με βέλτιστο αριθμό νευρώνων κρυφού στρώματος 19.

Παρατηρείται ότι για την Φ/Β παραγωγή, ο βέλτιστος αριθμός νευρώνων του κρυφού στρώματος είναι μικρότερος, γεγονός που πιθανώς ερμηνεύεται λόγω της αυξημένης δυσκολίας πρόβλεψης της αιολικής παραγωγής σε σχέση με την Φ/Β παραγωγή.

4.4.4 Βελτιστοποίηση παραμέτρων FFNN-PSO

Στο μοντέλο FFNN με αλγόριθμο βελτιστοποίησης PSO, οι παράμετροι που επιλέχθηκαν προς βελτιστοποίηση είναι ο αριθμός σωματιδίων στο σμήνος (n particles), το c_1 , το c_2 , το w_{min} , και το w_{max} .

Όσο μεγαλύτερος είναι ο αριθμός των σωματιδίων, τόσο περισσότερες πιθανές λύσεις εξετάζονται από τον αλγόριθμο. Με λιγότερα σωματίδια, ο αλγόριθμος μπορεί να συγκλίνει γρηγορότερα, αλλά με κίνδυνο να παραβλέψει βέλτιστες λύσεις.

Ένας υψηλός συντελεστής c_1 υποδεικνύει ότι το σωματίδιο θα τείνει να επιστρέφει συχνά στην προσωπική του καλύτερη θέση. Ένας υψηλός συντελεστής c_2 ενθαρρύνει το σωματίδιο να ακολουθεί το σμήνος, βοηθώντας στη σύγκλιση προς μια καλή λύση, ιδιαίτερα

Παράμετρος	Μεταβλητή Εξόδου		
	Φ/B	Αιολική	
Πλήθος Σωματιδίων	120	40	
<i>c</i> ₁	2.0	0.5	
<i>c</i> ₂	2.0	0.5	
W _{max}	0.9	0.9	
W _{min}	0.4	0.1	

Πίνακας 4.4: Βέλτιστες τιμές των παραμέτρων του μοντέλου FFNN-PSO για την πρόβλεψη Φ/Β και αιολικής παραγωγής.

όταν το σμήνος έχει βρει μια αποδοτική περιοχή [61] ενώ, ένας χαμηλός συντελεστής c_2 μειώνει την επιρροή του σμήνους, αυξάνοντας την ποικιλία των λύσεων, αλλά μπορεί να επιβραδύνει τη σύγκλιση. Με τιμή w κοντά στο w_{max} τα σωματίδια τείνουν να διατηρούν τη φορά της κίνησής τους, εξερευνώντας μεγαλύτερες περιοχές του χώρου των λύσεων, ενώ με τιμή w κοντά στο w_{min} τα σωματίδια μειώνουν τη φορά της κίνησής τους και τείνουν να συγκλίνουν προς την καλύτερη θέση που έχει βρεθεί.

Στο μοντέλο FFNN-PSO, για την πρόβλεψη Φ/B και αιολικής ισχύος, έγιναν δοκιμές για τιμές c_1 , c_2 από 0.5 έως 2.0 και w_{min} , w_{max} από 0.1 έως 1.0. Επιπλέον, όσον αφορά τον αριθμό σωματιδίων, έγιναν δοκιμές για τιμές από το 40 μέχρι και το 140 με βήμα 20. Στον Πίνακα 4.4 παρουσιάζονται οι βέλτιστοι παράμετροι με βάση το μετρητικό αξιολόγησης MSE. Για την Φ/B παραγωγή, οι βέλτιστες τιμές είναι: $c_1 = 2.0$, $c_2 = 2.0$, $w_{min} = 0.4$, $w_{max} = 0.9$ και αριθμός σωματιδίων 120. Για την αιολική παραγωγή, βέλτιστες τιμές $c_1 = 0.5$, $c_2 = 0.5$, $w_{min} = 0.1$, $w_{max} = 0.9$ και αριθμό σωματιδίων 40.

Παρατηρείται ότι στην Φ/Β παραγωγή η βέλτιστη τιμή των c_1 , c_2 είναι η μέγιστη τιμή οπότε, η Φ/Β παραγωγή δίνει μεγαλύτερη βαρύτητα στην καλύτερη καταγεγραμμένη θέση. Η βέλτιστη τιμή των c_1 , c_2 πιθανώς οφείλεται στο γεγονός ότι στην Φ/Β παραγωγή υπάρχουν λιγότερα τοπικά ελάχιστα, λόγω μεγαλύτερης απλότητας του προβλήματος, κάτι το οποίο δεν ισχύει για την αιολική παραγωγή.

4.4.5 Βελτιστοποίηση παραμέτρων NARX-PSO

Στο μοντέλο NARX με αλγόριθμο βελτιστοποίησης PSO, οι παράμετροι που επιλέχθηκαν προς βελτιστοποίηση είναι ο αριθμός σωματιδίων στο σμήνος, το c_1 , το c_2 , το w_{min} , το w_{max} , η χρονική υστέρηση ανατροφοδότησης και ο αριθμός των επαναλήψεων.

Παράμετροι	Μεταβλητή Εξόδου		
	Φ/B	Αιολική	
Αριθμός Επαναλήψεων	30	30	
Αριθμός Σωματιδίων	30	30	
Χρονική Υστέρηση Ανατροφοδότησης (λεπτά)	5	10	
<i>c</i> ₁	2.0	0.5	
<i>C</i> ₂	2.0	0.5	
W _{max}	0.9	0.9	
W _{min}	0.4	0.1	

Πίνακας 4.5: Βέλτιστες τιμές των παραμέτρων του μοντέλου NARX-PSO για την πρόβλεψη Φ/Β και αιολικής παραγωγής.

Ο αριθμός σωματιδίων στο σμήνος, το c_1 , το c_2 , το w_{min} , το w_{max} και η χρονική υστέρηση ανατροφοδότησης είναι παράμετροι που έχουν, ήδη, παρουσιαστεί. Ο αριθμός των επαναλήψεων αναφέρεται στις επαναλήψεις που εκτελεί ο PSO για να βελτιστοποιήσει τις παραμέτρους του μοντέλου. Ένας πολύ μεγάλος αριθμός επαναλήψεων πιθανώς να οδηγήσει σε υψηλό υπολογιστικό φόρτο, χωρίς σημαντικές βελτιώσεις στη λύση.

Η επιλογή των c_1 , c_2 , w_{min} και w_{max} έγινε με βάση τις βέλτιστες τιμές που προέκυψαν από την εκπαίδευση του μοντέλου FFNN-PSO. Οπότε, για την Φ/Β παραγωγή η εκπαίδευση έγινε με $c_1 = 2.0$, $c_2 = 2.0$, $w_{min} = 0.4$, $w_{max} = 0.9$ και για την αιολική παραγωγή με $c_1 = 0.5$, $c_2 = 0.5$, $w_{min} = 0.1$, $w_{max} = 0.9$.

Επιπλέον για την Φ/Β και αιολική παραγωγή έγιναν δοκιμές με τιμές για τον αριθμό σωματιδίων από 10 έως 40 με βήμα 10 και για την χρονική υστέρηση ανατροφοδότησης με τιμές από 1 έως 20 λεπτά με βήμα 5. Στο NARX PSO, έγιναν δοκιμές για μικρότερο αριθμό σωματιδίων, σε σχέση με το FFNN-PSO, καθώς ο μεγάλος αριθμός σωματιδίων οδηγούσε σε πολύ μεγάλη υπολογιστική πολυπλοκότητα του μοντέλου και αύξηση των χρόνων εκπαίδευσης και πρόβλεψης.

Στον πίνακα 4.5 παρουσιάζονται οι βέλτιστοι παράμετροι με βάση το μετρητικό αξιολόγησης MSE. Για την Φ/Β παραγωγή, η βέλτιστη τιμή για το πλήθος σωματιδίων είναι 30, ο βέλτιστος αριθμός επαναλήψεων 30 και βέλτιστη χρονική υστέρηση ανατροφοδότησης είναι 5 λεπτά. Για την αιολική παραγωγή η βέλτιστη τιμή για το πλήθος σωματιδίων είναι 30, ο βέλτιστος αριθμός επαναλήψεων 30 και η βέλτιστη χρονική υστέρηση ανατροφοδότησης είναι 10 λεπτά. Παρατηρείται ότι στην Φ/Β παραγωγή η βέλτιστη τιμή των c_1 , c_2 είναι η μέγιστη τιμή οπότε, η Φ/Β παραγωγή δίνει μεγαλύτερη βαρύτητα στην καλύτερη καταγεγραμμένη θέση. Η βέλτιστη τιμή των c_1 , c_2 πιθανώς οφείλεται στο γεγονός ότι στην Φ/Β παραγωγή υπάρχουν λιγότερα τοπικά ελάχιστα, λόγω μεγαλύτερης απλότητας του προβλήματος, κάτι το οποίο δεν ισχύει για την αιολική παραγωγή.

ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΣΥΓΚΡΙΣΗ ΜΟΝΤΕΛΩΝ

Στο παρόν κεφάλαιο παρουσιάζονται τα αποτελέσματα των μοντέλων στην βραχυπρόθεσμη πρόβλεψη Φ/B και αιολικής παραγωγής και γίνεται σύγκριση των αποτελεσμάτων με σκοπό την ανάδειξη του μοντέλου με την βέλτιστη απόδοση στην πρόβλεψη Φ/B και αιολικής.

5.1 ΑΠΟΤΕΛΕΣΜΑΤΑ Φ/Β ΠΑΡΑΓΩΓΗΣ

Ενδεικτικά αποτελέσματα της πρόβλεψης Φ/Β παραγωγής παρουσιάζονται στα διαγράμματα που αντιστοιχούν στα Σχήματα 5.1, 5.2, 5.3 και 5.4. Τα διαγράμματα συγκρίνουν τις πραγματικές τιμές ισχύος με τις τιμές που προβλέπουν τα μοντέλα σε μια περίοδο 24 ωρών. Στα Σχήματα 5.1 και 5.2, απεικονίζονται δύο ημέρες οι οποίες χαρακτηρίζονται από πλήρη ηλιοφάνεια και αυξημένη παραγωγή ισχύος. Οι συγκεκριμένες ημέρες είναι κατά την διάρκεια των χειμερινών μηνών, κατά τους οποίους νυχτώνει περίπου στις 6μμ, όπως φαίνεται και από τις καμπύλες Φ/Β παραγωγής των Σχημάτων 5.1 και 5.2. Στο Σχήμα 5.1 παρατηρείται πλήρης ηλιοφάνεια κατά την διάρκεια όλης της ημέρας. Στο Σχήμα 5.2, την περισσότερη ώρα της ημέρας παρατηρείται ηλιοφάνεια, ενώ κάποιες μεσημεριανές ώρες, η παραγωγή έχει απότομες διακυμάνσεις, γεγονός που υποδηλώνει ότι κάποιες ώρες υπήρξε συννεφιά ή ακόμα και βροχόπτωση. Η πραγματική παραγωγή απεικονίζεται με την μπλε καμπύλη, η οποία λειτουργεί ως σημείο αναφοράς για την αξιολόγηση των προβλέψεων των μοντέλων. Η διαφορά μεταξύ των προβλέψεων και των πραγματικών τιμών καταδεικνύει την ικανότητα των μοντέλων να αποδίδουν με ακρίβεια υπό σταθερές ηλιακές συνθήκες. Στα διαγράμματα γίνεται εμφανές ότι το μοντέλο NARX, που αποδίδεται με την πράσινη καμπύλη, παρουσιάζει σημαντικές αποκλίσεις σε σχέση με την πραγματική παραγωγή ισχύος.

Στα Σχήματα 5.3 και 5.4 παρουσιάζονται διαγράμματα που αφορούν επίσης δύο περιόδους 24 ωρών κατά τους χειμερινούς μήνες, ωστόσο σε διαφορετικές συνθήκες σε σχέση με τα Σχήματα 5.1 και 5.2, καθώς πρόκειται για δύο ημέρες με άστατο καιρό και την έντονη παρουσία νεφώσεων, γεγονός που έχει ως αποτέλεσμα ασταθή Φ/Β παραγωγή. Στο Σχήμα 5.3 η παραγωγή φτάνει το μέγιστο επίπεδο κατά το 9% της συνολικής διάρκειας της ημέρας. Τις υπόλοιπες ώρες η παραγωγή παρουσιάζει πολλές διακυμάνσεις υποδεικνύοντας την ύπαρξη έντονων νεφώσεων. Συγκεκριμένα, γύρω στις 8πμ παρατηρείται μία απότομη μείωση της παραγωγής, η οποία παραμένει αρκετά μειωμένη μέχρι και τις 12μμ, και αμέσως μετά παρατηρείται μία ξαφνική αύξηση της παραγωγής, η οποία φτάνει την ονομαστική ισχύ. Στο Σχήμα 5.4 η παραγωγή φτάνει το μέγιστο επίπεδο κατά το 9% της συνολικής διάρκειας της ημέρας. Αντιθέτως, στα Σχήματα 5.1 και 5.2 η παραγωγή φτάνει το μέγιστο επίπεδό κατά το 18% της συνολικής διάρκειας της ημέρας, όμως σε αντίθεση με τα Σχήματα 5.3 και 5.4 η παραγωγή δεν έχει διακυμάνσεις και η τιμή της παραμένει αρκετά υψηλή. Συγκεκριμένα στο Σχήμα 5.3 παρατηρείται ότι υπάρχουν συνολικά τέσσερις έντονες διακυμάνσεις, το οποίο υποδηλώνει τις απότομες αλλαγές στις καιρικές συνθήκες. Επομένως, τα Σχήματα 5.1 και 5.2 δείχνουν ημέρες με μέγιστη δυνατή παραγωγή ισχύος σχεδόν όλες τις ώρες της ημέρας, ενώ τα Σχήματα 5.3 και 5.4 απεικονίζουν ημέρες όπου η παραγωγή είναι η μέγιστη δυνατή για λιγότερες ώρες. Όλα τα μοντέλα πρόβλεψης Φ/Β παραγωγής, εκτός του NARX, καταφέρνουν να προσεγγίσουν με σχετικά μεγάλη ακρίβεια την πραγματική παραγωγή, παρά τις μεταβολές στις καιρικές συνθήκες. Για αυτό τον λόγο θεωρείται πως δεν έχει πλέον νόημα η περεταίρω αξιολόγηση του μοντέλου NARX.

Στα Σχήματα 5.5(α), 5.5(β), 5.5(γ), και 5.5(δ), συγκρίνονται οι πραγματικές τιμές της Φ/Β ισχύος με τις προβλεπόμενες τιμές που παράγονται από τα μοντέλα FFNN, FFNN-PSO, LSTM και NARX-PSO, αντίστοιχα. Τα Σχήματα 5.5(α), 5.5(β), 5.5(γ) και 5.5(δ) αφορούν την ημέρα που παρουσιάζεται και στο Σχήμα 5.3, δηλαδή μία ημέρα κατά του χειμερινούς μήνες. Η πραγματική και η προβλεπόμενη παραγωγή απεικονίζονται με μπλε και κίτρινο χρώμα, αντίστοιχα. Οι διαφορές μεταξύ των προβλέψεων και των πραγματικών τιμών ποικίλλουν σημαντικά ανάλογα με το εκάστοτε μοντέλο, προσφέροντας σημαντικές ενδείξεις σχετικά με την ακρίβεια και την αποτελεσματικότητα των μοντέλων πρόβλεψης. Στα Σχήματα 5.5(α) και 5.5(β) απεικονίζονται τα αποτελέσματα των μοντέλων FFNN και FFNN-PSO, αντίστοιχα. Στα συγκεκριμένα διαγράμματα παρατηρείται μια σαφής απόκλιση ανάμεσα στις καμπύλες των προβλέψεων και των πραγματικών τιμών στον οριζόντιο άξονα του χρόνου (ώρα ημέρας). Η απόκλιση αυτή ξεπερνάει τον χρονικό ορίζοντα της μίας ώρας, κάτι που υποδηλώνει ότι τα συγκεκριμένα μοντέλα παρουσιάζουν μειωμένη ακρίβεια στις προβλέψεις τους. Αμφότερα δηλαδή τα μοντέλα FFNN και FFNN-PSO φαίνεται να ακολουθούν την σχετική τάση της παραγωγής, αλλά με την χρονική υστέρηση που παρατηρείται. Η ύπαρξη της χρονικής υστέρησης τα καθιστά μη αποδοτικά, καθώς όταν η χρονική υστέρηση ξεπερνάει τον χρονικό ορίζοντα πρόβλεψης, οι σωστές τιμές της παραγωγής έχουν ήδη παρατηρηθεί μέσω μέτρησης, επομένως η πρόβλεψη δεν έχει νόημα.



Σχήμα 5.1: Σύγκριση των πραγματικών τιμών ισχύος με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης Φ/Β παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με πλήρη ηλιοφάνεια.



Σχήμα 5.2: Σύγκριση των πραγματικών τιμών ισχύος με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης Φ/Β παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με ηλιοφάνεια και λίγες νεφώσεις κατά την διάρκεια των μεσημεριανών ωρών.



Σχήμα 5.3: Σύγκριση των πραγματικών τιμών ισχύος με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης Φ/Β παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με έντονες διακυμάνσεις στην παραγωγή και πλήρη νεφοκάλυψη κατά τις μεσημεριανές ώρες.



Σχήμα 5.4: Σύγκριση των πραγματικών τιμών ισχύος με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης Φ/Β παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με έντονες διακυμάνσεις στην παραγωγή και νεφοκάλυψη καθόλη τη διάρκεια της ημέρας.

Αντίθετα, το μοντέλο LSTM, οι προβλέψεις του οποίου παρουσιάζονται στο Σχήμα 5.5 (γ), παρουσιάζει μικρότερη απόκλιση μεταξύ των προβλέψεων και των πραγματικών τιμών στον οριζόντιο άξονα του χρόνου, με την χρονική υστέρηση να παραμένει εντός του χρονικού ορίζοντα, με τιμή περίπου 20 λεπτά. Η μειωμένη χρονική υστέρηση υποδηλώνει ότι το μοντέλο διαχειρίζεται καλύτερα τις χρονικές ακολουθίες, βελτιώνοντας τόσο την ακρίβεια όσο και τη συνολική αξιοπιστία των προβλέψεων. Η μειωμένη τιμή της χρονικής υστέρησης οφείλεται στην καλύτερη διαχείριση των χρονικών ακολουθιών από το μοντέλο LSTM, το οποίο μέσω των κελιών μνήμης και των πυλών καταφέρνει να διατηρεί σημαντικές πληροφορίες για μεγαλύτερα γρονικά διαστήματα, βελτιώνοντας την πρόβλεψη. Στα Σχήματα 5.5(α) και 5.5(γ), παρατηρείται ότι το μοντέλο FFNN καταφέρνει να αποτυπώσει με μεγαλύτερη ακρίβεια την καμπύλη της πραγματικής παραγωγής, αλλά με πολύ μεγάλη χρονική υστέρηση. Σε αντίθεση, στην προσπάθειά του να μειώσει την χρονική υστέρηση και να παράξει προβλέψεις που είναι πιο ακριβείς, το LSTM δεν καταφέρνει να αποτυπώσει με την ίδια ακρίβεια την καμπύλη της πραγματικής παραγωγής. Ωστόσο, τελικά το μοντέλο LSTM καταφέρνει να προβλέψει την πραγματική παραγωγή καλύτερα από το FFNN, το οποίο φαίνεται και στο Σχήμα 5.5(γ), όπου η καμπύλη των προβλέψεων τέμνει και ταυτίζεται με την καμπύλη της πραγματικής παραγωγής σε σχέση με το FFNN, στα Σχήματα $5.5(\alpha)$ και $5.5(\beta)$.

Όσον αφορά το μοντέλο NARX-PSO, το οποίο παρουσιάζεται στο Σχήμα 5.5 (δ), παρατηρείται ότι η χρονική υστέρηση σχεδόν εκμηδενίζεται, κάτι που οφείλεται κυρίως στην ανάδραση της εξόδου σε συνδυασμό με την βελτιστοποίηση που προσφέρει ο αλγόριθμος PSO. Ο συνδυασμός αυτών των τεχνικών επιτρέπει στο μοντέλο να προσαρμόζεται καλύτερα στις εισόδου, διατηρώντας μνήμη των προηγούμενων τιμών με αποτέλεσμα την ελαχιστοποίηση της χρονικής υστέρησης. Η καμπύλη των προβλέψεων ακολουθεί πιστά τη γενική τάση της



 (γ) LSTM



Σχήμα 5.5 : Σύγκριση της πραγματικής παραγωγής με τις τιμές των προβλέψεων των μοντέλων της Φ/Β παραγωγής σε χρονική διάρκεια 24 ωρών.

παραγωγής, χωρίς να εμφανίζει αξιοσημείωτη καθυστέρηση, επομένως το μοντέλο NARX-PSO καταφέρνει να προβλέπει με μεγάλη ακρίβεια την παραγωγή της Φ/Β ισχύος.

Τέλος, μοντέλα FFNN και LSTM διαχειρίζονται πιο αποτελεσματικά τις χρονικές περιόδους όπου οι τιμές της Φ/B ισχύος είναι μηδενικές, σε αντίθεση με τα μοντέλα NARX-PSO και FFNN-PSO που δυσκολεύονται στην διαχείριση των μηδενικών τιμών. Από τα Σγήματα 5.5(α), 5.5(β), 5.5(γ), και 5.5(δ), παρατηρείται ότι όταν η πραγματική παραγωγή είναι μηδενική, δηλαδή κατά τις βραδινές ώρες όπου δεν υπάρχει ηλιοφάνεια, τα μοντέλα FFNN και LSTM παράγουν ακριβείς προβλέψεις, ενώ τα μοντέλα FFNN-PSO και NARX-PSO υπερεκτιμούν συστηματικά την παραγωγή. Η κύρια αιτία που τα μοντέλα NARX-PSO και ,FFNN-PSO παράγουν αυξημένες προβλέψεις όταν η πραγματική παραγωγή είναι μηδενική μπορεί να σχετίζεται με το ότι χρησιμοποιούν τον αλγόριθμο PSO για τη βελτιστοποίηση των παραμέτρων τους. Ο αλγόριθμος PSO, αν και διακρίνεται για τις ικανότητες σύγκλισης που έχει σε σχέση με άλλους μεταευρετικούς αλγορίθμους, υστερεί στον βαθμό σύγκλισης σε σχέση με τους αλγορίθμους που βασίζονται στη μείωση της κλίσης. Επομένως, η συστηματική υπερεκτίμηση των μηδενικών τιμών παραγωγής ίσως να οφείλεται στην αδυναμία επαρκούς σύγκλισης του PSO κατά την εκπαίδευση των μοντέλων NARX και FFNN. Θεωρητικά, ωστόσο, θα ήταν δυνατή η αφαίρεση των δεδομένων των βραδινών ωρών από το σετ δεδομένων εκπαίδευσης, αφού δεν συνεισφέρουν στην πραγματική παραγωγή και επομένως δεν υπάρχει η ανάγκη για πρόβλεψη. Λόγω χρονικού περιορισμού, ωστόσο, δεν πραγματοποιήθηκε κάτι τέτοιο στα πλαίσια της παρούσας διπλωματικής εργασίας.

Στον Πίνακα 5.1 παρουσιάζονται συγκεντρωτικά τα τελικά αποτελέσματα των μοντέλων πρόβλεψης Φ/Β παραγωγής. Η σύγκριση γίνεται με βάση τα πέντε μετρητικά αξιολόγησης που παρουσιάστηκαν στην Ενότητα 4.3. Ταυτόχρονα, ο Πίνακας 5.1 περιλαμβάνει τον μέσο χρόνο εκπαίδευσης και εκτέλεσης για το κάθε μοντέλο. Η ανάλυση των μοντέλων δείχνει, με σαφήνεια, ότι το NARX-PSO υπερέχει σε όλα τα μετρητικά αξιολόγησης, με βασικά μετρητικά αξιολόγησης τα nMSE και nRMSE, με τιμές 0.0009 και 0.030, αντίστοιχα, γεγονός που το καθιστά το πιο αξιόπιστο μοντέλο ως προς την ακρίβεια των προβλέψεων. Η ικανότητα του NARX-PSO στην παραγωγή προβλέψεων υποδηλώνει ότι ο

	Πρόβλεψη Φ/Β Παραγωγής				
Μοντέλο Μηχανικής Μάθησης	FFNN	NARX	LSTM	FFNN-PSO	NARX-PSO
nMSE (pu)	0.024	0.023	0.015	0.026	0.0009
nRMSE (pu)	0.155	0.153	0.124	0.162	0.030
nMAE (pu)	0.088	0.099	0.062	0.095	0.044
nMBE (pu)	-0.019	-0.021	-0.022	-0.043	-0.0023
MAAPE (%)	50.266	53.469	46.440	52.239	45.298
Χρόνος Εκτέλεσης (us)	0.051	0.019	0.140	0.051	0.019
Χρόνος Εκπαίδευσης (s)	16.385	243.320	503.814	345.548	5695.143

Πίνακας 5.1: Τελικά αποτελέσματα των μοντέλων πρόβλεψης Φ/Β παραγωγής

συνδυασμός ανατροφοδότησης και μεταευρετικού αλγορίθμου οδηγεί στην βέλτιστη απόδοση. Ωστόσο, αυτό το πλεονέκτημα συνοδεύεται από έναν σημαντικά αυξημένο χρόνο εκπαίδευσης, ίσο με 5695.143 δευτερόλεπτα. Ο υψηλός χρόνος εκπαίδευσης στις περισσότερες εφαρμογές δεν αποτελεί πρόβλημα, με εξαίρεση κάποιες εφαρμογές όπου απαιτούνται επανεκπαιδεύσεις του μοντέλου σε πραγματικό χρόνο (online training). Ο χρόνος εκτέλεσης αναφέρεται στον χρόνο που χρειάζεται κάθε μοντέλο για την παραγωγή μίας πρόβλεψης. Από τον Πίνακα 5.1, παρατηρούμε ότι το μοντέλο NARX-PSO έχει τον μικρότερο χρόνο εκτέλεσης, με τιμή 0.019 us. Αντίθετα, το LSTM έχει τον μεγαλύτερο χρόνο εκτέλεσης, με τιμή 0.140 us. Ο χρόνος εκτέλεσης είναι ιδιαίτερα σημαντικός σε εφαρμογές όπου απαιτείται παραγωγή προβλέψεων ανά πολύ μικρά χρονικά διαστήματα.

Τα αποτελέσματα των μοντέλων FFNN και FFNN-PSO είναι παρόμοια ως προς την ακρίβεια των προβλέψεων, επομένως η χρήση του αλγορίθμου PSO για την εκπαίδευση του μοντέλου FFNN δεν προσφέρει κάποια βελτίωση, παρόλο που απαιτείται περισσότερος χρόνος εκπαίδευσης. Η ποσοστιαία βελτίωση του FFNN σε σχέση με το FFNN-PSO είναι 7% (με βάση το MAE). Αυτό πιθανώς να οφείλεται στις ιδιαιτερότητες της αρχιτεκτονικής του FFNN, η οποία δεν εκμεταλλεύεται τον αλγόριθμο βελτιστοποίησης PSO. Συγκεκριμένα, το FFNN δεν διαθέτει εσωτερικούς μηχανισμούς μνήμης και ανατροφοδότησης, κάτι που περιορίζει την ικανότητά του να επωφεληθεί από μακροπρόθεσμες χρονικές εξαρτήσεις. Έτσι, η απλότητα της δομής του FFNN περιορίζει τις βελτιώσεις που μπορεί να προσφέρει ο PSO, καθώς υπάρχουν λιγότερες παράμετροι για βελτιστοποίηση.

Παρόλο που το μοντέλο LSTM δεν επιτυγχάνει την ίδια απόδοση με το NARX-PSO, οι τιμές των μετρητικών δεικτών αξιολόγησης καταδεικνύουν ότι αποτελεί ένα εξαιρετικά αποδοτικό μοντέλο, το οποίο επιτυγχάνει ικανοποιητική ισορροπία μεταξύ της χρονικής υστέρησης και της ακρίβειας των προβλέψεων. Το LSTM είναι μια πολύ καλή επιλογή, με πιθανές προοπτικές βελτίωσης μέσω της χρήσης του αλγορίθμου βελτιστοποίησης PSO για την εκπαίδευσή του. Ο λόγος που δεν πραγματοποιήθηκε η συγκεκριμένη δοκιμή είναι η αυξημένη υπολογιστική πολυπλοκότητα στον συνδυασμό του LSTM με τον PSO, η οποία θα είχε ως αποτέλεσμα μεγαλύτερο χρόνο εκπαίδευσης, κάτι που θεωρήθηκε μη αποδοτικό με βάση τον υφιστάμενο υπολογιστικό εξοπλισμό που χρησιμοποιήθηκε, δεδομένης επίσης της εξαιρετικής απόδοσης που παρουσιάζει το μοντέλο NARX-PSO.

Από τον δείκτη αξιολόγησης MBE διαπιστώνεται ότι όλα τα μοντέλα κατά μέσο όρο υποεκτιμούν την Φ/Β παραγωγή. Ο δείκτης αυτός αποτυπώνει με σαφήνεια την κατεύθυνση των σφαλμάτων που παρατηρούνται, επισημαίνοντας τη μεροληψία των μοντέλων προς την αρνητική κατεύθυνση (υποεκτίμηση), γεγονός που επηρεάζει την συνολική ακρίβεια των προβλέψεων.

Η αξιολόγηση των μοντέλων με βάση το ΜΑΑΡΕ υποδεικνύει πως τα μοντέλα NARX-PSO και LSTM παρουσιάζουν πολύ κοντινές αποδόσεις. Στην περίπτωση της πρόβλεψης της Φ/Β παραγωγής, οι τιμές του ΜΑΑΡΕ για τα μοντέλα NARX-PSO και LSTM είναι 45.298% και 46.440%, αντίστοιχα. Η ποσοστιαία διαφορά τους είναι 2.5% και η τιμή αυτή υποδεικνύει την παραπλήσια απόδοση των δύο μοντέλων. Ωστόσο, αυτό το συμπέρασμα θα ήταν εσφαλμένο, καθώς, η συνολική ανάλυση δείχνει ότι το NARX-PSO παρουσιάζει σαφή υπεροχή σε σύγκριση με το LSTM, όπως επιβεβαιώνεται και ποιοτικά από τα διαγράμματα των Σχημάτων 5.1 έως 5.5, αλλά και από την ποσοστιαία βελτίωση του NARX-PSO σε σχέση με το LSTM βάσει του ΜΑΕ, που ισούται με 29%. Όπως έχει ήδη αναφερθεί, το LSTM φαίνεται να κάνει καλή διαγείριση των μηδενικών τιμών, επομένως η τιμή του ΜΑΑΡΕ σε αυτές τις περιπτώσεις είναι ικανοποιητική. Αντιθέτως, το NARX-PSO υπερεκτιμά ελαφρώς αλλά συστηματικά τις μηδενικές τιμές παραγωγής. Καθώς το ΜΑΑΡΕ υπολογίζει ποσοστιαία σφάλματα, φαίνεται τελικά να επηρεάζεται σε μεγάλο βαθμό από τα δείγματα που αντιστοιγούν σε ώρες μηδενικής ή σχεδόν μηδενικής παραγωγής, με αποτέλεσμα να μεγεθύνει υπερβολικά τα σφάλματα του NARX-PSO τις ώρες μηδενικής ή σχεδόν μηδενικής παραγωγής. Έτσι, ενώ ο στόχος του ΜΑΑΡΕ ήταν η καλύτερη διαχείριση των μηδενικών τιμών σε σχέση με το κλασικό μετρητικό MAPE, τελικά η παραπάνω διαπίστωση οδηγεί στο συμπέρασμα ότι και το ΜΑΑΡΕ δυσκολεύεται σε μεγάλο βαθμό στην διαχείριση των μηδενικών τιμών.

Συνοψίζοντας, από την ανάλυση των αποτελεσμάτων, αποδείχθηκε πως η ανατροφοδότηση της εξόδου (NARX) σε συνδυασμό με τη χρήση μεταευρετικού αλγορίθμου βελτιστοποίησης (PSO) οδηγεί στην καλύτερη απόδοση στη περίπτωση της Φ/Β παραγωγής. Τα μοντέλα LSTM και NARX-PSO επιτυγχάνουν τις υψηλότερες αποδόσεις, ωστόσο παρουσιάζουν αυξημένους χρόνους εκπαίδευσης. Ο υψηλός χρόνος εκπαίδευσης στις περισσότερες εφαρμογές δεν αποτελεί πρόβλημα, εκτός εάν απαιτούνται επανεκπαιδεύσεις του μοντέλου σε πραγματικό χρόνο (online training). Αναφορικά με το μετρητικό αξιολόγησης MAAPE, επισημαίνεται ότι εάν η αξιολόγηση των μοντέλων βασιζόταν αποκλειστικά σε αυτό, θα μπορούσε να προκύψει το συμπέρασμα ότι τα μοντέλα NARX-PSO και LSTM παρουσιάζουν παρόμοιες αποδόσεις. Το συμπέρασμα αυτό θα ήταν εσφαλμένο, καθώς ο συγκεκριμένος δείκτης δεν καταγράφει επαρκώς τη συνολική απόδοση των μοντέλων. Επομένως, συνιστάται η χρήση περισσοτέρων του ενός μετρητικού αξιολόγησης για την αξιόπιστη και αντικειμενική σύγκριση των μοντέλων πρόβλεψης. Η επιλογή του κατάλληλου συνδυασμού μετρητικών αξιολόγησης είναι κρίσιμη και μπορεί να επηρεάσει σημαντικά τις τελικές αποφάσεις σχετικά με την αποδοτικότητα των μοντέλων.

5.2 ΑΠΟΤΕΛΕΣΜΑΤΑ ΑΙΟΛΙΚΗΣ ΠΑΡΑΓΩΓΗΣ

Ενδεικτικά αποτελέσματα της πρόβλεψης αιολικής παραγωγής παρουσιάζονται στα διαγράμματα που αντιστοιχούν στα Σχήματα 5.6, 5.7 και 5.8. Τα διαγράμματα συγκρίνουν τις πραγματικές τιμές ισχύος με τις τιμές που προβλέπουν τα μοντέλα σε μία περίοδο 24 ωρών. Η πραγματική παραγωγή απεικονίζεται με την μπλε καμπύλη, η οποία λειτουργεί ως σημείο αναφοράς για την αξιολόγηση των προβλέψεων των μοντέλων. Στο Σχήμα 5.6 παρουσιάζεται μία καλοκαιρινή ημέρα η οποία χαρακτηρίζεται από σταθερή παραγωγή ισχύος, αλλά παρ' όλα αυτά η παραγωγή είναι αρκετά χαμηλή. Στα Σχήματα 5.7 και 5.8 παρουσιάζονται δύο φθινοπωρινές ημέρες με πιο υψηλή παραγωγή σε σχέση με την ημέρα του Σχήματος 5.6, ωστόσο η παραγωγή δεν είναι καθόλου σταθερή, εμφανίζοντας έντονες διακυμάνσεις. Στο Σχήμα 5.7, στις 8πμ και στις 2μμ παρατηρούνται απότομες αυξήσεις στην αιολική παραγωγή, σε διάστημα μισής ώρας, όπου η παραγωγή τριπλασιάζεται και πλησιάζει το 60% της ονομαστικής ισχύος, το οποίο υποδηλώνει αυξημένη ένταση του ανέμου. Τις υπόλοιπες ώρες της ημέρας η παραγωγή παραμένει μειωμένη, γύρω στο 20% της ονομαστικής ισχύος. Στο Σχήμα 5.8, από τις 1πμ έως τις 3πμ παρατηρείται παραγωγή σχεδόν ίση της ονομαστικής ισχύος, ενώ και κατά την διάρκεια της ημέρας η παραγωγή παραμένει αρκετά υψηλή, γύρω στο 50% της ονομαστικής ισχύος. Από τα διαγράμματα γίνεται εμφανές ότι το μοντέλο NARX, που αποδίδεται με την πράσινη καμπύλη, παρουσιάζει σημαντικές αποκλίσεις σε σχέση με την πραγματική παραγωγή ισχύος. Αντίθετα, τα υπόλοιπα μοντέλα καταφέρνουν να προσεγγίσουν με μεγαλύτερη ακρίβεια την πραγματική παραγωγή, παρά τις μεταβολές στις καιρικές συνθήκες, προσφέροντας πιο αξιόπιστες προβλέψεις σε σύγκριση με το NARX. Για αυτό τον λόγο δεν έχει, πλέον, νόημα η αξιολόγηση του συγκεκριμένου μοντέλου.



Σχήμα 5.6: Σύγκριση των πραγματικών τιμών ισχύος, με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης αιολικής παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με χαμηλή παραγωγή.



Σχήμα 5.7: Σύγκριση των πραγματικών τιμών ισχύος, με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης αιολικής παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με μέση παραγωγή.



Σχήμα 5.8: Σύγκριση των πραγματικών τιμών ισχύος, με τις προβλεπόμενες τιμές των μοντέλων πρόβλεψης αιολικής παραγωγής σε χρονική διάρκεια 24 ωρών, για μία ημέρα με υψηλή παραγωγή.

Στα Σχήματα 5.9(α), 5.9(β), 5.9(γ), και 5.9(δ), συγκρίνονται οι πραγματικές τιμές της αιολικής ισχύος με τις προβλεπόμενες τιμές που παράγονται από τα μοντέλα FFNN, FFNN-PSO, LSTM και NARX-PSO, αντίστοιχα. Τα διαγράμματα των Σχημάτων 5.9(α), 5.9(β), 5.9(γ), και 5.9(δ) αφορούν την ημέρα που παρουσιάζεται στο Σχήμα 5.8. Η πραγματική και η προβλεπόμενη παραγωγή απεικονίζονται με μπλε και κίτρινο χρώμα, αντίστοιχα. Οι διαφορές μεταξύ των προβλέψεων και των πραγματικών τιμών ποικίλλουν σημαντικά ανάλογα με το εκάστοτε μοντέλο, προσφέροντας σημαντικές ενδείξεις σχετικά με την ακρίβεια και την αποτελεσματικότητα των μοντέλων πρόβλεψης.





⁽δ) NARX-PSO

Σχήμα 5.9 : Σύγκριση της πραγματικής παραγωγής με τις τιμές των προβλέψεων των μοντέλων της αιολικής παραγωγής σε χρονική διάρκεια 24 ωρών.

Από τα Σχήματα 5.9(α), 5.9(β), και 5.9(γ) παρατηρείται μια σαφής απόκλιση ανάμεσα στις καμπύλες των προβλέψεων και των πραγματικών τιμών στον οριζόντιο άξονα του χρόνου (ώρα ημέρας). Η απόκλιση αυτή ξεπερνάει τον χρονικό ορίζοντα της μίας ώρας, κάτι που υποδηλώνει ότι τα συγκεκριμένα μοντέλα παρουσιάζουν μειωμένη ακρίβεια στις προβλέψεις τους. Έτσι, παρόλο που τα μοντέλα FFNN, FFNN-PSO, και LSTM φαίνεται να ακολουθούν την σχετική τάση της παραγωγής, η ύπαρξη της μεγάλης χρονικής υστέρησης τα καθιστά μη αποδοτικά. Όσον αφορά το μοντέλο NARX-PSO, το οποίο παρουσιάζεται στο Σχήμα 5.9(δ), παρατηρείται ότι η χρονική υστέρηση σχεδόν εκμηδενίζεται, κάτι που οφείλεται κυρίως στην ανάδραση της εξόδου σε συνδυασμό με την βελτιστοποίηση που προσφέρει ο αλγόριθμος PSO. Όπως και στην περίπτωση της Φ/Β ισχύος, η καμπύλη των προβλέψεων ακολουθεί πιστά τη γενική τάση της παραγωγής, χωρίς να εμφανίζει αξιοσημείωτη καθυστέρηση, επομένως το
μοντέλο NARX-PSO καταφέρνει να προβλέπει με μεγάλη ακρίβεια την παραγωγή της αιολικής ισχύος.

Στον Πίνακα 5.2 παρουσιάζονται συγκεντρωτικά τα τελικά αποτελέσματα των μοντέλων πρόβλεψης αιολικής παραγωγής. Η σύγκριση γίνεται με βάση τα πέντε μετρητικά αξιολόγησης που παρουσιάστηκαν στην Ενότητα 4.3. Ταυτόχρονα, ο Πίνακας 5.2 περιλαμβάνει τον μέσο χρόνο εκπαίδευσης και εκτέλεσης για το κάθε μοντέλο. Η ανάλυση των μοντέλων δείχνει, με σαφήνεια, ότι το NARX-PSO υπερέχει σε όλα τα μετρητικά αξιολόγησης, με βασικά μετρητικά αξιολόγησης τα nMSE και nRMSE, και τιμές 0.0006 και 0.024, αντίστοιχα.-Η ικανότητα του NARX-PSO στην παραγωγή προβλέψεων υποδηλώνει ότι ο συνδυασμός ανατροφοδότησης και μεταευρετικού αλγορίθμου οδηγεί στην βέλτιστη απόδοση. Ω στόσο, αυτό το πλεονέκτημα συνοδεύεται από έναν σημαντικά αυζημένο χρόνο εκπαίδευσης, ίσο με 1241.832 δευτερόλεπτα. Ο υψηλός χρόνος εκπαίδευσης στις περισσότερες εφαρμογές δεν αποτελεί πρόβλημα, με εξαίρεση κάποιες εφαρμογές όπου απαιτούνται επανεκπαιδεύσεις του μοντέλου σε πραγματικό χρόνο (online training). Ο χρόνος εκτέλεσης αναφέρεται στον χρόνο που χρειάζεται κάθε μοντέλο για την παραγωγή μίας πρόβλεψης. Από τον Πίνακα 5.2, παρατηρούμε ότι το μοντέλο NARX-PSO έχει τον μικρότερο χρόνο εκτέλεσης, με τιμή 0.022 us. Αντίθετα, το LSTM έχει τον μεγαλύτερο χρόνο εκτέλεσης, με τιμή 0.092 us. Ο χρόνος εκτέλεσης είναι ιδιαίτερα σημαντικός σε εφαρμογές όπου απαιτείται παραγωγή προβλέψεων ανά πολύ μικρά χρονικά διαστήματα.

Τα αποτελέσματα των μοντέλων FFNN και FFNN-PSO είναι παρόμοια ως προς την ακρίβεια των προβλέψεων, επομένως η χρήση του αλγορίθμου PSO για την εκπαίδευση του μοντέλου FFNN δεν προσφέρει κάποια βελτίωση, παρόλο που απαιτείται περισσότερος χρόνος εκπαίδευσης. Η ποσοστιαία βελτίωση του FFNN σε σχέση με το FFNN-PSO είναι 1% (με βάση το MAE). Αυτό πιθανώς να οφείλεται στις ιδιαιτερότητες της αρχιτεκτονικής του FFNN, η οποία δεν εκμεταλλεύεται τον αλγόριθμο βελτιστοποίησης PSO. Συγκεκριμένα, το FFNN δεν διαθέτει εσωτερικούς μηχανισμούς μνήμης και ανατροφοδότησης, κάτι που περιορίζει την ικανότητά του να επωφεληθεί από μακροπρόθεσμες χρονικές εξαρτήσεις. Έτσι, η απλότητα της δομής του FFNN περιορίζει τις βελτιώσεις που μπορεί να προσφέρει ο PSO, καθώς υπάρχουν λιγότερες παράμετροι για βελτιστοποίηση.

Από τον δείκτη αξιολόγησης MBE διαπιστώνεται ότι κάποια από τα μοντέλα υποεκτιμούν, ενώ άλλα υπερεκτιμούν κατά μέσο όρο την αιολική παραγωγή. Ο δείκτης αυτός αποτυπώνει με σαφήνεια την κατεύθυνση των σφαλμάτων που παρατηρούνται, επισημαίνοντας τη μεροληψία κάποιων μοντέλων είτε προς τη θετική (υπερεκτίμηση) είτε προς την αρνητική κατεύθυνση (υποεκτίμηση).

Η αξιολόγηση των μοντέλων με βάση το MAAPE υποδεικνύει πως τα μοντέλα NARX-PSO και LSTM παρουσιάζουν πολύ κοντινές αποδόσεις. Στην περίπτωση της πρόβλεψης της Φ/Β παραγωγής οι τιμές του MAAPE για τα μοντέλα NARX-PSO και LSTM είναι 26.1% και 25.182 %, αντίστοιχα. Η ποσοστιαία διαφορά τους είναι 3.5% και η τιμή αυτή υποδεικνύει την παραπλήσια απόδοση των δύο μοντέλων. Ωστόσο, αυτό το συμπέρασμα θα ήταν εσφαλμένο, καθώς, η συνολική ανάλυση δείχνει ότι το NARX-PSO παρουσιάζει σαφή υπεροχή σε σύγκριση με το LSTM, όπως επιβεβαιώνεται και ποιοτικά από τα διαγράμματα των Σχημάτων 5.6 έως 5.9 αλλά και από την ποσοστιαία βελτίωση του NARX-PSO σε σχέση με το LSTM βάσει του MAE, που ισούται με 65%.

Συνοψίζοντας, από την ανάλυση των αποτελεσμάτων αποδείχθηκε πως η ανατροφοδότηση της εξόδου (NARX) σε συνδυασμό με τη χρήση μεταευρετικού αλγορίθμου βελτιστοποίησης (PSO) οδηγεί στην καλύτερη απόδοση στη περίπτωση της αιολικής

	Πρόβλεψη Αιολικής Παραγωγής				
Μοντέλο Μηχανικής Μάθησης	FFNN	NARX	LSTM	FFNN-PSO	NARX-PSO
nMSE (pu)	0.023	0.046	0.021	0.023	0.0006
nRMSE (pu)	0.152	0.214	0.148	0.153	0.024
nMAE (pu)	0.100	0.166	0.094	0.101	0.033
nMBE (pu)	-0.023	-0.112	0.185	0.018	-0.0003
MAAPE (%)	34.636	46.684	26.100	35.168	25.182
Χρόνος Εκτέλεσης (us)	0.054	0.022	0.092	0.054	0.022
Χρόνος Εκπαίδευσης (s)	25.247	187.28	541.407	41.161	1241.832

Πίνακας 5.2: Τελικά αποτελέσματα των μοντέλων πρόβλεψης αιολικής παραγωγής

παραγωγής. Όπως και στην περίπτωση της Φ/Β παραγωγής, το μοντέλο NARX-PSO παρουσιάζει την υψηλότερη απόδοση, ωστόσο παρουσιάζει και αυξημένους χρόνους εκπαίδευσης. Ο υψηλός χρόνος εκπαίδευσης στις περισσότερες εφαρμογές δεν αποτελεί πρόβλημα, εκτός εάν απαιτούνται επανεκπαιδεύσεις του μοντέλου σε πραγματικό χρόνο (online training). Αναφορικά με το μετρητικό αξιολόγησης MAAPE, επισημαίνεται ότι εάν η αξιολόγηση των μοντέλων βασιζόταν αποκλειστικά σε αυτό, θα μπορούσε να προκύψει το συμπέρασμα ότι τα μοντέλα NARX-PSO και LSTM παρουσιάζουν παρόμοιες αποδόσεις. Το συμπέρασμα αυτό θα ήταν εσφαλμένο, καθώς ο συγκεκριμένος δείκτης δεν καταγράφει επαρκώς τη συνολική απόδοση των μοντέλων. Επομένως, συνιστάται η χρήση περισσοτέρων του ενός μετρητικού αξιολόγησης για την αξιόπιστη και αντικειμενική σύγκριση των μοντέλων πρόβλεψης. Η επιλογή του κατάλληλου συνδυασμού μετρητικών αξιολόγησης είναι κρίσιμη και μπορεί να επηρεάσει σημαντικά τις τελικές αποφάσεις σχετικά με την αποδοτικότητα των μοντέλων.

Όσον αφορά την σύγκριση της πρόβλεψης της Φ/Β παραγωγής με την πρόβλεψη αιολικής παραγωγής, παρατηρείται τελικά ότι το μοντέλο NARX-PSO έχει την καλύτερη απόδοση αμφότερα στις περιπτώσεις Φ/Β και αιολικής παραγωγής. Στην πρόβλεψη της αιολικής παραγωγής, το μοντέλο NARX-PSO οδηγεί σε μικρότερα σφάλματα κατά μέσο όρο συγκριτικά με την πρόβλεψη της Φ/Β παραγωγής. Συγκεκριμένα, η τιμή της ποσοστιαίας βελτίωσης να ανέρχεται στο 25% με βάση το μετρητικό αξιολόγησης MAE. Το γεγονός αυτό πιθανώς οφείλεται στο ότι τα δεδομένα της Φ/Β παραγωγής μετρήθηκαν σε μεγαλύτερη χρονική ανάλυση, καθώς οι μετρήσεις έγιναν ανά 1 λεπτό, σε αντίθεση με την αιολική παραγωγή, όπου οι μετρήσεις έγιναν ανά 10 λεπτά. Η μεγαλύτερη χρονική ανάλυση των δεδομένων, οδηγεί σε μεγαλύτερη λεπτομέρεια, με αποτέλεσμα την ύπαρξη πολλών διακυμάνσεων, που είναι πολύ δύσκολο να προβλεφθούν. Έτσι, τα μοντέλα δυσκολεύτηκαν στην ακριβή πρόβλεψη παραγωγής, με αποτέλεσμα η απόδοση των μοντέλων για την πρόβλεψη Φ/Β παραγωγής, να είναι σχετικά μειωμένη. Σε ότι αφορά το μοντέλο LSTM, παρατηρείται ότι καταφέρνει να μειώσει επαρκώς την χρονική υστέρηση μόνο στην πρόβλεψη της Φ/Β παραγωγής, πιθανώς λόγω της μεγάλης χρονικής αυτοσυσχέτισης που χαρακτηρίζει την Φ/Β παραγωγή. Τελικά, η απόδοση του LSTM στην πρόβλεψη Φ/Β παραγωγής είναι καλύτερη από την απόδοση του LSTM στην πρόβλεψη της αιολικής παραγωγής. Επίσης, στην πρόβλεψη της Φ/Β παραγωγής παρατηρείται συστηματική υποεκτίμηση της πραγματικής παραγωγής από όλα τα μοντέλα, κάτι το οποίο δεν συμβαίνει στην περίπτωση της αιολικής παραγωγής. Τέλος, παρατηρείται ότι το μετρητικό αξιολόγησης ΜΑΑΡΕ έχει μικρότερες τιμές στην αιολική παραγωγή σε σχέση με την Φ/Β παραγωγή. Συγκεκριμένα, οι τιμές του ποσοστιαίου σφάλματος στην Φ/Β παραγωγή είναι σχεδόν διπλάσιες συγκριτικά με την αιολική παραγωγή. Αυτό πιθανώς να οφείλεται στο γεγονός ότι η Φ/Β παραγωγή περιλαμβάνει περισσότερες μηδενικές τιμές σε σχέση με την αιολική παραγωγή, καθώς το μετρητικό αξιολόγησης ΜΑΑΡΕ δυσκολεύεται στην διαχείριση των μηδενικών τιμών, και άρα παρατηρείται αυξημένο.

КЕФАЛАЮ 6

ΕΠΙΛΟΓΟΣ

6.1 ΣΥΝΟΨΗ ΕΡΓΑΣΙΑΣ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ

Στην παρούσα διπλωματική εργασία συγκρίθηκαν πέντε μοντέλα μηχανικής μάθησης, τα οποία εκπαιδεύτηκαν με ιστορικά δεδομένα παραγωγής ισχύος και μετεωρολογικών μεταβλητών, με σκοπό την βραχυπρόθεσμη πρόβλεψη της Φ/Β και αιολικής παραγωγής σε χρονικό ορίζοντα μίας ώρας. Όλα τα μοντέλα βασίστηκαν σε τεχνητά νευρωνικά δίκτυα και εκπαιδεύτηκαν με χρήση αλγορίθμου βελτιστοποίησης μείωσης της κλίσης, ενώ δύο από αυτά επανεκπαιδεύτηκαν με τον αλγόριθμο βελτιστοποίησης σμήνους σωματιδίων. Επίσης, στα συγκρινόμενα μοντέλα συμπεριλήφθηκε μοντέλο που βασίζεται στη βαθιά μάθηση. Για την εξασφάλιση της αποτελεσματικής εκπαίδευσης των μοντέλων πρόβλεψης Φ/Β και αιολικής παραγωγής και την επίτευξη των καλύτερων δυνατών προβλέψεων, έγινε χρήση δεδομένων που προήλθαν από πραγματικούς σταθμούς Φ/Β και αιολικής παραγωγής. Τα δεδομένα ήταν αντιπροσωπευτικά του υπό εξέταση προβλήματος, δεν περιείχαν ακραίες ή κενές τιμές, και υπήρχε επαρκής όγκος δείγματος.

Αρχικά έγινε βελτιστοποίηση των υπερπαραμέτρων του κάθε μοντέλου, ξεχωριστά, ώστε να εξασφαλιστεί η βέλτιστη απόδοση. Στη συνέχεια, κάθε μοντέλο εκπαιδεύτηκε βάσει των βέλτιστων υπερπαραμέτρων σε δεδομένα Φ/Β και αιολικής παραγωγής. Με το πέρας της εκπαίδευσης, έγινε η παραγωγή προβλέψεων Φ/Β και αιολικής ισχύος από κάθε μοντέλο με χρονικό ορίζοντα μίας ώρας. Για την ολοκληρωμένη και αξιόπιστη σύγκριση όλων των μοντέλων πρόβλεψης χρησιμοποιήθηκαν μία σειρά από μετρητικά αξιολόγησης, ώστε να προκύψουν τα μοντέλα με την βέλτιστη απόδοση στην πρόβλεψη Φ/Β και αιολικής παραγωγής. Ταυτόχρονα, έγινε η σύγκριση του χρόνου εκπαίδευσης και εκτέλεσης, για το κάθε μοντέλο και για τις δύο παραγωγές.

Από την ανάλυση των αποτελεσμάτων, αποδείχθηκε πως η ανατροφοδότηση της εξόδου (NARX) σε συνδυασμό με τη χρήση μεταευρετικού αλγορίθμου βελτιστοποίησης (PSO) οδηγεί στην καλύτερη απόδοση αμφότερα στις περιπτώσεις Φ/Β και αιολικής παραγωγής. Ο αλγόριθμος βελτιστοποίησης σμήνους σωματιδίων εξερευνά αποτελεσματικά τον χώρο των λύσεων, καθώς έχει σχεδιαστεί έτσι ώστε να κατευθύνει την αναζήτηση σε περιοχές του χώρου που είναι πιο πιθανό να περιέχουν βέλτιστες λύσεις. Η ανατροφοδότηση αναδεικνύεται ως κρίσιμος παράγοντας στην επιτυχία των μοντέλων, λόγω της υψηλής χρονικής αυτοσυσχέτισης που παρατηρείται στην Φ/Β και αιολική παραγωγή. Τέλος, μεταξύ των μοντέλων μηχανικής μάθησης που βελτιστοποιήθηκαν με αλγόριθμο μείωσης της κλίσης, το μοντέλο LSTM αποδείχθηκε ότι έχει την καλύτερη απόδοση στην πρόβλεψη της Φ/Β και αιολικής παραγωγής.

Ένα ζήτημα που προκύπτει από τη χρήση του μεταευρετικού αλγορίθμου είναι η υπολογιστική πολυπλοκότητα, η οποία μεταφράζεται σε αυξημένο χρόνο εκπαίδευσης. Ο υψηλός χρόνος εκπαίδευσης στις περισσότερες εφαρμογές δεν αποτελεί πρόβλημα, εκτός εάν απαιτούνται επανεκπαιδεύσεις του μοντέλου σε πραγματικό χρόνο (online training). Επιπλέον,

ο χρόνος εκτέλεσης των μοντέλων είναι κρίσιμος για εφαρμογές που απαιτούν προβλέψεις ανά μικρά χρονικά διαστήματα, με το μοντέλο NARX να υπερέχει σε ταχύτητα έναντι του LSTM.

Επίσης, παρατηρείται ότι η πρόβλεψη της αιολικής παραγωγής είναι πιο ακριβής σε σύγκριση με την πρόβλεψη της Φ/Β παραγωγής. Το γεγονός αυτό μπορεί να οφείλεται στο ότι τα δεδομένα της Φ/Β παραγωγής ήταν σε μεγαλύτερη ανάλυση, καθώς οι μετρήσεις έγιναν ανά 1 λεπτό, ενώ για την αιολική παραγωγή οι μετρήσεις έγιναν ανά 10 λεπτά. Έτσι, τα μοντέλα πρόβλεψης Φ/Β παραγωγής κλήθηκαν να διαχειριστούν δεδομένα με αυξημένη λεπτομέρεια και άρα περισσότερες διακυμάνσεις, με αποτέλεσμα τη μείωση της απόδοσής τους.

Αναφορικά με το μετρητικό αξιολόγησης ΜΑΑΡΕ, επισημαίνεται ότι εάν η αξιολόγηση των μοντέλων βασιζόταν αποκλειστικά σε αυτό, θα μπορούσε να προκύψει το συμπέρασμα ότι τα μοντέλα NARX-PSO και LSTM παρουσιάζουν παρόμοιες αποδόσεις. Το συμπέρασμα θα ήταν εσφαλμένο, καθώς ο συγκεκριμένος δείκτης δεν καταγράφει επαρκώς τη συνολική απόδοση των μοντέλων. Παρά τις ενδείξεις του ΜΑΑΡΕ για παραπλήσια αποτελέσματα, η συνολική ανάλυση δείχνει ότι το NARX-PSO παρουσιάζει σαφή υπεροχή σε σύγκριση με το LSTM. Το MAAPE φαίνεται να οδηγεί σε διαφορετικά συμπεράσματα σε σχέση με τα άλλα μετρητικά αξιολόγησης. Επίσης, ενώ ο στόχος του ΜΑΑΡΕ ήταν η σωστή διαχείριση των μηδενικών τιμών καθώς και των τιμών κοντά στο μηδέν, παρατηρείται τελικά ότι δυσκολεύεται σε μεγάλο βαθμό από την ύπαρξη τέτοιων τιμών. Επίσης, το μετρητικό αξιολόγησης ΜΑΑΡΕ παρουσιάζει μικρότερο ποσοστό σφάλματος στην αιολική παραγωγή σε σχέση με την Φ/Β παραγωγή. Αυτό, πιθανώς να οφείλεται στο γεγονός ότι η Φ/Β παραγωγή περιλαμβάνει περισσότερες μηδενικές τιμές σε σχέση με την αιολική παραγωγή. Από τα γρησιμοποιούμενα μετρητικά αξιολόγησης, το MSE (RMSE) αναδεικνύεται ως το πιο αξιόπιστο, καθώς τα αποτελέσματά του ευθυγραμμίζονται με τα συμπεράσματα που προέκυψαν από τα διαγράμματα σύγκρισης των μοντέλων με την πραγματική παραγωγή. Ωστόσο, συνιστάται η χρήση περισσοτέρων του ενός μετρητικού αξιολόγησης για την αξιόπιστη και αντικειμενική σύγκριση των μοντέλων πρόβλεψης. Η επιλογή του κατάλληλου συνδυασμού μετρητικών αξιολόγησης είναι κρίσιμη και μπορεί να επηρεάσει σημαντικά τις τελικές αποφάσεις σχετικά με την αποδοτικότητα των μοντέλων.

6.2 ΠΡΟΤΑΣΕΙΣ ΜΕΛΛΟΝΤΙΚΗΣ ΕΠΕΚΤΑΣΗΣ

Κάποιες πιθανές επεκτάσεις της παρούσας διπλωματικής εργασίας είναι οι εξής:

- Η δοκιμή του αλγορίθμου βελτιστοποίησης σμήνους σωματιδίων για την εκπαίδευση του μοντέλου βαθιάς μάθησης LSTM, καθώς ο συνδυασμός της ανατροφοδότησης με αυτόν τον μεταευρετικό αλγόριθμο αποδείχθηκε ότι προσφέρει την καλύτερη απόδοση σε σύγκριση με άλλες μεθόδους. Είναι πολύ πιθανό ο συνδυασμός του μοντέλου LSTM με τον αλγόριθμο βελτιστοποίησης σμήνους σωματιδίων να οδηγήσει στη βέλτιστη απόδοση. Στην παρούσα διπλωματική εργασία, δεν δοκιμάστηκε αυτός ο συνδυασμός λόγω της αυξημένης υπολογιστικής πολυπλοκότητας, της σημαντικής αύξησης του χρόνου εκπαίδευσης, καθώς και λόγω της εξαιρετικής απόδοσης που παρουσίαση το μοντέλο NARX-PSO αμφότερα για την Φ/Β και την αιολική παραγωγή.
- Η δοκιμή περισσότερων μοντέλων μηχανικής, βαθιάς μάθησης, αλγορίθμων βελτιστοποίησης, καθώς και η δοκιμή συνδυασμών μοντέλων μηχανικής μάθησης και υβριδικών αλγορίθμων βελτιστοποίησης.

- Η επέκταση των δεδομένων της Φ/Β και αιολικής παραγωγής. Η μελλοντική επέκταση των δεδομένων που αφορούν τη Φ/Β και αιολική παραγωγή αποτελεί ένα κρίσιμο βήμα για τη βελτίωση των μοντέλων πρόβλεψης παραγωγής ενέργειας. Η αύξηση του πλήθους των δεδομένων, τόσο αναφορικά με τις μετεωρολογικές συνθήκες όσο και με την παραγωγή, καθώς και ο εμπλουτισμός των δεδομένων με άλλου τύπου δεδομένα, όπως επίγειες εικόνες του ουρανού και δορυφορικές εικόνες, προσφέρει μεγαλύτερες δυνατότητες εκπαίδευσης και καλύτερης απόδοσης των μοντέλων.
- Η αξιολόγηση των μοντέλων πρόβλεψης, και ιδιαίτερα του μοντέλου με την βέλτιστη απόδοση, σε κάποιο πραγματικό πρόβλημα διαχείρισης ηλεκτρικής ενέργειας. Η εφαρμογή και αξιολόγηση των μοντέλων σε ένα πραγματικό πρόβλημα διαχείρισης ηλεκτρικής ενέργειας θα επέκτειναν σημαντικά την παρούσα διπλωματική εργασία. Μέσω αυτής της δοκιμής σε πραγματικές συνθήκες, θα μπορούσε να αναδειχθεί η χρησιμότητα και η αποτελεσματικότητα των μοντέλων, και να γίνει η σύγκρισή τους βάσει της πραγματικής αξίας των προβλέψεων που παράγουν.

ΚΕΦΑΛΑΙΟ 7

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] "Εθνικό σχέδιο ενέργειας κλίματος προσχέδιο αναθεωρημένης έκδοσης Οκτώβριος 2023", Διαθέσιμο στην ιστοσελίδα: <u>https://ypen.gov.gr/energeia/esek/.</u>
- [2] K. V. Vidyanandan, "An Overview of Factors Affecting the Performance of Solar PV Systems", *Energy Scan*, A house journal of Corporate Planning, NTPC Ltd., issue 27, pp. 2-8, Feb. 2017, New Delhi.
- [3] Π. Σ. Γεωργιλάκης, Σύγχρονα Συστήματα Μεταφοράς και Διανομής Ηλεκτρικής Ενέργειας. Ηλεκτρονικό Βιβλίο, Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών (ΣΕΑΒ), Αθήνα, 2015. Διαθέσιμο στην ιστοσελίδα : <u>http://repository.kallipos.gr/handle/11419/2013</u>. Προσπελάστηκε στις 9 Σεπτεμβρίου 2024.
- [4] Sebastian Busch, Ruben Kasdorp, Derck Koolen, Arnaud Mercier, Magdalena Spooner, and Directorate-General for Economic and Financial Affairs, *The development of renewable energy* in the electricity market, Διαθέσιμο στην ιστοσελίδα: <u>https://economy-finance.ec.europa.eu/publications/development-renewable-energy-electricity-market_en</u>
- [5] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca, F. J. Martinez-de-Pison, and F. Antonanzas-Torres, "Review of photovoltaic power forecasting", *Solar Energy*, vol. 136. Elsevier Ltd, pp. 78–111, Oct. 15, 2016. DOI: 10.1016/j.solener.2016.06.069.
- [6] S. Mirjalili, H. Faris, I. Aljarah, and A. Algorithms, "*Evolutionary Machine Learning Techniques*", Singapore: Springer Singapore, 2019.
- [7] Sungil Kim, Heeyoung Kim, " New metric of absolute percentage error for intermittent demand forecasts", *International Journal of Forecasting*, Volume 32, Issue 3, Pages 669-679, July–September 2016, DOI: <u>https://doi.org/10.1016/j.ijforecast.2015.12.003</u>
- [8] David Markovics, Martin Janos Mayer, "Comparison of machine learning methods for photovoltaic power forecasting based on numerical weather prediction", *Renewable and Sustainable Energy Reviews*, Volume 161, 112364, June 2022. DOI: <u>https://doi.org/10.1016/j.rser.2022.112364</u>
- [9] Utpal Kumar Das, Kok Soon Tey, Mehdi Seyedmahmoudian, Saad Mekhilef, Moh Yamani Idna Idris, Willem Van Deventer, Bend Horan, Alex Stojcevski, "Forecasting of photovoltaic power generation and model optimization: A review", *Renewable and Sustainable Energy Reviews*, Volume 81, Part 1, Pages 912-928, January 2018. DOI: <u>https://doi.org/10.1016/j.rser.2017.08.017</u>
- [10] Aditya Chaudhary, Akash Sharma, Ayush Kumar, Karan Dikshit & Neeraj Kumar (2020), "Short term wind power forecasting using machine learning techniques", *Journal of Statistics*

and Management Systems, 23:1, 145-156, DOI: <u>https://doi.org/10.1080/09720510.2020.1721632</u>

- [11] Qin Chen, Komla A Folly, "Comparison of Three Methods for Short-Term Wind Power Forecasting", in Proc. *IEEE Rio de Janeiro*, *Brazil*, 08-13 July 2018, DOI: <u>https://doi.org/10.1016/j.ijforecast.2015.12.003</u>
- [12] Renewable Energy Agency, "Renewable energy statistics 2023". Available at: <u>www.irena.org</u>, Accessed July 2023
- [13] *Executive Summary*, Available at: <u>https://www.iea.org/reports/renewables-2023/executive-summary</u>, Accessed 2023
- [14] Electricity, "Global forecast summary 2023 marks a step change for renewable power growth over the next five years", Available at: <u>https://www.iea.org/reports/renewables-2023/electricity</u>, Accessed 2023
- [15] Α. Τόμπρα, "Ember: Ηγέτιδα της ηλιακής ενέργειας η Ελλάδα Το άλμα της 4ετίας", Διαθέσιμο στην ιστοσελίδα <u>https://www.ot.gr/2024/02/07/green/ape/ember-igetis-tis-iliakis-energeias-i-ellada-to-alma-tis-4etias/</u>, Προσπελάστηκε στις 7 Φεβρουαρίου 2024
- [16] Διεύθυνση εγγυήσεων προέλευσης και ενεργειακού μίγματος, "Ενεργειακό μείγμα 2022, 2023". [Online]. Available: <u>https://www.dapeep.gr</u>
- [17] Jonathan Touriño Jacobo, "IRENA: Solar PV represents 44% of renewables global workforce", Διαθέσιμο στην ιστοσελίδα: <u>https://www.pv-tech.org</u>, Accessed October 2, 2024
- [18] HWEA Wind Energy Statistics 2023, Διαθέσιμο στην ιστοσελίδα: <u>https://eletaen.gr</u>, Προσπελάστηκε τον Ιανουάριο 2024
- [19] Wind energy in Europe 2020 Statistics and the outlook for 2021-2025, Available at: <u>https://windeurope.org</u>, Accessed 25 February 2021
- [20] Η Στατιστική της Αιολικής Ενέργειας στην Ελλάδα για το 2023, Διαθέσιμο στην ιστοσελίδα: <u>https://www.veriotis.gr</u>, Προσπελάστηκε στις 23 Ιανουαρίου 2024
- [21] Joyce Lee, Feng Zhao, "GWEC | GLOBAL WIND REPORT 2024", in Proc. *Global Wind Energy Council*, Rue de Commerce 31 1000 Brussels, Belgium, 16 April 2024
- [22] M. H. M. Hariri, M. K. Mat Desa, S. Masri, and M. A. A. M. Zainuri, "Grid-Connected PV Generation System—Components and Challenges: A Review", *Energies 2020*, Vol. 13, Page 4279, vol. 13, no. 17, p. 4279, Aug. 2020, DOI: <u>10.3390/EN13174279</u>.
- [23] Hosenuzzaman, Md., Rahim, N. Abd., Selvaraj, J., "Factors affecting the PV based power generation", in Proc. 3rd IET International Conference on Clean Energy and Technology (CEAT) 2014, Kuching, 24-26 Nov. 2014, DOI: <u>10.1049/cp.2014.1467</u>
- [24] Ioannis K. Bazionis, Markos A. Kousounadis-Knousen, Vasileios E. Katsigiannis, Francky Catthoor, Pavlos S. Georgilakis, "An Advanced Hybrid Boot-LSTM-ICSO-PP Approach for Day-Ahead Probabilistic PV Power Yield Forecasting and Intra-Hour Power Fluctuation Estimation", *IEEE Access* (Volume: 12), 22 March 2024, DOI: 10.1109/ACCESS.2024.3381049
- [25] Nuri Gökmen, Weihao Hu, Peng Hou, Zhe Chen, Dezso Sera, Sergiu Spataru, "Investigation of wind speed cooling effect on PV panels in windy locations", *Renewable Energy*, Volume 90, May 2016, Pages 283-290, DOI: <u>https://doi.org/10.1016/j.renene.2016.01.017</u>

- [26] Tavner Peter, Edwards Clare, Brinkman Andy, Spinato Fabio, "Influence of Wind Speed on Wind Turbine Reliability", *Wind Engineering*, Volume 30, Issue 1, 55–72, January 2006, doi:10.1260/030952406777641441
- [27] Priya Gupta and Rhythm Singh, "PV power forecasting based on data-driven models: a review", *International Journal of Sustainable Engineering*, 14:6, 1733-1755, 21 Sep 2021, DOI: <u>10.1080/19397038.2021.1986590</u>
- [28] Ιπποκράτης Μπόμπορας, Συμεών Περσίδης, 'Πρόβλεψη Αιολικής Παραγωγής στην Ελλάδα'', Διπλωματική Εργασία, Πολυτεχνική Σχολή, Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης, 2013, Διαθέσιμο στην ιστοσελίδα: <u>https://ikee.lib.auth.gr</u>, Προσπελάστηκε στις 10 Ιουλίου 2013
- [29] V. Sohoni, S. C. Gupta, and R. K. Nema, "A Critical Review on Wind Turbine Power Curve Modelling Techniques and Their Applications in Wind Based Energy Systems", J. Energy, vol. 2016, no. region 4, pp. 1–18, 2016, doi: <u>10.1155/2016/8519785</u>
- [30] C. Voyant, G. Notton, S. Kalogirou, M.L. Nivet, C. Paoli, F. Motte and A. Fouilloy, "Machine learning methods for solar radiation forecasting: A review", *Renewable Energy*, vol. 105, pp. 569–582, May 2017, doi: <u>10.1016/J.RENENE.2016.12.095.</u>
- [31] A. El Hendouzi and A. Bourouhou, "Solar Photovoltaic Power Forecasting", Journal of Electrical and Computer Engineering, vol. 2020, 31 December 2020, doi: 10.1155/2020/8819925.
- [32] Alcañiz A., Grzebyk D., Ziar H., Isabella O., "Trends and gaps in photovoltaic power forecasting with machine learning", *Energy Reports*, Volume 9, December 2023, Pages 447-471, DOI: <u>https://doi.org/10.1016/j.egyr.2022.11.208</u>
- [33] P.S. Georgilakis, *Spotlight on Modern Transformer Design*, Springer, London, UK, August 2009. ISBN: 978-1-84882-667-0
- [34] P. Daponte, D. Grimaldi, "Artificial neural networks in measurements", *Measurement*, Volume 23, Issue 2, March 1998, Pages 93-115, DOI: <u>https://doi.org/10.1016/S0263-2241(98)00013-X</u>
- [35] Lippmann R, "An introduction to computing with neural nets", ACM SIGARCH Computer Architecture News, Volume 16, Issue 1, 01 March 1988, DOI: https://doi.org/10.1145/44571.44572
- [36] J. Gracia, A. J. Mazón, and I. Zamora, "Best ANN structures for fault location in single- and double-circuit transmission lines", in Proc. *IEEE Transactions on Power Delivery*, vol. 20, no. 4, pp. 2389–2395, Oct. 2005, doi: <u>10.1109/TPWRD.2005.855482.</u>
- [37] N. C. Majee and A. B. Roy, "Asymptotic Behavior of an Artificial Neural Network Defined on Multipartite Directed Graph", Available: https://www.researchgate.net/publication/237584452, Accessed January 2010
- [38] A. D. Dongare, R. R. Kharde, and A. D. Kachare, "Introduction to Artificial Neural Network", *International Journal of Engineering and Innovative Technology (IJEIT)*, vol. 9001, no. 1, pp. 2277–3754, 2008, July 2012
- [39] Y. Wang, Y. Li, Y. Song, and X. Rong, "The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition", *Applied Sciences* 2020, Vol. 10, Page 1897, vol. 10, no. 5, p. 1897, Mar. 2020, doi: <u>10.3390/APP10051897.</u>

- [40] Ding M., Wang L., Bi R, "An ANN-based Approach for Forecasting the Power Output of Photovoltaic System", *Procedia Environmental Sciences*, Volume 11, Part C, 2011, Pages 1308-1315, DOI: <u>https://doi.org/10.1016/j.proenv.2011.12.196</u>
- [41] Anagnostos D., Schmidt T., Cavadias S., Soudris D., Poortmans J., Catthoor F, "A method for detailed, short-term energy yield forecasting of photovoltaic installations", *Renewable Energy*, Volume 130, January 2019, Pages 122-129, DOI: <u>https://doi.org/10.1016/j.renene.2018.06.058</u>
- [42] S Hochreiter, Y Bengio, P Frasconi, J Schmidhuber, "Gradient flow in recurrent nets: the difficulty of learning long-term dependencies", *Wiley-IEEE Press*, pp. 237-243, 2001, doi: <u>10.1109/9780470544037.ch14</u>
- [43] Y. Yu, X. Si, C. Hu, and J. Zhang, "A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures", *Neural Computation* (2019), 31 (7): 1235–1270. Jul. 2019, doi: 10.1162/NECO_A_01199.
- [44] F. A. Gers, J. Schmidhuber, and F. Cummins, "Learning to forget: continual prediction with LSTM", *Neural Computation*, Volume: 12 Issue: 10 pp. 2451–2471, 2000, doi: 10.1162/089976600300015015
- [45] R. Jozefowicz, W. Zaremba, and I. Sutskever, "An Empirical Exploration of Recurrent Network Architectures", PMLR, pp. 2342–2350, Jun. 01, 2015, Available: <u>https://proceedings.mlr.press/v37/jozefowicz15.html</u>
- [46] Nan Cui, "Applying Gradient Descent in Convolutional Neural Networks", IOP Conf. Series: Journal of Physics: Conf. Series 1004 (2018) 012027, DOI: <u>10.1088/1742-6596/1004/1/012027</u>
- [47] Imran Khan Mohd Jais, Amelia Ritahani Ismail, Syed Qamrun Nisa, "Adam Optimization Algorithm for Wide and Deep Neural Network", *Knowledge Engineering and Data Science* (*KEDS*), Vol 2, No 1, Juni 2019, pp. 41–46, DOI: <u>https://doi.org/10.17977/um018v2i12019p41-46</u>
- [48] X. S. Yang, Nature-inspired Metaheuristic Algorithms. Amsterdam University Press, 2010, ISBN-13: 978-1-905986-28-6, ISBN-10: 1-905986-28-9
- [49] Kazem Meidani, Seyedali, Amir Barati, "Online metaheuristic algorithm selection", Expert Systems with Applications, Volume 201, 1 September 2022, 117058, DOI: 10.1016/j.eswa.2022.117058
- [50] J. Kennedy and R. Eberhart, "Particle swarm optimization", in Proc. ICNN'95 Int. Conf. Neural Networks, doi: 10.1109/ icnn.1995.488968.
- [51] G. T. Pulido and C. A. Coello Coello, "A constraint-handling mechanism for particle swarm optimization", in Proc. 2004 Congress on Evolutionary Computation, vol. 2, no. 4, pp. 1396– 1403, 19-23 June 2004, doi: <u>10.1109/cec.2004.1331060.</u>
- [52] H. Quan, D. Srinivasan and A. Khosravi, "Particle swarm optimization for construction of neural network-based prediction intervals", *Neurocomputing*, Volume 127, 15 March 2014, Pages 172-180, doi: <u>10.1016/j.neucom.2013.08.020</u>.
- [53] C. Plumley, "Penmanshiel Wind Farm Data", Zenodo, Feb. 07, 2022. doi: 10.5281/zenodo.5946808.
- [54] K. Cabello-Solorzano, I. Ortigosa de Araujo, M. Peña, L. Correia, and A. J. Tallón-Ballesteros, "The Impact of Data Normalization on the Accuracy of Machine Learning Algorithms: A Comparative Analysis", in Proc 18th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2023), 31 August 2023, pp. 344–353, doi: 10.1007/978-3-031-42536-3_33.

- [55] E. Hall and S. Dwyer, "Evaluating image quality: A new formulation computer", *Computers in Biology and Medicine*, Volume 2, Issue 1, February 1972, Pages 15-20, IN7-IN10, 21-25, DOI: <u>https://doi.org/10.1016/0010-4825(72)90004-2</u>
- [56] Rong Jin, Luo Si, Cheng Xiang Zhai and Jamie Callan, "Collaborative Filtering with Decoupled Models for Preferences and Ratings", in Proc. ACM International Conference on Information and Knowledge Management, Pages 309-316, New Orleans, 3 November 2003, DOI: https://doi.org/10.1145/956863.956922
- [57] C.P. Jacovides, H. Kontoyiannis, "Statistical procedures for the evaluation of evapotranspiration computing models", *Agricultural Water Management*, Volume 27, Issues 3–4, July 1995, Pages 365-371, DOI: <u>https://doi.org/10.1016/0378-3774(95)01152-9</u>
- [58] MAAPE Mean Arctangent Absolute Percentage Error, Διαθέσιμο στην ιστοσελίδα: <u>https://permetrics.readthedocs.io/en/latest/pages/regression/MAAPE</u>
- [59] Thomas Back, Hans-Paul Schwefel, "An Overview of Evolutionary Algorithms for Parameter Optimization", in Proc. *Evolutionary Computation*, Volume: 1 Issue: 1 D -4600 Dortmund 50, Germany
- [60] Masahiko Arai, "Bounds on the number of hidden units in binary-valued three-layer neural networks", *Neural Networks*, Volume 6, Issue 6, 1993, Pages 855-860, DOI: <u>https://doi.org/10.1016/S0893-6080(05)80130-3</u>
- [61] Hafiz Tayyab Rauf, Umar Shoaib, Muhammad Ikramullah Lali, Majed Alhaisoni, Muhammad Naeem Irfan, Muhammad Attique Khan, "Particle Swarm Optimization With Probability Sequence for Global Optimization", in Proc. *IEEE Access*, Volume 8, accepted June 6, 2020, DOI: <u>10.1109/ACCESS.2020.3002725</u>