



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

**ΣΥΓΚΡΙΣΗ ΑΝΤΙΚΕΙΜΕΝΙΚΩΝ ΣΥΝΑΡΤΗΣΕΩΝ ΓΙΑ
ΤΗΝ ΥΠΕΡΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ
ΑΠΟΤΟΜΩΝ ΜΕΤΑΒΟΛΩΝ ΠΑΡΑΓΩΓΗΣ ΑΠΟ
ΑΝΑΝΕΩΣΙΜΕΣ ΠΗΓΕΣ ΕΝΕΡΓΕΙΑΣ**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Στυλιανή Κώστογλου

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

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

Αθήνα, Οκτώβριος 2025



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

**ΣΥΓΚΡΙΣΗ ΑΝΤΙΚΕΙΜΕΝΙΚΩΝ ΣΥΝΑΡΤΗΣΕΩΝ ΓΙΑ
ΤΗΝ ΥΠΕΡΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ
ΑΠΟΤΟΜΩΝ ΜΕΤΑΒΟΛΩΝ ΠΑΡΑΓΩΓΗΣ ΑΠΟ
ΑΝΑΝΕΩΣΙΜΕΣ ΠΗΓΕΣ ΕΝΕΡΓΕΙΑΣ**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Στυλιανή Κώστογλου

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

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

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 06 Οκτωβρίου 2025

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

.....
Βασίλειος Νικολαΐδης
Επικ. Καθηγητής Ε.Μ.Π.

.....
Γεώργιος Τσεκούρας
Αναπ. Καθηγητής Π.Α.Δ.Α.

Αθήνα, Οκτώβριος 2025

.....

Στυλιανή Κώστογλου

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

Copyright © Στυλιανή Κώστογλου, 2025.

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 διερεύνηση της επίδρασης που έχουν διαφορετικές αντικειμενικές συναρτήσεις στην εκπαίδευση τεχνητών νευρωνικών δικτύων, όσον αφορά στην ικανότητά τους να ανιχνεύουν υπερβραχυπρόθεσμες απότομες μεταβολές στην παραγωγή από Ανανεώσιμες Πηγές Ενέργειας (ΑΠΕ). Συγκεκριμένα, αναπτύσσονται και συγκρίνονται μοντέλα τεχνητών νευρωνικών δικτύων, υλοποιημένων με την αρχιτεκτονική ενός πολυεπίπεδου perceptron (Multi-Layer Perceptron – MLP) και εκπαιδευμένων με πέντε διαφορετικές αντικειμενικές συναρτήσεις. Η βελτιστοποίηση σε κάθε μία εκ των πέντε δοκιμών αντικειμενικής συνάρτησης πραγματοποιείται με τον μεταερευτικό αλγόριθμο βελτιστοποίησης σμήνους σωματιδίων (Particle Swarm Optimization – PSO). Η μεθοδολογία εφαρμόζεται σε δύο σενάρια πρόβλεψης: στην υπερβραχυπρόθεσμη πρόβλεψη φωτοβολταϊκής (Φ/Β) ισχύος με επιθυμητό χρονικό ορίζοντα πρόβλεψης δέκα λεπτών και με δεδομένα χρονικής ανάλυσης ενός λεπτού, και στην υπερβραχυπρόθεσμη πρόβλεψη αιολικής παραγωγής με χρονικό ορίζοντα πρόβλεψης δέκα λεπτών και με δεδομένα χρονικής ανάλυσης δέκα λεπτών. Επίσης, για σκοπούς σύγκρισης, αναπτύσσονται δύο στατιστικά μοντέλα για την αιολική ισχύ και ένα στατιστικό μοντέλο για την Φ/Β ισχύ.

Για την υλοποίηση των μοντέλων πρόβλεψης, χρησιμοποιούνται πραγματικά δεδομένα παραγωγής. Για την πρόβλεψη της αιολικής παραγωγής χρησιμοποιούνται δεδομένα για μία ανεμογεννήτρια (Α/Γ) ονομαστικής ισχύος 2500kW του αιολικού πάρκου Penmanshiel στο Ηνωμένο Βασίλειο για όλη την διάρκεια του έτους 2017, ενώ για την πρόβλεψη της Φ/Β παραγωγής χρησιμοποιούνται δεδομένα από ένα Φ/Β πάρκο στην Βοιωτία, ονομαστικής ισχύος 1200kW, για τον Νοέμβριο του 2023.

Η συγγραφή του κώδικα για την κατασκευή των μοντέλων πρόβλεψης πραγματοποιείται στην γλώσσα προγραμματισμού Python. Τα αποτελέσματα των προβλέψεων για όλες τις μεθόδους πρόβλεψης συγκρίνονται μεταξύ τους με βασικό κριτήριο την ικανότητα που επιδεικνύουν στην ορθή ανίχνευση απότομων μεταβολών (ramp events) παραγωγής ισχύος, μέσω κατάλληλου μετρητικού σφάλματος. Αναδεικνύεται η σημασία της επιλογής αντικειμενικής συνάρτησης σε εφαρμογές πρόβλεψης απότομων μεταβολών παραγωγής ισχύος, και προτείνονται μερικές πιθανές μελλοντικές επεκτάσεις της παρούσας εργασίας.

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ

Αιολική παραγωγή, φωτοβολταϊκή παραγωγή, υπερβραχυπρόθεσμη πρόβλεψη ισχύος, απότομες μεταβολές παραγωγής ισχύος, αντικειμενικές συναρτήσεις, τεχνητά νευρωνικά δίκτυα.

ABSTRACT

The purpose of this diploma thesis is to investigate the effect of different objective functions used during the training of artificial neural networks, on their ability to detect ultra-short-term fluctuations (ramp events) in power production from Renewable Energy Sources (RES). Artificial neural network models, implemented as Multi-Layer Perceptrons (MLP), are compared, trained with five different objective functions. Optimization in each case is conducted using the metaheuristic Particle Swarm Optimization (PSO) algorithm. The methodology is applied to two forecasting scenarios; ultra-short-term photovoltaic (PV) power forecasting with a forecasting horizon of ten minutes and time series data of one-minute resolution, and ultra-short-term wind power forecasting with a forecasting horizon of ten minutes and time series data of ten-minute resolution. Additionally, for comparison purposes, two statistical models are used for wind power prediction, and one statistical model is used for PV power prediction.

For the development of the forecasting models, real production datasets are employed. For wind power forecasting, data from a wind turbine at the Penmanshiel wind farm in the United Kingdom is used, with nominal capacity of 2500kW, covering the entire year of 2017, while for PV power prediction, data from a PV park in Boeotia with a nominal capacity of 1200kW is used, for November 2023.

The code development for the construction of the forecasting models is implemented in Python. The prediction results from all forecasting methods are compared, mainly with respect to their ability to accurately detect ramp events, using an appropriate error metric. In the aforementioned analysis, the importance of selecting an appropriate objective function in ramp event forecasting applications is highlighted, and possible future research on the topic is suggested.

KEY WORDS

Wind turbine production, photovoltaic production, ultra-short-term forecasting, ramp events, objective functions, artificial neural networks.

ΕΥΧΑΡΙΣΤΙΕΣ

Η παρούσα διπλωματική εργασία εκπονήθηκε κατά το ακαδημαϊκό έτος 2024–2025 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 θέμα. Επίσης, θα ήθελα να ευχαριστήσω θερμά τον υποψήφιο διδάκτορα Μάρκο Κουσουνάδη Κνούσεν, για την υπομονή και την πολύτιμη βοήθεια και καθοδήγηση που μου παρείχε σε όλη τη διάρκεια εκπόνησης της εργασίας.

Τέλος, θα ήθελα να ευχαριστήσω την μητέρα μου Μαρία, τον πατέρα μου Ευάγγελο και την αδερφή μου Σοφία, για την ολοκληρωτική αφοσίωση και στήριξή τους σε όλη τη διάρκεια της ζωής μου, τους φίλους μου που στέκονται πάντα δίπλα μου, και τον Ηλία για όλη του την αγάπη και την συμπαράσταση σε κάθε στάδιο της φοιτητικής μου διαδρομής.

ΠΕΡΙΕΧΟΜΕΝΑ

ΚΕΦΑΛΑΙΟ 1: ΕΙΣΑΓΩΓΗ	17
1.1 Αντικείμενο της διπλωματικής εργασίας	17
1.2 Ανασκόπηση βιβλιογραφίας	19
1.3 Δομή της εργασίας	21
ΚΕΦΑΛΑΙΟ 2: ΠΡΟΒΛΕΨΗ ΑΙΟΛΙΚΗΣ ΚΑΙ Φ/Β ΠΑΡΑΓΩΓΗΣ	23
2.1 Γενικά	23
2.2 Αιολική παραγωγή	24
2.3 Φωτοβολταϊκά συστήματα και παραγωγή	27
2.4 Αξία πρόβλεψης αιολικής και φωτοβολταϊκής παραγωγής	30
2.5 Μέθοδοι πρόβλεψης αιολικής και φωτοβολταϊκής παραγωγής	31
2.5.1 Στατιστικές μέθοδοι πρόβλεψης	31
2.5.1.1 Μοντέλο ARIMA	31
2.5.1.2 Μοντέλο Persistence	33
2.5.2 Μοντέλα μηχανικής μάθησης	33
2.6 Ταξινόμηση προβλέψεων βάσει χρονικού ορίζοντα πρόβλεψης	34
2.7 Απότομες μεταβολές παραγωγής ισχύος (ramp events)	35
ΚΕΦΑΛΑΙΟ 3: ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	37
3.1 Γενικά	37
3.2 Δίκτυα FFNN	38
3.3 Αλγόριθμοι βελτιστοποίησης	41
3.3.1 Αλγόριθμοι μείωσης της κλίσης	41
3.3.2 Αλγόριθμος PSO	42
3.4 Αντικειμενικές συναρτήσεις	45
3.4.1 Ελαχιστοποίηση μέσου απόλυτου σφάλματος	45
3.4.2 Ελαχιστοποίηση ρίζας του μέσου τετραγωνικού σφάλματος	46
3.4.3 Ελαχιστοποίηση μέσου τόξου εφαπτομένης του απόλυτου ποσοστιαίου σφάλματος	46
3.4.4 Ελαχιστοποίηση σφάλματος $\log - \cosh$	47
3.4.5 Μεγιστοποίηση δείκτη F1	47
ΚΕΦΑΛΑΙΟ 4: ΑΝΑΛΥΣΗ ΔΕΔΟΜΕΝΩΝ ΚΑΙ ΜΕΘΟΔΟΛΟΓΙΑ ΓΙΑ ΤΑ ΜΟΝΤΕΛΑ ΠΡΟΒΛΕΨΗΣ	49
4.1 Επεξεργασία αιολικών δεδομένων	49
4.1.1 Προέλευση και ανάλυση των δεδομένων αιολικής παραγωγής	49

4.1.2	Προεπεξεργασία των δεδομένων αιολικής παραγωγής	52
4.2	Επεξεργασία φωτοβολταϊκών δεδομένων	53
4.2.1	Προέλευση και ανάλυση των δεδομένων φωτοβολταϊκής παραγωγής	54
4.2.2	Προεπεξεργασία των δεδομένων φωτοβολταϊκής παραγωγής	57
4.3	Μετρητικά σφάλματος	57
4.4	Μεθοδολογία για τα μοντέλα πρόβλεψης αιολικής παραγωγής	59
4.5	Μεθοδολογία για τα μοντέλα πρόβλεψης φωτοβολταϊκής παραγωγής	61
ΚΕΦΑΛΑΙΟ 5:	ΑΠΟΤΕΛΕΣΜΑΤΑ	63
5.1	Αποτελέσματα προβλέψεων αιολικής παραγωγής	63
5.2	Αποτελέσματα προβλέψεων φωτοβολταϊκής παραγωγής	71
5.3	Σύγκριση των αποτελεσμάτων	76
ΚΕΦΑΛΑΙΟ 6:	ΣΥΜΠΕΡΑΣΜΑΤΑ	81
6.1	Σύνοψη και συμπεράσματα της εργασίας	81
6.2	Μελλοντικές επεκτάσεις	82
ΚΕΦΑΛΑΙΟ 7:	ΒΙΒΛΙΟΓΡΑΦΙΑ	85

ΚΑΤΑΛΟΓΟΣ ΣΧΗΜΑΤΩΝ

Σχήμα 2.1:	Η συνολική εγκατεστημένη αιολική ισχύς στην Ελλάδα ανά έτος	24
Σχήμα 2.2:	Η συνολική εγκατεστημένη φωτοβολταϊκή ισχύς στην Ελλάδα ανά έτος	24
Σχήμα 2.3:	Τα κύρια δομικά μέρη μίας Α/Γ	26
Σχήμα 2.4:	Θεωρητική καμπύλη ισχύος μίας Α/Γ	27
Σχήμα 2.5:	Τα κύρια δομικά μέρη μίας Φ/Β συστοιχίας	28
Σχήμα 2.6:	Χαρακτηριστική καμπύλη I-V Φ/Β πλαισίου για διαφορετικές τιμές θερμοκρασίας και ηλιακής ακτινοβολίας	29
Σχήμα 2.7(α):	Η τιμή της μετοχής της Google για 200 συνεχόμενες ημέρες	32
Σχήμα 2.7(β):	Η ημερήσια διαφορά στην τιμή της μετοχής της Google για 200 ημέρες	32
Σχήμα 2.8:	Η ανά μονάδα παραγόμενη Φ/Β ισχύς για συγκεκριμένες ώρες της ημέρας	36
Σχήμα 3.1:	Μαθηματικό μοντέλο της δομής ενός νευρώνα	39
Σχήμα 3.2:	Διάγραμμα δομής ενός FFNN με ένα κρυφό στρώμα	40
Σχήμα 3.3:	Σχηματική αναπαράσταση του τρόπου λειτουργίας του αλγόριθμου μείωσης της κλίσης	42
Σχήμα 3.4:	Ενημέρωση ταχύτητας και θέσης ενός σωματιδίου στον αλγόριθμο PSO	44
Σχήμα 4.1:	Συχνότητα εμφάνισης απότομης μεταβολής στα αιολικά δεδομένα	51
Σχήμα 4.2:	Θηκόγραμμα των συμβάντων απότομης μεταβολής στην αιολική παραγωγή για διαφορετικά εύρη ταχυτήτων ανέμου	52
Σχήμα 4.3:	Συχνότητα εμφάνισης απότομων μεταβολών στην Φ/Β παραγωγή	56
Σχήμα 4.4:	Θηκόγραμμα των συμβάντων απότομων μεταβολών στην Φ/Β παραγωγή για διαφορετικά εύρη ζενιθιακής γωνίας του ήλιου	56
Σχήμα 5.1:	Πραγματική αιολική παραγωγή και αντίστοιχες προβλέψεις του μοντέλου Persistence για τα τελευταία 1000 δείγματα	64
Σχήμα 5.2:	Πραγματική αιολική παραγωγή και αντίστοιχες προβλέψεις του μοντέλου ARIMA για τα τελευταία 1000 δείγματα	65
Σχήμα 5.3:	Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου Persistence για τις 29/12/2018	65
Σχήμα 5.4:	Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου ARIMA για τις 29/12/2018	66
Σχήμα 5.5:	Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-MAE για τα τελευταία 1000 δείγματα	66
Σχήμα 5.6:	Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-MSE για τα τελευταία 1000 δείγματα	67
Σχήμα 5.7:	Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-MAAPE για τα τελευταία 1000 δείγματα	67

Σχήμα 5.8:	Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-LOGCOSH για τα τελευταία 1000 δείγματα	68
Σχήμα 5.9:	Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-F1 για τα τελευταία 1000 δείγματα	68
Σχήμα 5.10:	Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-MAE για τις 29/12/2018	69
Σχήμα 5.11:	Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-MSE για τις 29/12/2018	69
Σχήμα 5.12:	Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-MAAPE για τις 29/12/2018	70
Σχήμα 5.13:	Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-LOGCOSH για τις 29/12/2018	70
Σχήμα 5.14:	Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-F1 για τις 29/12/2018	71
Σχήμα 5.15:	Πραγματική και αντίστοιχη προβλεπόμενη Φ/Β παραγωγή του μοντέλου Persistence για τις 28/11/2023	72
Σχήμα 5.16:	Πραγματική και αντίστοιχη προβλεπόμενη Φ/Β παραγωγή του μοντέλου MLP-MAE για τις 28/11/2023	73
Σχήμα 5.17:	Πραγματική και αντίστοιχη προβλεπόμενη Φ/Β παραγωγή του μοντέλου MLP-MSE για τις 28/11/2023	74
Σχήμα 5.18:	Πραγματική και αντίστοιχη προβλεπόμενη Φ/Β παραγωγή του μοντέλου MLP-MAAPE για τις 28/11/2023	74
Σχήμα 5.19:	Πραγματική και αντίστοιχη προβλεπόμενη Φ/Β παραγωγή του μοντέλου MLP-LOGCOSH για τις 28/11/2023	75
Σχήμα 5.20:	Πραγματική και αντίστοιχη προβλεπόμενη Φ/Β παραγωγή του μοντέλου MLP-F1 για τις 28/11/2023	75

ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ

Πίνακας 3.1:	Ευρέως διαδεδομένες συναρτήσεις ενεργοποίησης	40
Πίνακας 4.1:	Χαρακτηριστικά και τιμές παραμέτρων του MLP-PSO για την πρόβλεψη αιολικής και Φ/Β ισχύος	61
Πίνακας 5.1:	Αποτελέσματα για τα MAE, RMSE, MBE και F1 των μοντέλων πρόβλεψης αιολικής παραγωγής	76
Πίνακας 5.2:	Skill Score για τα MAE και RMSE των μοντέλων πρόβλεψης αιολικής παραγωγής	77
Πίνακας 5.3:	Αποτελέσματα για τα MAE, RMSE, MBE και F1 των μοντέλων πρόβλεψης Φ/Β παραγωγής	78
Πίνακας 5.4:	Skill Score για τα MAE και RMSE των μοντέλων πρόβλεψης Φ/Β παραγωγής	79

ΕΙΣΑΓΩΓΗ

1.1 ΑΝΤΙΚΕΙΜΕΝΟ ΤΗΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Αντικείμενο της παρούσας διπλωματικής εργασίας είναι η διερεύνηση της δυνατότητας ακριβούς υπερβραχυπρόθεσμης πρόβλεψης των απότομων μεταβολών στην παραγωγή των αιολικών και Φ/Β συστημάτων, χρησιμοποιώντας μοντέλο που βασίζεται στα τεχνητά νευρωνικά δίκτυα, καθώς και στατιστικά μοντέλα πρόβλεψης. Η επιτακτική ανάγκη για ταχεία μείωση των εκπομπών διοξειδίου του άνθρακα (CO_2) ως κύριο μέτρο περιορισμού των επιπτώσεων της κλιματικής αλλαγής, καθώς και ο κίνδυνος εξάντλησης των ορυκτών καυσίμων στο μέλλον, αποτελούν σημαντικούς παράγοντες που οδηγούν στην ευρεία ενσωμάτωση των ΑΠΕ στα Συστήματα Ηλεκτρικής Ενέργειας (ΣΗΕ), με σημαντική συνεισφορά τόσο της αιολικής όσο και της Φ/Β παραγωγής στην κάλυψη της ζήτησης [1]. Όμως, η αύξηση του μεριδίου των αιολικών και Φ/Β συστημάτων στο ενεργειακό ισοζύγιο, συνοδεύεται από αύξηση στην αβεβαιότητα και την μεταβλητότητα της διαθέσιμης ισχύος, απειλώντας την ευστάθεια του δικτύου. Αυτό συμβαίνει διότι η παραγωγή ισχύος από αιολικά και Φ/Β συστήματα εξαρτάται από πλήθος παραμέτρων που παρουσιάζουν έντονη αστάθεια και στοχαστική συμπεριφορά, με τις κυριότερες να είναι οι καιρικές συνθήκες, όπως είναι για παράδειγμα η ταχύτητα του ανέμου και η ένταση της ηλιακής ακτινοβολίας.

Οι συνεχείς και ανεξέλεγκτες μεταβολές στην ταχύτητα του ανέμου και στην ένταση της ηλιακής ακτινοβολίας προκαλούν αντίστοιχες απότομες μεταβολές στην παραγόμενη αιολική και Φ/Β ισχύ, καθιστώντας την ορθή πρόβλεψη της αιολικής και Φ/Β παραγωγής μία ιδιαίτερα απαιτητική διαδικασία. Ωστόσο, η ακριβής και αξιόπιστη πρόβλεψη της αιολικής και Φ/Β παραγωγής, και πιο συγκεκριμένα η σωστή πρόβλεψη των απότομων μεταβολών αυτής, είναι μεγάλης σημασίας για την ευστάθεια και αποτελεσματική διαχείριση του δικτύου, για τον έγκαιρο προγραμματισμό των εφεδρειών και των αναγκαίων συμβατικών μονάδων παραγωγής, καθώς και για την οικονομική αποδοτικότητα των συστημάτων ηλεκτρικής ενέργειας με υψηλή διείσδυση ΑΠΕ [2], [3].

Για την διαχείριση των δυσκολιών που επιφέρει η έντονη στοχαστικότητα της αιολικής και Φ/Β παραγωγής, έχουν αναπτυχθεί διάφορες μέθοδοι πρόβλεψης που στοχεύουν στην όσο το δυνατόν μεγαλύτερη μείωση της απόκλισης μεταξύ των πραγματικών τιμών ισχύος και των αντίστοιχων προβλέψεων. Οι δύο κύριες κατηγορίες μεθόδων είναι τα παραδοσιακά στατιστικά μοντέλα, τα οποία αξιοποιούν αποκλειστικά ιστορικά δεδομένα για την εξαγωγή σχέσεων και την παραγωγή των προβλέψεων, και τα μοντέλα μηχανικής μάθησης που εκπαιδεύονται σε μεγάλο πλήθος δεδομένων διαφορετικού τύπου με την βοήθεια αλγορίθμων, αποτυπώνοντας

πολύπλοκες μη γραμμικές συσχετίσεις και μοτίβα, με σκοπό την παραγωγή των βέλτιστων προβλέψεων. Η επιλογή της μεθόδου πρόβλεψης εξαρτάται από τον επιθυμητό χρονικό ορίζοντα πρόβλεψης, από την διαθεσιμότητα και το είδος των δεδομένων, και από τους διαθέσιμους υπολογιστικούς πόρους. Για εφαρμογές που βασίζονται σε υπερβραχυπρόθεσμες προβλέψεις, δηλαδή για προβλέψεις που εκτείνονται από τα επόμενα δευτερόλεπτα έως την επόμενη ώρα, τα στατιστικά μοντέλα αποδεικνύονται αρκετά αποτελεσματικά, ενώ για βραχυπρόθεσμες προβλέψεις, δηλαδή για χρονικό ορίζοντα πρόβλεψης από μία ώρα έως μία ημέρα, έχουν επικρατήσει τα μοντέλα μηχανικής μάθησης [4].

Στην παρούσα διπλωματική εργασία υλοποιείται ένα μοντέλο πρόβλεψης που βασίζεται στην μηχανική μάθηση, το οποίο εκπαιδεύεται με πέντε διαφορετικές αντικειμενικές συναρτήσεις, ώστε να παράγει υπερβραχυπρόθεσμες προβλέψεις για την αιολική και την Φ/Β ισχύ, με χρονικό ορίζοντα πρόβλεψης το επόμενο δεκάλεπτο. Το συγκεκριμένο μοντέλο, το οποίο βασίζεται στα τεχνητά νευρωνικά δίκτυα, εκπαιδεύεται με αλγόριθμο βελτιστοποίησης τον μεταερευτικό αλγόριθμο PSO, και για τα δύο προβλήματα πρόβλεψης. Επίκεντρο αυτής της εργασίας είναι η σύγκριση και ο σχολιασμός της επίδρασης αυτών των αντικειμενικών συναρτήσεων στην ικανότητα του μοντέλου να ανιχνεύει ορθά τις απότομες μεταβολές στην αιολική και Φ/Β παραγωγή. Επίσης, χρησιμοποιήθηκαν δύο στατιστικά μοντέλα πρόβλεψης για την αιολική ισχύ και ένα στατιστικό μοντέλο για την Φ/Β ισχύ, ώστε να υπάρξει ευρύτερη σύγκριση της επίδοσης μεταξύ μεθόδων πρόβλεψης διαφορετικού τύπου.

Προκειμένου να διασφαλιστεί η αποτελεσματική υλοποίηση και εκπαίδευση των μοντέλων πρόβλεψης, χρησιμοποιήθηκαν πραγματικές μετρήσεις ισχύος και μετεωρολογικών δεδομένων, για Α/Γ εγκατεστημένης ισχύος 2050kW ενός αιολικού πάρκου στο Ηνωμένο Βασίλειο και για ένα Φ/Β πάρκο εγκατεστημένης ισχύος 1200kW στην Βοιωτία. Τα διαθέσιμα αιολικά δεδομένα είναι για ολόκληρο το έτος 2017, ενώ τα Φ/Β δεδομένα αφορούν στον Νοέμβριο του έτους 2023. Πριν την υλοποίηση οποιουδήποτε μοντέλου πρόβλεψης, τα εν λόγω δεδομένα ελέγχθηκαν για τυχόν ελλειπείς ή κενές τιμές, οι οποίες απομακρύνθηκαν από αυτά, και υπέστησαν κατάλληλη προεπεξεργασία ώστε να χρησιμοποιηθούν σωστά για την αξιόπιστη πρόβλεψη της αιολικής και Φ/Β παραγωγής από όλα τα μοντέλα.

Αρχικά, αναπτύσσονται τα στατιστικά μοντέλα πρόβλεψης για την αιολική και Φ/Β παραγωγή. Στην συνέχεια, αφού καθοριστούν οι παράμετροι του μοντέλου μηχανικής μάθησης, πραγματοποιείται η εκπαίδευσή του και παράγονται οι ζητούμενες προβλέψεις. Η εκπαίδευσή του γίνεται πέντε φορές για τα αιολικά δεδομένα και πέντε φορές για τα Φ/Β δεδομένα, ώστε να δοκιμαστούν όλες οι αντικειμενικές συναρτήσεις. Για την αποτελεσματική σύγκριση της επίδοσης των μοντέλων πρόβλεψης ως προς την ακρίβεια και την ικανότητα ανίχνευσης απότομων μεταβολών, εφαρμόζονται πέντε μετρητικά αξιολόγησης για κάθε μοντέλο πρόβλεψης.

Βασική καινοτομία της παρούσας διπλωματικής εργασίας είναι η σύγκριση της επίδοσης μοντέλων πρόβλεψης τεχνητών νευρωνικών δικτύων υλοποιημένα με την ίδια αρχιτεκτονική, αλλά χρησιμοποιώντας διαφορετικές αντικειμενικές συναρτήσεις για την εκπαίδευσή τους, προκειμένου να εξεταστεί η επίδραση αυτών, όσον αφορά στην ικανότητα πρόβλεψης των απότομων μεταβολών στην παραγωγή. Επιπλέον, ένα μετρητικό σφάλματος το οποίο βασίζεται αποκλειστικά στην ανίχνευση απότομων μεταβολών, ο δείκτης F1, αξιοποιείται και ως αντικειμενική συνάρτηση, ώστε το νευρωνικό δίκτυο να εκπαιδεύεται με βάση αυτό το κριτήριο. Επίσης, η μεθοδολογία της παρούσας διπλωματικής εργασίας εφαρμόζεται σε δύο διακριτά προβλήματα πρόβλεψης: στην υπερβραχυπρόθεσμη πρόβλεψη Φ/Β ισχύος με επιθυμητό χρονικό ορίζοντα πρόβλεψης δέκα λεπτών και με διαθέσιμα δεδομένα

χρονικής ανάλυσης ενός λεπτού, και στην υπερβραχυπρόθεσμη πρόβλεψη αιολικής ισχύος με επιθυμητό χρονικό ορίζοντα πρόβλεψης δέκα λεπτών και με δεδομένα χρονικής ανάλυσης δέκα λεπτών, γεγονός που επιτρέπει την ευρύτερη αξιολόγηση της συμπεριφοράς των αντικειμενικών συναρτήσεων και των μοντέλων πρόβλεψης, σε διαφορετικά δεδομένα και χρονικές κλίμακες. Τέλος, η σύγκριση της επίδοσης των μοντέλων γίνεται με πέντε διακριτά μετρητικά σφάλματος: το μέσο απόλυτο σφάλμα (Mean Absolute Error – MAE), τη ρίζα του μέσου τετραγωνικού σφάλματος (Root Mean Squared Error – RMSE), τη μεροληψία (Bias/Mean Bias Error – MBE), τον δείκτη ικανότητας (Skill Score) και το μετρητικό για την ανίχνευση απότομων μεταβολών (F1 Score), παρέχοντας ένα πολυκριτηριακό πλαίσιο αξιολόγησης που αναδεικνύει όχι μόνο τη συνολική ακρίβεια πρόβλεψης αλλά και την ικανότητα των μοντέλων πρόβλεψης στον εντοπισμό απότομων μεταβολών.

1.2 ΑΝΑΣΚΟΠΗΣΗ ΒΙΒΛΙΟΓΡΑΦΙΑΣ

Η ακριβής και αξιόπιστη πρόβλεψη της αιολικής και Φ/Β παραγωγής, καθώς και των απότομων μεταβολών αυτής, ιδιαίτερα σε υπερβραχυπρόθεσμους και βραχυπρόθεσμους ορίζοντες πρόβλεψης, αποτελεί κρίσιμο εργαλείο για την εύρυθμη λειτουργία του δικτύου και την ορθή διαχείριση των ΣΗΕ. Στην διεθνή βιβλιογραφία έχουν προταθεί και συγκριθεί ποικίλες μέθοδοι προσέγγισης του συγκεκριμένου ζητήματος. Παρακάτω παρουσιάζονται ενδεικτικά κάποιες επιλεγμένες εργασίες της διαθέσιμης βιβλιογραφίας σχετικά με τα συμβάντα απότομων μεταβολών στην αιολική και Φ/Β παραγωγή και την σύγκριση μεθόδων πρόβλεψης για βραχυπρόθεσμους ορίζοντες πρόβλεψης.

Στο άρθρο των Nouri et al. [5], οι συγγραφείς προτείνουν ένα απλό και ευπροσάρμοστο μετρητικό σφάλματος για την αξιολόγηση της ικανότητας ανίχνευσης απότομων μεταβολών στην ένταση της ηλιακής ακτινοβολίας, και αντίστοιχα κατάλληλα κατώφλια ε . Για τον καθορισμό των βέλτιστων κατωφλίων χρησιμοποιήθηκαν δεδομένα 359 ημερών από την πλατφόρμα Solar de Almeria της CIEMAT στην Ισπανία, και διαπιστώθηκε ότι τα κατώφλια ε που βασίζονται στην καθολική κεκλιμένη ακτινοβολία (Global Tilted Irradiance – GTI) και εξαρτώνται από τη σχετική θέση του ήλιου οδηγούν στην καλύτερη επίδοση, ανιχνεύοντας με ακρίβεια έως και το 95% των κρίσιμων απότομων μεταβολών στην Φ/Β ισχύ ενός προσομοιωμένου Φ/Β πάρκου, υποθετικά τοποθετημένου στην πλατφόρμα Solar de Almeria. Επίσης, αξιολογήθηκαν δύο μοντέλα πρόβλεψης της έντασης της ηλιακής ακτινοβολίας, βασισμένα σε αισθητήρες ουρανού: ένα μοντέλο βαθιάς μάθησης End2End εκπαιδευμένο να ελαχιστοποιεί την ρίζα του RMSE, και ένα παραγωγικό μοντέλο πρόβλεψης (Generative Forecasting Model – GFM). Το GFM επέδειξε καλύτερη επίδοση στην πρόβλεψη απότομων μεταβολών (έως και 71%), υπερτερώντας του μοντέλου End2End, το οποίο απέτυχε στην ικανοποιητική ανίχνευση απότομων μεταβολών εξαιτίας της τάσης του για εξομάλυνση των προβλέψεων. Η έρευνα υπογραμμίζει την σημασία της χρήσης ειδικών μετρητικών σφάλματος για τις απότομες μεταβολές, καθώς η αξιολόγηση με παραδοσιακά μετρητικά, όπως το RMSE, μπορεί να αποκρύπτει σημαντικές αδυναμίες των μοντέλων στην πρόβλεψη έντονων μεταβολών.

Στην εργασία των L. Han, Y. Qiao, M. Li και L. Shi [6], προτείνεται ένα μοντέλο πρόβλεψης συμβάντων απότομων μεταβολών στην αιολική παραγωγή, που συνδυάζει εξαγωγή χαρακτηριστικών και πρόβλεψη, χρησιμοποιώντας βαθιά μάθηση. Πρώτα εφαρμόζεται ο βελτιστοποιημένος αλγόριθμος Swinging Door (Optimized Swinging Door Algorithm –

OpSDA) για τον εντοπισμό ιστορικών συμβάντων απότομων μεταβολών και την εξαγωγή τεσσάρων χαρακτηριστικών τους, τα οποία είναι ο ρυθμός απότομης μεταβολής (ramp rate), το μέγεθός τους, ο χρόνος έναρξης και η διάρκεια. Στη συνέχεια, ιστορικά δεδομένα αιολικής παραγωγής σε συνδυασμό με αυτά τα τέσσερα εξαγόμενα χαρακτηριστικά για τα συμβάντα απότομων μεταβολών, τροφοδοτούν ένα μοντέλο πρόβλεψης βασισμένο σε αρχιτεκτονική που συνδυάζει ένα συνελκτικό νευρωνικό δίκτυο (Convolutional Neural Network – CNN) με ένα δίκτυο μακράς βραχύχρονης μνήμης (Long Short-Term Memory – LSTM). Το CNN χρησιμοποιείται για δευτερεύουσα εξαγωγή χαρακτηριστικών, ενώ το LSTM αναλαμβάνει την πρόβλεψη της ισχύος βασισμένη στη χρονική ακολουθία των δεδομένων. Η μέθοδος δοκιμάστηκε σε δεδομένα του αιολικού πάρκου της Elia στο Βέλγιο, με χρονική ανάλυση 15 λεπτών και αφορούν στο έτος 2020. Τα αποτελέσματα της μελέτης δείχνουν ότι η συγκεκριμένη μεθοδολογία επιτυγχάνει υψηλότερη ακρίβεια στην πρόβλεψη των συμβάντων απότομων μεταβολών σε σχέση με μοντέλο MLP με ενισχυμένα δέντρα (Boosted Trees –BT), με μοντέλο MLP με αυτοπαλινδρόμηση με μεταγωγές Markov (MLP – Markov Switching Auto-Regression), και με μοντέλο βαθιών νευρωνικών δικτύων με μάθηση πολλαπλών εργασιών (Deep Neural Networks – Multi-Task Learning (DNN–MTL)), με μέση ακρίβεια ανίχνευσης συμβάντων απότομων μεταβολών πάνω από 90%.

Στην μελέτη των D. Markovics και M. J. Mayer [7], συγκρίνονται 24 μοντέλα μηχανικής μάθησης για την ημερήσια πρόβλεψη Φ/Β παραγωγής, τα οποία βασίζονται σε αριθμητικές μετεωρολογικές προβλέψεις (Numerical Weather Predictions – NWP). Η ανάλυση στηρίζεται σε σύνολο δεδομένων για τα έτη 2019 και 2020 με χρονική ανάλυση 15 λεπτών, τα οποία λήφθηκαν από 16 Φ/Β πάρκα στην Ουγγαρία. Μεταξύ των εξεταζόμενων μοντέλων, η παλινδρόμηση τύπου kernel ridge και το MLP επέδειξαν τις καλύτερες επιδόσεις σε ότι αφορά την μέση ακρίβεια πρόβλεψης, υπερέχοντας κατά περίπου 44.6% σε σχέση με το στατιστικό μοντέλο αναφοράς Persistence και μειώνοντας το RMSE κατά περίπου 13.9% έναντι απλών γραμμικών μοντέλων. Οι συγγραφείς επισημαίνουν ότι η κατάλληλη επιλογή των χαρακτηριστικών εισόδου (features) και η βελτιστοποίηση των υπερπαραμέτρων αποτελούν καθοριστικούς παράγοντες για τη βελτίωση της ακρίβειας των προβλέψεων.

Στην εργασία των Q. Chen και K.A. Folly [8], συγκρίνονται τρεις προσεγγίσεις για βραχυπρόθεσμη πρόβλεψη αιολικής ενέργειας, οι οποίες αφορούν σε κλασικά στατιστικά αυτοπαλινδρομικά μοντέλα κινητού μέσου όρου (Autoregressive-Moving Average – ARMA), σε τεχνητά νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης (Feed Forward Neural Network – FNN), και σε υβριδικό σύστημα νευρο-ασαφούς ελέγχου (Adaptive Neuro-Fuzzy Inference System – ANFIS). Εφαρμόζοντας τις μεθόδους για προβλέψεις σε υπερβραχυπρόθεσμους και βραχυπρόθεσμους χρονικούς ορίζοντες, προκύπτει ότι όλα τα μοντέλα έχουν παρόμοια επίδοση για υπερβραχυπρόθεσμες προβλέψεις (σε χρονικό ορίζοντα πρόβλεψης μικρότερο της μίας ώρας), ενώ στις βραχυπρόθεσμες προβλέψεις το μοντέλο ARMA υπερέχει, παρουσιάζοντας μικρότερη τιμή RMSE σε σχέση με τα μοντέλα FFNN και ANFIS. Τα ευρήματα υπογραμμίζουν, επίσης, ότι η προσεκτική ρύθμιση των παραμέτρων ενός μοντέλου ARMA και η επιλογή κατάλληλων δεδομένων εισόδου είναι καθοριστικοί παράγοντες για την επίτευξη βελτιωμένης ακρίβειας σε μικρά χρονικά διαστήματα.

Στην μελέτη των J. Schaible et al. [9], οι συγγραφείς χρησιμοποιούν ένα προσομοιωμένο παράδειγμα πραγματικού Φ/Β πάρκου στην Γερμανία με δεδομένα που αφορούν σε 18 ημέρες του έτους 2020, για να ερευνηθεί με ποιον τρόπο μπορούν οι υπερβραχυπρόθεσμες προβλέψεις για την ένταση της προσπίπτουσας ηλιακής ακτινοβολίας, να αποτελέσουν εργαλείο για τον μετριασμό των επιπτώσεων από τα συμβάντα απότομων

μεταβολών. Από την συγκεκριμένη εφαρμογή, προέκυψε ότι η αξιοποίηση των υπερβραχυπρόθεσμων προβλέψεων οδήγησε σε μείωση των παραβιάσεων των ορίων των επιτρεπτών απότομων μεταβολών κατά περίπου 81%, γεγονός που επέτρεψε την μείωση της απαιτούμενης χωρητικότητας των μπαταριών κατά περίπου 71%, και της μέγιστης ισχύος που θα όφειλαν να παρέχουν οι μπαταρίες κατά 48%. Επιπλέον, από τα αποτελέσματα φαίνεται ότι το σταθμισμένο κόστος ηλεκτρικής ενέργειας (Levelized Cost of Electricity – LCOE) μειώνεται κατά 5.5%, ενώ υπό ιδανικές συνθήκες πρόβλεψης, μπορεί να μειωθεί έως και κατά 35%. Συμπερασματικά, ενώ οι υπερβραχυπρόθεσμες προβλέψεις δεν μπορούν να αντικαταστήσουν πλήρως τα συστήματα αποθήκευσης, προσφέρουν σημαντική μείωση των απαιτήσεων σε μπαταρίες και αντίστοιχη οικονομική ωφέλεια, καθιστώντας τις ένα πρακτικό εργαλείο για την αντιμετώπιση των επιπτώσεων σε Φ/Β πάρκα.

1.3 ΔΟΜΗ ΤΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία οργανώνεται σε 7 κεφάλαια.

Στο Κεφάλαιο 2 δίνεται το θεωρητικό υπόβαθρο σχετικά με τα χαρακτηριστικά των αιολικών και Φ/Β συστημάτων. Επίσης, αναλύεται η αξία της ορθής πρόβλεψης της αιολικής και Φ/Β ισχύος, παρουσιάζονται οι κατηγορίες των μεθόδων πρόβλεψης και γίνεται ταξινόμησή τους βάσει του χρονικού ορίζοντα πρόβλεψης. Τέλος, εισάγεται η έννοια των συμβάντων απότομων μεταβολών στην παραγωγή.

Στο Κεφάλαιο 3 δίνεται το θεωρητικό υπόβαθρο γύρω από τα τεχνητά νευρωνικά δίκτυα. Παρουσιάζονται τα είδη τους και οι βασικές μαθηματικές σχέσεις που διέπουν την λειτουργία τους. Περιγράφεται ο αλγόριθμος βελτιστοποίησης μείωσης της κλίσης και ο αλγόριθμος βελτιστοποίησης σμήνους σωματιδίων και ο ρόλος των αντικειμενικών συναρτήσεων στην εκπαίδευση των τεχνητών νευρωνικών δικτύων.

Στο Κεφάλαιο 4 παρουσιάζεται η προέλευση, η προεπεξεργασία και η στατιστική ανάλυση των διαθέσιμων αιολικών και Φ/Β δεδομένων που χρησιμοποιήθηκαν για την παρούσα διπλωματική εργασία. Περιγράφεται η μεθοδολογία υλοποίησης των μοντέλων πρόβλεψης και παρατίθενται τα μετρητικά σφάλματος που χρησιμοποιήθηκαν για την αξιολόγηση της επίδοσής τους.

Στο Κεφάλαιο 5 παρουσιάζονται τα αποτελέσματα των προβλέψεων για την αιολική και Φ/Β παραγωγή, πραγματοποιείται σύγκριση της επίδοσης των μοντέλων μέσω των μετρητικών σφάλματος, και γίνεται εξαγωγή συμπερασμάτων για την αιολική και Φ/Β ισχύ.

Στο Κεφάλαιο 6 γίνεται η σύνοψη της παρούσας διπλωματικής εργασίας, παρουσιάζονται τα γενικά συμπεράσματά της, και προτείνονται ενδεχόμενες μελλοντικές επεκτάσεις της.

Στο Κεφάλαιο 7 περιέχεται η βιβλιογραφία που χρησιμοποιήθηκε για την εκπόνηση της παρούσας διπλωματικής εργασίας.


ΠΡΟΒΛΕΨΗ ΑΙΟΛΙΚΗΣ ΚΑΙ Φ/Β ΠΑΡΑΓΩΓΗΣ

2.1 ΓΕΝΙΚΑ


Είναι γεγονός ότι στη διάρκεια των τελευταίων ετών, οι δυσμενείς συνέπειες της κλιματικής αλλαγής έχουν γίνει ολοένα και πιο αισθητές παγκοσμίως, προκαλώντας συχνές συζητήσεις για την υιοθέτηση μέτρων αντιμετώπισής τους. Βασικός παράγοντας της κλιματικής κρίσης είναι η συνεχώς αυξανόμενη συγκέντρωση αερίων του θερμοκηπίου στην ατμόσφαιρα, ιδιαίτερα διοξειδίου του άνθρακα (CO_2), κυρίως λόγω της καύσης ορυκτών καυσίμων, της βιομηχανικής δραστηριότητας και της αποψίλωσης των δασών [10]. Μάλιστα, η συγκέντρωση ατμοσφαιρικού CO_2 κατά το έτος 2023 παρουσίασε αύξηση κατά 51% σε σχέση με το προβιομηχανικό επίπεδο (πριν το 1750) [11]. Άρα, η άμεση και δραστική μείωση των εκπομπών CO_2 παγκοσμίως είναι αναγκαία, ώστε η άνοδος στην θερμοκρασία του πλανήτη να μην υπερβεί τους 1.5°C σε σχέση με τα προβιομηχανικά επίπεδα, όπως ορίζει ο κεντρικός στόχος της Συμφωνίας του Παρισιού (2015) [12]. Σύμφωνα με μελέτες του 2024, για την επίτευξη αυτού του στόχου πρέπει να γίνουν περικοπές εκπομπών αερίων του θερμοκηπίου κατά 42% μέχρι το 2030 και κατά 57% μέχρι το 2035 [13].

Λόγω της ανάγκης ανεξαρτητοποίησης από τα ορυκτά καύσιμα, η παγκόσμια βιομηχανία παραγωγής ηλεκτρικής ενέργειας έχει στραφεί στις ΑΠΕ και η αυξανόμενη και επιταχυνόμενη διείσδυσή τους στο ηλεκτρικό δίκτυο είναι γεγονός, με τις Φ/Β και αιολικές τεχνολογίες να κυριαρχούν. Σε παγκόσμιο επίπεδο, η συνολική εγκατεστημένη ισχύς των ΑΠΕ στο τέλος του 2024 άγγιξε τα 4,448 GW, λαμβάνοντας μερίδιο 46.4% στην συνολική παραγωγή ηλεκτρικής ενέργειας (κατά 15.1% αυξημένο ποσοστό συγκριτικά με το 2023), με την ηλιακή και αιολική ενέργεια να αποτελούν περίπου το 67.4% της συνολικής εγκατεστημένης ισχύος [1].

Όσον αφορά στην Ελλάδα, κατά το έτος 2024, οι ΑΠΕ κάλυψαν περίπου το 50.5% της ζήτησης σε ηλεκτρική ενέργεια, με τα αιολικά και Φ/Β συστήματα να κυριαρχούν με ποσοστό 44.4% έναντι του 39.1% το 2023 [14]. Πιο συγκεκριμένα, έγινε εγκατάσταση νέων Φ/Β συστημάτων ισχύος 2.57 GW, αυξάνοντας την συνολική εγχώρια εγκατεστημένη ισχύ των Φ/Β σε 9.2 GW [15]. Επιπλέον, σύμφωνα με πρόσφατα στοιχεία της Ελληνικής Επιστημονικής Ένωσης Αιολικής Ενέργειας (ΕΛΕΤΑΕΝ), η συνολική εγκατεστημένη ισχύς αιολικής ενέργειας για το 2024 έφτασε τα 5.355 GW και αυξήθηκε κατά 2.4% σε σχέση με το 2023, παρουσιάζοντας πιο αργό ρυθμό ανάπτυξης συγκριτικά με το έτος 2022–2023, στο οποίο ο ρυθμός ανάπτυξης ήταν 11.6% [14], [16]. Στο Σχήμα 2.1, φαίνεται η συνολική εγκατεστημένη αιολική ισχύς στο δίκτυο της Ελλάδας ανά έτος, για το χρονικό διάστημα 2010 έως 2024, όπως προκύπτει από τα δεδομένα της ΕΛΕΤΑΕΝ, και στο Σχήμα 2.2 υπάρχει διάγραμμα το οποίο δείχνει την συνολική εγχώρια εγκατεστημένη ισχύ των Φ/Β ανά έτος, από το 2014 έως το 2024 [16],[17].



Σχήμα 2.1: Η συνολική εγκατεστημένη αιολική ισχύς στην Ελλάδα ανά έτος



Σχήμα 2.2: Η συνολική εγκατεστημένη Φ/Β ισχύς στην Ελλάδα ανά έτος

2.2 ΑΙΟΛΙΚΗ ΠΑΡΑΓΩΓΗ


Η αξιοποίηση της ενέργειας του ανέμου από τον άνθρωπο χρονολογείται από την αρχαιότητα, αφού ήδη από την 5^η χιλιετία π.Χ. υπήρχαν στην Αίγυπτο τα πρώτα ιστιοφόρα πλοία για την μεταφορά αγαθών και ανθρώπων, και από τον 7^ο αιώνα μ.Χ. κατασκευάζονταν από τους Πέρσες ανεμόμυλοι για την άντληση νερού. Φτάνοντας στην σημερινή εποχή, η

εκμετάλλευση της αιολικής ενέργειας γίνεται μέσω των Α/Γ, μηχανικών, δηλαδή, συστημάτων που μετατρέπουν την κινητική ενέργεια του ανέμου σε ηλεκτρική ενέργεια [18].

Όπως φαίνεται στο Σχήμα 2.3, τα βασικά δομικά μέρη μίας Α/Γ είναι τα ακόλουθα [18]:

- **Ρότορας (rotor) ή δρομέας:** είναι, ουσιαστικά, το κινητήριο μέρος της Α/Γ και αποτελείται από αεροδυναμικά σχεδιασμένα πτερύγια (συνήθως τρία) και την πλήμνη (hub). Όταν ο άνεμος προσπίπτει στα πτερύγια, λόγω της διαφοράς πίεσης ανάμεσα στην πάνω και στην κάτω πλευρά τους, δημιουργείται μία δύναμη, η άντωση (lift), η οποία ωθεί το πτερύγιο προς την κατεύθυνση χαμηλότερης πίεσης. Η συνισταμένη δύναμη της άντωσης και της οπισθέλκουσας δύναμης προκαλούν την περιστροφή του πτερυγίου [19]. Τα πτερύγια των περισσότερων Α/Γ διαθέτουν έλεγχο βήματος, δηλαδή ρύθμιση της γωνίας των πτερυγίων ως προς τον άξονά τους για την βελτιστοποίηση παραγωγής ηλεκτρικής ενέργειας ανάλογα με την ταχύτητα του ανέμου.
- **Σύστημα μετάδοσης της κίνησης (Drive train):** περιλαμβάνει τον κύριο άξονα χαμηλής ταχύτητας, το κιβώτιο ταχυτήτων και τον άξονα υψηλής ταχύτητας (άξονας της γεννήτριας). Ο άξονας χαμηλής ταχύτητας περιστρέφεται με ταχύτητες της τάξης των δεκάδων στροφών ανά λεπτό (rpm), με τυπικές ταχύτητες για μία μεγάλη κλίμακα Α/Γ να είναι οι 10–20 rpm. Οι χαμηλές αυτές ταχύτητες περιστροφής, προσαρμόζονται μέσω του κιβωτίου ταχυτήτων σε τιμές κατάλληλες για τη λειτουργία της γεννήτριας, δηλαδή σε τιμές της τάξης των εκατοντάδων ή χιλιάδων rpm. Εκτός από τα παραπάνω, υπάρχει και το σύστημα πέδησης, το φρένο της Α/Γ, το οποίο τοποθετείται είτε στον άξονα χαμηλής ταχύτητας είτε στον άξονα της γεννήτριας, και σταματάει την λειτουργία του δρομέα, σε περίπτωση ανάγκης ή συντήρησης των εξαρτημάτων [20].
- **Γεννήτρια (Generator):** μέσω της ηλεκτρομαγνητικής επαγωγής (νόμος του Faraday), μετατρέπει την μηχανική ενέργεια περιστροφής σε ηλεκτρική. Στις σύγχρονες μεγάλες Α/Γ χρησιμοποιούνται συχνά γεννήτριες επαγωγής διπλής τροφοδότησης (DFIG–Doubly Fed Induction Generator), ή σύγχρονες γεννήτριες με μόνιμους μαγνήτες (PMSG–Permanent Magnet Synchronous Generator) [21].
- **Κέλυφος και σύστημα προσανατολισμού (Nacelle and Yaw system):** το κέλυφος είναι η κλειστή κατασκευή η οποία προστατεύει όλα τα σημαντικά μέρη και τα ευαίσθητα ηλεκτρικά και μηχανικά εξαρτήματα της Α/Γ από τις εξωτερικές συνθήκες. Με το σύστημα προσανατολισμού, ο άξονας του δρομέα προσανατολίζεται συνεχώς παράλληλα στην διεύθυνση του ανέμου. Αυτό επιτυγχάνεται μέσω ενός ανεμομέτρου στην κορυφή του κελύφους, το οποίο συλλέγει ανεμολογικά δεδομένα, τα οποία με τη σειρά τους εισέρχονται σε ελεγκτή.
- **Συστήματα και πίνακας ελέγχου:** Τα συστήματα ελέγχου μίας Α/Γ περιλαμβάνουν εξαρτήματα όπως αισθητήρες, ελεγκτές, αυτοματισμούς, διακόπτες κλπ. Γενικά, ο σχεδιασμός των συστημάτων ελέγχου στοχεύει στην μέγιστη παραγωγή ηλεκτρικής ενέργειας διατηρώντας την Α/Γ στο βέλτιστο σημείο λειτουργίας και στην προστασία του συστήματος μετάδοσης κίνησης από υπερφορτίσεις, θέτοντας όρια στην ροπή και στην ισχύ τις οποίες αυτό δέχεται.

- **Πύργος:** είναι η κατασκευή η οποία στηρίζει όλη την εγκατάσταση που περιγράφηκε παραπάνω. Συνήθως, το ύψος του πύργου είναι 1 έως 1.5 φορές μεγαλύτερο από τη διάμετρο του δρομέα και οι τυπικές τιμές ύψους για σχετικά μεγάλες Α/Γ είναι τα 80 έως 160 μέτρα.




Σχήμα 2.3: Τα κύρια δομικά μέρη μίας ανεμογεννήτριας [18]

Λαμβάνοντας υπόψη βασικές αρχές της αεροδυναμικής, η μηχανική ισχύς στον άξονα της Α/Γ δίνεται από την σχέση:

$$P_m = \frac{1}{2} \cdot \rho \cdot A \cdot C_p \cdot V_w^3 \quad (2.1)$$

όπου ρ η πυκνότητα του ανέμου, A η επιφάνεια σάρωσης των πτερυγίων, C_p ο αεροδυναμικός συντελεστής απόδοσης και V_w η οριζόντια συνιστώσα ταχύτητας του ανέμου, κάθετη στο επίπεδο του δρομέα, στο ύψος της πλήμνης. Η κυβική εξάρτηση μεταξύ της ισχύος και της ταχύτητας ανέμου, υποδεικνύει ότι ακόμη και μικρές αυξομειώσεις στην ταχύτητα του ανέμου προκαλούν σημαντικές μεταβολές στην ισχύ που παράγεται [18]. Στην θεωρητική καμπύλη ισχύος του Σχήματος 2.4 [22], διακρίνονται τρεις χαρακτηριστικές τιμές της ταχύτητας ανέμου: η ταχύτητα έναρξης λειτουργίας, δηλαδή η ελάχιστη ταχύτητα ανέμου στην οποία ξεκινά η παραγωγή ισχύος, η ονομαστική ταχύτητα ανέμου, στην οποία η Α/Γ παράγει την μέγιστη ισχύ και η ταχύτητα διακοπής λειτουργίας, η οποία είναι η μέγιστη ταχύτητα ανέμου πάνω από την οποία η Α/Γ τίθεται εκτός λειτουργίας για λόγους ασφαλείας.



Σχήμα 2.4: Θεωρητική καμπύλη ισχύος μίας Α/Γ [22]


Η ισχύς εξόδου μίας Α/Γ, στην πράξη, εξαρτάται από πλήθος παραγόντων, όπως είναι η θερμοκρασία, η υγρασία, η παρουσία πάγου ή σκόνης στα πτερύγια, τα φαινόμενα σκίασης, κι όχι αποκλειστικά από την ταχύτητα του ανέμου. Όλοι αυτοί οι παράγοντες, και ειδικά η ταχύτητα του ανέμου και οι καιρικές συνθήκες, είναι τυχαίοι και στοχαστικής φύσης, γεγονός που έχει ως αποτέλεσμα συνεχείς και απότομες μεταβολές στην αιολική παραγωγή. Η αιολική παραγωγή, λοιπόν, είναι μία στοχαστική διαδικασία. Η μελλοντική συμπεριφορά μίας στοχαστικής διαδικασίας είναι τυχαία και δεν μπορεί να προβλεφθεί με ακρίβεια, ακόμη κι αν είναι δεδομένα η αρχική της κατάσταση και οι εξισώσεις που τη διέπουν. Δηλαδή, ακόμη κι αν σε μία συγκεκριμένη Α/Γ επικρατούν οι ίδιες γνωστές συνθήκες για δύο διαφορετικές χρονικές στιγμές, οι δύο τιμές παραγόμενης ισχύος ενδέχεται να μην είναι ίδιες [23].

Η στοχαστική φύση της αιολικής παραγωγής καθιστά τον έλεγχο και την πρόβλεψη της παραγόμενης ισχύος απαιτητικές διαδικασίες, οι οποίες, όμως, είναι ιδιαίτερα σημαντικές για την προστασία των μηχανικών εξαρτημάτων από καταπονήσεις, για την αποδοτική λειτουργία της Α/Γ, καθώς και για την ευστάθεια του ηλεκτρικού δικτύου.

2.3 ΦΩΤΟΒΟΛΤΑΪΚΑ ΣΥΣΤΗΜΑΤΑ ΚΑΙ ΠΑΡΑΓΩΓΗ

Φ/Β σύστημα είναι ένα ολοκληρωμένο σύνολο στοιχείων, το οποίο αποτελείται από συστοιχίες (arrays) Φ/Β πλαισίων (modules), τα οποία, με τη σειρά τους, απαρτίζονται από Φ/Β κυψέλες (cells) κατασκευασμένες από ημιαγώγιμα υλικά και συνδεδεμένες σε σειρά ή παράλληλα, όπως φαίνεται και στο απλουστευμένο σχεδιάγραμμα του Σχήματος 2.5 [24]. Τα Φ/Β συστήματα μετατρέπουν την προσπίπτουσα ηλιακή ακτινοβολία σε ηλεκτρική ενέργεια, με την λειτουργία τους να βασίζεται στο φωτοηλεκτρικό/φωτοβολταϊκό φαινόμενο. Σύμφωνα με αυτό το φαινόμενο, όταν προσπίπτει ηλιακή ακτινοβολία στην επιφάνεια μίας Φ/Β κυψέλης, λόγω του ημιαγώγιμου υλικού, ένα μέρος της απορροφάται, δημιουργώντας περίσσεια από

ζεύγη ηλεκτρονίων και οπών. Ως αποτέλεσμα, εμφανίζεται διαφορά δυναμικού ανάμεσα στους ακροδέκτες της κυψέλης [25].




Σχήμα 2.5: Τα κύρια δομικά μέρη μίας Φ/Β συστοιχίας [24]

Τα περισσότερα Φ/Β στοιχεία κατασκευάζονται από δισκία μονοκρυσταλλικού ή πολυκρυσταλλικού πυριτίου, καθώς κι από λεπτά στρώματα ημιαγωγικών υλικών (thin-film PV cells) [26]. Βασιζόμενα στο φωτοηλεκτρικό/φωτοβολταϊκό φαινόμενο, μετατρέπουν την ηλιακή ενέργεια σε συνεχές (DC) ηλεκτρικό ρεύμα. Αυτό το ρεύμα εισέρχεται σε αντιστροφέα (inverter) DC-AC, ώστε από συνεχές να γίνει εναλλασσόμενο. Στους Φ/Β σταθμούς, η παροχή του παραγόμενου ρεύματος στο δίκτυο, γίνεται μέσω ενός μετασχηματιστή χαμηλής τάσης/μέσης τάσης (ΜΣ ΧΤ/ΜΤ). Επιπλέον, στις εγκαταστάσεις ενός Φ/Β σταθμού υπάρχει και το κτίριο τοπικών χειρισμών, όπου μέσω κατάλληλου εξοπλισμού γίνεται παρακολούθηση και έλεγχος του Φ/Β συστήματος. Ο εξοπλισμός αυτός περιλαμβάνει αποζεύκτες ισχύος και διακόπτες, μετρητικά όργανα, συστήματα αδιάλειπτης παροχής ενέργειας (Unlimited Power Supply—UPS) και τοπικές μπαταρίες. Τα φορτία του Φ/Β σταθμού τροφοδοτούνται από την ηλεκτρική ενέργεια που παράγεται εντός αυτού [27]. Εκτός από τα μεγάλα Φ/Β πάρκα, εγκαθίστανται ευρέως και Φ/Β συστήματα σε στέγες κατοικιών, εμπορικών κτιρίων και δημόσιων υποδομών. Η δυνατότητα τοποθέτησης σε ήδη υπάρχουσες κατασκευές και η απουσία μεγάλων υποδομών, όπως είναι οι μετασχηματιστές και το κτίριο τοπικών χειρισμών, καθιστούν τα Φ/Β συστήματα ιδανικά για μικρής κλίμακας οικιακές και αστικές εφαρμογές [28].

Η σχέση μεταξύ της τάσης V που δημιουργείται στην επιφάνεια ενός Φ/Β πλαισίου και του αντίστοιχου ρεύματος I αποτυπώνεται στην χαρακτηριστική καμπύλη $I-V$ για συγκεκριμένες τιμές θερμοκρασίας και ακτινοβολίας [17]. Στο Σχήμα 2.6 [29] απεικονίζεται η χαρακτηριστική $I-V$ για τρεις διαφορετικές τιμές θερμοκρασίας κυψελών και τρεις διαφορετικές τιμές ηλιακής ακτινοβολίας, στην οποία διακρίνονται τρία κρίσιμα σημεία και μεγέθη: το ρεύμα βραχυκύκλωσης I_{sc} στο σημείο μηδενισμού της τάσης, την τάση ανοιχτού κυκλώματος V_{oc} , όπου το ρεύμα μηδενίζεται, και το σημείο μέγιστης ισχύος (Maximum Power

Point—MPP) στο οποίο για το αντίστοιχο ρεύμα I_{MPP} και τάση V_{MPP} , η ισχύς είναι η μέγιστη. Για την συνεχή λειτουργία στο σημείο μέγιστης ισχύος, έχουν αναπτυχθεί και εφαρμόζονται αλγόριθμοι Maximum Power Point Tracking (MPPT), οι οποίοι εντοπίζουν το εν λόγω σημείο και προσαρμόζουν συνεχώς την λειτουργία του αντιστροφέα, με στόχο την διατήρηση της τάσης V και του ρεύματος I κοντά στο σημείο (I_{MPP}, V_{MPP}) [30]. Η μορφή της καμπύλης $I-V$ εξαρτάται από την θερμοκρασία και την προσπίπτουσα ηλιακή ακτινοβολία, με υψηλότερες θερμοκρασίες να μειώνουν την V_{OC} και με αυξημένη ηλιακή ακτινοβολία να αυξάνει το I_{SC} [25].



Σχήμα 2.6: Χαρακτηριστική καμπύλη $I-V$ Φ/Β πλαισίου για διαφορετικές τιμές θερμοκρασίας και ηλιακής ακτινοβολίας [29]

Σε ένα Φ/Β σύστημα, η παραγωγή ηλεκτρικής ισχύος επηρεάζεται σημαντικά από ένα σύνολο τυχαίων παραγόντων στοχαστικού χαρακτήρα. Ο βασικότερος από αυτούς είναι η ηλιακή ακτινοβολία, η οποία, λόγω νεφώσεων και ατμοσφαιρικών συνθηκών, παρουσιάζει έντονες βραχυχρόνιες απότομες μεταβολές, γεγονός που οδηγεί σε αντίστοιχες απότομες μεταβολές στην παραγόμενη Φ/Β ισχύ [31]. Η θερμοκρασία λειτουργίας των Φ/Β πλαισίων είναι μία ακόμη κρίσιμη μεταβλητή για την απόδοση του συστήματος. Πιο συγκεκριμένα, η αύξηση της θερμοκρασίας πάνω από τους $25^{\circ}C$, η οποία είναι η ιδανική θερμοκρασία λειτουργίας, προκαλεί μείωση της τάσης ανοικτού κυκλώματος και κατά συνέπεια μείωση του βαθμού απόδοσης σε θερμότερα κλίματα. Επιπλέον, η νεφοκάλυψη επηρεάζει άμεσα την ποσότητα της ηλιακής ακτινοβολίας που προσπίπτει στα πάνελ, καθώς σε ημέρες με έντονες και πυκνές νεφώσεις η άμεση ακτινοβολία που φτάνει στο πλαίσιο είναι αισθητά μειωμένη. Επίσης, οι τυχαίες και γρήγορες μεταβολές στην νεφοκάλυψη ενδέχεται να οδηγήσουν σε απότομες, βραχυχρόνιες μεταβολές στην παραγωγή, θέτοντας ζητήματα ευστάθειας του δικτύου [32]. Βέβαια, παρά την στοχαστική της φύση, η Φ/Β παραγωγή, σε αντίθεση με την αιολική, παρουσιάζει ημερήσια περιοδικότητα, με αποτέλεσμα η συνιστώσα της υπό συνθήκες καθαρού ουρανού να είναι πιο εύκολα μοντελοποιήσιμη και προβλέψιμη.

2.4 ΑΞΙΑ ΠΡΟΒΛΕΨΗΣ ΑΙΟΛΙΚΗΣ ΚΑΙ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

Όπως αναφέρθηκε στην Ενότητα 2.1, η μετάβαση προς ένα ενεργειακό σύστημα με χαμηλό αποτύπωμα άνθρακα, απαιτεί γρήγορη κι αυξανόμενη διείσδυση των ΑΠΕ στο ενεργειακό ισοζύγιο. Για να υποστηριχθεί, λοιπόν, η ασφαλής και απρόσκοπτη ενσωμάτωση υψηλών ποσοστών αιολικής και Φ/Β παραγωγής στο δίκτυο, χρειάζεται να γίνει διαχείριση της αβεβαιότητας και της τυχειότητας που χαρακτηρίζουν αυτά τα συστήματα, λόγω της εξάρτησής τους από μετεωρολογικούς παράγοντες. Είναι ιδιαίτερα σημαντική, δηλαδή, η ακριβής πρόβλεψη των μεταβολών στην παραγωγή, τόσο για τεχνικά ζητήματα που αφορούν στην ευστάθεια του δικτύου, όσο και για οικονομικούς λόγους.

Σε επίπεδο διαχείρισης του δικτύου, οι αξιόπιστες προβλέψεις αιολικής και Φ/Β παραγωγής δίνουν την δυνατότητα στους διαχειριστές να προγραμματίζουν και να οργανώνουν αποτελεσματικά την λειτουργία όλων των μονάδων ηλεκτροπαραγωγής και την διανομή της ηλεκτρικής ενέργειας [32]. Επιπλέον, μέσω έγκυρων προβλέψεων για την παραγωγή, διευκολύνεται ο έγκαιρος προγραμματισμός εφεδρειών, με αποτέλεσμα τον συντονισμό συμβατικών μονάδων και υβριδικών συστημάτων αποθήκευσης. Με αυτόν τον τρόπο, γίνεται κατάλληλη ευθυγράμμιση προσφοράς—ζήτησης σε πραγματικό χρόνο και αποτρέπεται η υπερπαραγωγή από ΑΠΕ και η αναγκαστική απόρριψη ενέργειας (curtailment), καθώς και οι ενεργειακές ελλείψεις, οι οποίες επιβάλλουν την ενεργοποίηση δαπανηρών εφεδρικών μονάδων [2], [33]. Οι ακριβείς προβλέψεις αιολικής και Φ/Β παραγωγής, επιτρέπουν κατάλληλη διαχείριση των ενεργειακών αποθεμάτων, όπως είναι τα συστήματα αποθήκευσης ενέργειας, ώστε να διασφαλιστεί η ύπαρξη διαθέσιμης ενέργειας σε περιπτώσεις χαμηλής παραγωγής από ΑΠΕ [32].

Όσον αφορά στην ευστάθεια του δικτύου, οι ακριβείς βραχυπρόθεσμες προβλέψεις συμβάλλουν στην λήψη προληπτικών μέτρων, όπως είναι η προσαρμογή ροών ισχύος και η ενεργοποίηση εφεδρικών μονάδων, πριν από τις αναμενόμενες απότομες μεταβολές στην αιολική και Φ/Β παραγωγή. Αυτό εξασφαλίζει την έγκαιρη αντιμετώπιση κρίσιμων και αιφνίδιων μεταβολών στην παραγωγή των ΑΠΕ, χωρίς διαταραχές τάσης ή συχνότητας, μειώνοντας τον την εμφάνιση διακοπών και blackouts [32]. Επίσης, τα αξιόπιστα προγνωστικά μοντέλα αιολικής και Φ/Β παραγωγής αποτελούν εργαλείο για την αποτελεσματική διαχείριση της συμφόρησης (congestion management). Σε περιπτώσεις υπερπαραγωγής ΑΠΕ και ειδικότερα σε περιοχές με περιορισμένη ικανότητα μεταφοράς ισχύος, αντί της απόρριψης ενέργειας από ΑΠΕ (curtailment), εφαρμόζονται εναλλακτικές λύσεις, όπως είναι η δυναμική ανακατεύθυνση ροών προς περιοχές υψηλής ζήτησης και η έγκαιρη ενεργοποίηση των συστημάτων αποθήκευσης, όταν η παραγωγή ενέργειας ξεπερνάει τα επίπεδα της ζήτησης [34]. Μάλιστα, σύμφωνα με έκθεση για το έτος 2022–2023 για την διαχείριση της συμφόρησης από το Ευρωπαϊκό Δίκτυο Διαχειριστών Συστημάτων Μεταφοράς Ηλεκτρικής Ενέργειας (ENTSO-E), τα κόστη που σχετίζονται με την συμφόρηση του δικτύου στα ευρωπαϊκά συστήματα μεταφοράς ηλεκτρικής ενέργειας, μειώθηκαν κατά 18%, λόγω χρήσης προγνωστικών εργαλείων [3].

Η βελτίωση της ακρίβειας των μοντέλων πρόβλεψης παραγωγής, οδηγεί σε άμεσα οικονομικά οφέλη, καθώς μειώνονται τα λειτουργικά κόστη που σχετίζονται με την ηλεκτροπαραγωγή. Όπως προαναφέρθηκε, η αποφυγή συχνών απορρίψεων ενέργειας (curtailment) και η μείωση της ανάγκης ενεργοποίησης εφεδρειών, έχουν ως αποτέλεσμα και

την ελάττωση του συνολικού κόστους λειτουργίας των σταθμών ΑΠΕ. Επιπλέον, στις αγορές επόμενης ημέρας (day-ahead markets), όταν η πραγματική τιμή της παραγωγής από ΑΠΕ αποκλίνει από την προσφορά που έχει υποβληθεί από τον παραγωγό, επιβάλλονται ποινές ανισορροπίας (imbalance costs), τόσο για υποπαραγωγή, όσο και για υπερπαραγωγή [35]. Επομένως, οι ακριβείς βραχυπρόθεσμες προβλέψεις για την παραγωγή αιολικών και Φ/Β σταθμών είναι απαραίτητες για τους παραγωγούς, διότι θα έχουν την δυνατότητα να αντιστοιχίσουν καλύτερα την υποβληθείσα προσφορά με την πραγματική τιμή παραγωγής, αποφεύγοντας τις οικονομικές απώλειες των ποινών ανισορροπίας.

2.5 ΜΕΘΟΔΟΙ ΠΡΟΒΛΕΨΗΣ ΑΙΟΛΙΚΗΣ ΚΑΙ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

Προκειμένου να αντιμετωπιστούν οι επιπτώσεις της αβέβαιης και τυχαίας συμπεριφοράς των αιολικών και Φ/Β συστημάτων, έχουν μελετηθεί και εφαρμοστεί αρκετές μέθοδοι πρόβλεψης, οι οποίες αξιοποιούν διάφορες τεχνικές, με στόχο την βέλτιστη εκτίμηση της πραγματικής αιολικής και Φ/Β παραγωγής. Στην παρούσα διπλωματική εργασία αναλύονται μόνο οι στατιστικές μέθοδοι πρόβλεψης και τα μοντέλα μηχανικής μάθησης. Αναλυτικές πληροφορίες σχετικά με φυσικές μεθόδους πρόβλεψης δίνονται στην εργασία του Π. Φιλίππου με τίτλο «Πρόβλεψη ηλιακής ακτινοβολίας με χρήση μεθόδων μηχανικής μάθησης και αξιοποίηση δεδομένων νεφοκάλυψης» [36].

2.5.1 Στατιστικές μέθοδοι πρόβλεψης

Οι στατιστικές μέθοδοι πρόβλεψης παραγωγής είναι μέθοδοι που βασίζονται αποκλειστικά, σε ένα μεγάλο σύνολο ιστορικών δεδομένων, καθώς και σε μετεωρολογικές μετρήσεις, για την εξαγωγή σχέσεων και εκτιμήσεων για την μελλοντική παραγωγή. Η αποτελεσματικότητα και η αξιοπιστία των στατιστικών μοντέλων επηρεάζεται σε μεγάλο βαθμό από τη χρονική διάρκεια και την ποιότητα το ιστορικού αρχείου· τα ελλιπή και θορυβώδη δεδομένα οδηγούν σε αστάθειες στις εκτιμήσεις και σε ευαισθησία σε ακραίες τιμές (outliers). Τα κυριότερα πλεονεκτήματα των στατιστικών μεθόδων πρόβλεψης είναι ότι τα περισσότερα έχουν χαμηλό υπολογιστικό κόστος και περιορισμένη ειδική εξειδίκευση για την εφαρμογή τους. Ωστόσο, υποθέτουν γραμμικές σχέσεις μεταξύ των δεδομένων εισόδου και της παραγωγής (έξοδος), με αποτέλεσμα να παρουσιάζουν δυσκολία ή και ανικανότητα στο να αποδώσουν πολύπλοκες, μη γραμμικές συσχετίσεις που υπάρχουν μεταξύ των στοχαστικών παραγόντων που επηρεάζουν τις ΑΠΕ. Επομένως, παρόλο που οι στατιστικές προσεγγίσεις πρόβλεψης είναι σχετικά απλές και εύχρηστες σε πρώιμα στάδια υλοποίησης, η αδυναμία τους να αναλύσουν μη γραμμικές σχέσεις μεταξύ των μεταβλητών που χαρακτηρίζουν τα αιολικά και Φ/Β συστήματα, περιορίζει την ακρίβειά τους [32].


2.5.1.1 Μοντέλο ARIMA

Τα μοντέλα ARIMA (Auto-Regressive Integrated Moving Average) είναι στοχαστικά μοντέλα και αποτελούν μία από τις πιο διαδεδομένες μεθόδους πρόβλεψης μελλοντικών τιμών βάσει ιστορικών παρατηρήσεων ενός μεγέθους, μέσω στατιστικής ανάλυσης χρονοσειρών. Οι

τρεις παράμετροι που χαρακτηρίζουν ένα μοντέλο ARIMA είναι οι παράμετροι (**p**, **d**, **q**), οι οποίες καθορίζουν τρεις συνιστώσες [37]:

- Auto-Regressive (AR): είναι η αυτοπαλινδρομική συνιστώσα. Υποδηλώνει ότι η μελλοντική τιμή εκφράζεται ως γραμμικός συνδυασμός των **p** προηγούμενων τιμών της ίδιας χρονοσειράς.
- Integrated (I): είναι η συνιστώσα που εκφράζει τον βαθμό διαφορίσης που υπέστησαν τα δεδομένα πριν εισαχθούν στο μοντέλο. Δηλαδή, εφαρμόζονται **d** διαφορές για να γίνει η χρονοσειρά στάσιμη και να απομακρυνθούν τάσεις και μη σταθερές συμπεριφορές. Η ύπαρξη στασιμότητας στην χρονοσειρά είναι απαραίτητη προϋπόθεση για την εφαρμογή του μοντέλου ARIMA.
- Moving Average (MA): είναι η συνιστώσα του κινητού μέσου όρου. Δείχνει ότι η μελλοντική τιμή εξαρτάται από γραμμικούς συνδυασμούς των **q** προηγούμενων σφαλμάτων πρόβλεψης.

Στο Σχήμα 2.7(α) φαίνεται η τιμή της μετοχής της Google για 200 συνεχόμενες ημέρες η οποία πρόκειται για μη-στάσιμη χρονοσειρά, ενώ στο Σχήμα 2.7(β) φαίνεται η ημερήσια διαφορά στην τιμή της μετοχής της Google για 200 ημέρες, η οποία είναι στάσιμη χρονοσειρά [38].



Σχήμα 2.7: (α) Η τιμή της μετοχής της Google για 200 συνεχόμενες ημέρες, (β) η ημερήσια διαφορά στην τιμή της μετοχής της Google για 200 ημέρες [38]

Ένα μοντέλο ARIMA για μία χρονοσειρά με τιμές X_t μπορεί να περιγραφεί από την μαθηματική σχέση (2.2) [37]:

$$\varphi(B)(1-B)^d X_t = \theta(B)\varepsilon_t \quad (2.2)$$

όπου:

- B είναι ο τελεστής ολίσθησης και ισχύει $BX_t = X_{t-1}$
- $\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p$, το αυτοπαλινδρομικό πολυώνυμο
- $\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$, το πολυώνυμο του κινητού μέσου όρου
- $(1-B)^d$, όρος που δηλώνει τον βαθμό της διαφορίσης (π.χ. αν $d=1$, έγινε μία διαφορίση στα δεδομένα)
- ε_t , λευκός θόρυβος (τυχαίο σφάλμα)

Τα μοντέλα ARIMA χρησιμοποιούνται κυρίως για την παραγωγή βραχυπρόθεσμων προβλέψεων, καθώς βασίζονται αποκλειστικά σε γραμμικούς συνδυασμούς από προηγούμενες ιστορικές τιμές και προηγούμενα σφάλματα πρόβλεψης. Με άλλα λόγια, σε μακροπρόθεσμες προβλέψεις πολλαπλών βημάτων, κάθε επόμενο βήμα, από ένα σημείο κι έπειτα, θα βασίζεται αναγκαστικά σε προηγούμενες προβλέψεις και όχι στα ιστορικά δεδομένα. Αυτό οδηγεί σε συσσώρευση σφαλμάτων και σε εκθετική αύξηση της αβεβαιότητας, με αποτέλεσμα η ακρίβεια να μειώνεται σε μεγάλο βαθμό μετά τα πρώτα βήματα πρόβλεψης [38].

2.5.1.2 Μοντέλο Persistence

Το μοντέλο Persistence (ή naive μέθοδος πρόβλεψης) είναι η απλούστερη μέθοδος πρόβλεψης χρονοσειρών και συνήθως χρησιμοποιείται ως μοντέλο αναφοράς για την αξιολόγηση άλλων πιο πολύπλοκων μεθόδων πρόβλεψης. Στηρίζεται στην υπόθεση ότι η μελλοντική τιμή μίας μεταβλητής y_{t+h} ισούται με την τελευταία μετρήσιμη τιμή y_t , δηλαδή ισχύει η σχέση (2.3),

$$\hat{y}_{t+h} = y_t \quad (2.3)$$

όπου h ο ορίζοντας πρόβλεψης. Παρόλο που το συγκεκριμένο μοντέλο πρόβλεψης αγνοεί περίπλοκα μοτίβα και τάσεις στα δεδομένα, είναι απλό, οπότε δεν απαιτεί υψηλούς υπολογιστικούς πόρους και εξειδικευμένη εκπαίδευση. Επιπλέον, για αρκετά μικρούς χρονικούς ορίζοντες ($h < 1$ ώρα), δηλαδή όταν πρόκειται για υπερβραχυπρόθεσμες προβλέψεις, εμφανίζει συνήθως εξαιρετικά χαμηλό μέσο σφάλμα πρόβλεψης, και για αυτόν τον λόγο η επίδοση πιο πολύπλοκων μοντέλων πρόβλεψης, όπως είναι το ARIMA, αξιολογείται σε σύγκριση με την επίδοση του persistence. Στο πλαίσιο των ΑΠΕ, η μέθοδος persistence βρίσκει συχνή εφαρμογή στην υπερβραχυπρόθεσμη πρόβλεψη Φ/Β παραγωγής, διότι παρουσιάζει αξιόλογη συμπεριφορά, αρκεί βέβαια να μην επικρατούν συνθήκες απότομης μεταβλητότητας (π.χ. νεφώσεις) [39].

2.5.2 Μοντέλα μηχανικής μάθησης

Τα μοντέλα μηχανικής μάθησης έχουν την ικανότητα να αναγνωρίζουν πολύπλοκα, μη γραμμικά μοτίβα σε μεγάλους όγκους δεδομένων και χρησιμοποιούνται, τα τελευταία χρόνια, και για την πρόβλεψη αιολικής και Φ/Β παραγωγής. Σε αντίθεση με τις κλασικές στατιστικές προσεγγίσεις, οι μέθοδοι μηχανικής μάθησης αξιοποιούν ταυτόχρονα διαφορετικού τύπου δεδομένα, όπως είναι οι μετεωρολογικές μεταβλητές (π.χ. ηλιακή ακτινοβολία και ταχύτητα του ανέμου), οι ιστορικές παρατηρήσεις και μετρήσεις, οι τεχνικές παράμετροι συστημάτων καθώς και γεωχωρικά δεδομένα, εξάγοντας σχέσεις που αποδίδουν με μεγαλύτερη λεπτομέρεια τις συσχετίσεις μεταξύ όλων αυτών των παραγόντων. Ένα από τα μεγαλύτερα πλεονεκτήματα των μοντέλων πρόβλεψης μηχανικής μάθησης είναι η υψηλή προσαρμοστικότητα τους, καθώς έχουν την δυνατότητα να εκπαιδεύονται δυναμικά σε νέα δεδομένα, εμφανίζοντας μεγαλύτερη ακρίβεια σε συνθήκες μεταβλητότητας (π.χ. μεταβαλλόμενες καιρικές συνθήκες). Ωστόσο, η εκπαίδευσή τους εξαρτάται από την ποσότητα και την ποιότητα των τιμών των μεταβλητών εισόδου, καθώς απαιτείται μεγάλος όγκος ιστορικών δεδομένων, προκειμένου αυτή να είναι αξιόπιστη. Επιπλέον, ορισμένα πολύπλοκα μοντέλα μηχανικής μάθησης τείνουν να

«απομνημονεύουν» και να προσαρμόζονται σε υπερβολικό βαθμό στα δεδομένα εκπαίδευσης, χάνοντας την ικανότητα γενίκευσης σε νέα δεδομένα (over-fitting) [32].

2.6 ΤΑΞΙΝΟΜΗΣΗ ΠΡΟΒΛΕΨΕΩΝ ΒΑΣΕΙ ΧΡΟΝΙΚΟΥ ΟΡΙΖΟΝΤΑ

Με βάση τον χρόνο επικείμενης εκπλήρωσης της πρόβλεψης, οι προβλέψεις αιολικής και Φ/Β παραγωγής ταξινομούνται σε τέσσερις κύριες κατηγορίες: σε υπερβραχυπρόθεσμες, βραχυπρόθεσμες, μεσοπρόθεσμες και μακροπρόθεσμες. Αυτή η κατηγοριοποίηση χρησιμεύει στην κατάλληλη επιλογή μεθόδων πρόβλεψης για διαφορετικές εφαρμογές. Κάθε χρονικός ορίζοντας πρόβλεψης εξυπηρετεί διαφορετικές ανάγκες και κάθε κατηγορία πρόβλεψης βρίσκει χρησιμότητα σε διάφορες εφαρμογές.


- **Υπερβραχυπρόθεσμη πρόβλεψη:** Η υπερβραχυπρόθεσμη πρόβλεψη παραγωγής στοχεύει σε χρονικό ορίζοντα με διάρκεια από μερικά δευτερόλεπτα έως μία ώρα. Είναι ιδιαίτερα σημαντική για την ευστάθεια του ηλεκτρικού δικτύου, διότι συμβάλλει στην παρακολούθηση σε πραγματικό χρόνο της κατάστασης του δικτύου και στον άμεσο έλεγχο και ρύθμιση των απότομων μεταβολών τάσης-συχνότητας. Αυτός ο τύπος πρόβλεψης βρίσκει εφαρμογή, μεταξύ άλλων, στον έλεγχο και στην αυτόματη ρύθμιση συχνοτήτων σε μικροδίκτυα, καθώς και στον προγραμματισμό των συστημάτων αποθήκευσης ενέργειας ανάλογα με τις μεταβολές στην ζήτηση. Οι μέθοδοι πρόβλεψης που χρησιμοποιούνται κυρίως είναι στατιστικές λόγω της αξιόπιστης συμπεριφοράς αυτών των μοντέλων για μικρούς ορίζοντες πρόβλεψης [32].
- **Βραχυπρόθεσμη πρόβλεψη:** Η βραχυπρόθεσμη πρόβλεψη παραγωγής καλύπτει χρονικό ορίζοντα με διάρκεια από μία ώρα έως μία ημέρα. Η συγκεκριμένη κατηγορία πρόβλεψης είναι εξαιρετικά χρήσιμη για τον κατάλληλο προγραμματισμό της διανομής ισχύος, καθώς και για την συμμετοχή στην αγορά ηλεκτρικής ενέργειας (day-ahead market). Όπως αναφέρθηκε στην Ενότητα 2.4, οι ακριβείς βραχυπρόθεσμες προβλέψεις δίνουν την δυνατότητα στους παραγωγούς να υποβάλλουν αξιόπιστες προσφορές στην αγορά προηγούμενης ημέρας, με αποτέλεσμα την μείωση των ποινών ανισορροπίας. Επίσης, συμβάλλουν στον βέλτιστο προγραμματισμό των συμβατικών μονάδων παραγωγής και των συστημάτων αποθήκευσης [32]. Για την παραγωγή βραχυπρόθεσμων προβλέψεων, χρησιμοποιούνται, πλέον, περισσότερο τα μοντέλα μηχανικής μάθησης σε σχέση με τις στατιστικές μεθόδους [4].
- **Μεσοπρόθεσμη πρόβλεψη:** Η μεσοπρόθεσμη πρόβλεψη παραγωγής καλύπτει χρονικό ορίζοντα διάρκειας από δύο ημέρες έως μία εβδομάδα. Αυτή η κλίμακα προβλέψεων χρησιμοποιείται κυρίως για τον προγραμματισμό προληπτικών συντηρήσεων των μονάδων παραγωγής και για την διαχείριση των εφεδρικών μονάδων [32]. Η μεσοπρόθεσμη πρόβλεψη παραγωγής στηρίζεται αρκετά στα αποτελέσματα από μετεωρολογικά μοντέλα πρόγνωσης, όπως είναι η αριθμητική πρόγνωση καιρού (Numerical Weather Prediction – NWP), σε συνδυασμό με στατιστικές μεθόδους και μοντέλα μηχανικής μάθησης [40].

- **Μακροπρόθεσμη πρόβλεψη:** Η μακροπρόθεσμη πρόβλεψη παραγωγής καλύπτει χρονικό ορίζοντα με διάρκεια από μία εβδομάδα-μήνες έως ένα έτος. Στηρίζεται σε κλιματικούς και στατιστικούς δείκτες, όπως εποχικά μοτίβα και ιστορικές τάσεις στα δεδομένα, αξιοποιώντας κυρίως στατιστικά μοντέλα πρόβλεψης. Αυτού του είδους οι προβλέψεις βρίσκουν εφαρμογή στον μακροπρόθεσμο ενεργειακό σχεδιασμό, στον υπολογισμό της οικονομικής απόδοσης νέων επενδύσεων σε αιολικά και Φ/Β πάρκα, καθώς και στον προγραμματισμό εκτεταμένων εργασιών συντήρησης [32].

2.7 ΑΠΟΤΟΜΕΣ ΜΕΤΑΒΟΛΕΣ ΠΑΡΑΓΩΓΗΣ ΙΣΧΥΟΣ (RAMP EVENTS)

Τα ramp events ορίζονται ως απότομες μεταβολές στην παραγωγή ηλεκτρικής ενέργειας από αιολικούς και Φ/Β σταθμούς, εντός σύντομου χρονικού διαστήματος. Μία απότομη μεταβολή στην παραγωγή, ανιχνεύεται όταν η μεταβολή της παραγόμενης ισχύος σε διαδοχικές χρονικές στιγμές, υπερβαίνει κάποιο κατώφλι ε . Σύμφωνα με το άρθρο *Ramp Rate Metric Suitable for Solar Forecasting* των Nouri et al., το κρίσιμο κατώφλι ε πάνω από το οποίο συμβαίνει απότομη μεταβολή στην παραγωγή είναι συνήθως το 10% της ονομαστικής ισχύος του αιολικού ή Φ/Β συστήματος [5]. Προφανώς, επειδή μία απότομη μεταβολή μπορεί να έχει είτε θετικό ή αρνητικό πρόσημο, δηλαδή ενδέχεται να συμβεί μία απότομη αύξηση στην παραγωγή ή μία απότομη μείωση, η προσοχή εστιάζεται στην απόλυτη τιμή της μεταβολής στην ισχύ κι όχι στο είδος της μεταβολής.

Τα έντονα και συχνά συμβάντα απότομης μεταβολής στην αιολική και Φ/Β παραγωγή οφείλονται κυρίως στις απότομες αλλαγές στην ταχύτητα του ανέμου και στην διέλευση νεφών αντίστοιχα, γεγονός που δυσχεραίνει την διατήρηση της ευστάθειας του ηλεκτρικού δικτύου και αυξάνει το κόστος διαχείρισης των εφεδρικών μονάδων, καθώς δημιουργεί την ανάγκη γρήγορης ενεργοποίησης ή απόσυρσης εφεδρειών. Επιπλέον, τα συμβάντα απότομης μεταβολής καθιστούν την διαδικασία παραγωγής βραχυπρόθεσμων προβλέψεων αρκετά απαιτητική, μειώνοντας την ακρίβεια και την αξιοπιστία των διάφορων μοντέλων πρόβλεψης. Πιο συγκεκριμένα, η ένταση και το πλήθος των συμβάντων απότομης μεταβολής εξαρτώνται άμεσα από την χρονική ανάλυση των δεδομένων παραγωγής: όσο υψηλότερη είναι η ανάλυση (π.χ. ανάλυση δευτερολέπτου έναντι λεπτού), τόσο πιο συχνά και έντονα καταγράφονται αυτά τα γεγονότα. Αυτό συμβαίνει διότι μειώνεται η επίδραση του φαινομένου συσσώρευσης (aggregation effect) το οποίο μετριάξει τις απότομες μεταβολές, καθώς οι διαδοχικές τιμές της παραγωγής εξομαλύνονται σε μεγαλύτερα χρονικά διαστήματα. Για παράδειγμα, σε καταγραφή ισχύος ανά λεπτό, ένα ή περισσότερα συμβάντα απότομης μεταβολής μέσα στο ίδιο λεπτό «χάνονται», ενώ σε δεδομένα δευτερολέπτου αποτυπώνονται πλήρως. Επειδή η υπερβραχυπρόθεσμη πρόβλεψη στηρίζεται στην υψηλή χρονική ανάλυση των δεδομένων, η ακριβής πρόβλεψη των έντονων απότομων μεταβολών σε τέτοιους χρονικούς ορίζοντες είναι αρκετά κρίσιμη [41]. Στο Σχήμα 2.8 φαίνεται η παραγόμενη ισχύς ενός Φ/Β συστήματος για συγκεκριμένες ώρες της ημέρας και είναι ευδιάκριτο ότι τα συμβάντα απότομης μεταβολής είναι ιδιαίτερα συχνά και έντονα στις ώρες 9:00–14:00 [42].



Σχήμα 2.8: Η ανά μονάδα παραγόμενη Φ/Β ισχύς για συγκεκριμένες ώρες της ημέρας [42]

ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

3.1 ΓΕΝΙΚΑ

Στην διάρκεια της τελευταίας δεκαετίας, η γνώση και η τεχνολογία γύρω από την τεχνητή νοημοσύνη έχει αναπτυχθεί ραγδαία, με τα μοντέλα μηχανικής μάθησης να επικρατούν στην ανάλυση και πρόβλεψη δεδομένων σε διάφορους τομείς. Τα μοντέλα μηχανικής μάθησης δίνουν την δυνατότητα σε υπολογιστικά συστήματα να εκπαιδεύονται από μεγάλο πλήθος δεδομένων, διαφορετικού τύπου. Βασίζονται σε αλγόριθμους που ανιχνεύουν πολύπλοκα μοτίβα και μπορούν να αναγνωρίσουν περίπλοκες, μη γραμμικές σχέσεις μεταξύ των δεδομένων. Η διαδικασία της εκπαίδευσης περιλαμβάνει, μεταξύ άλλων, την συνεχή αλλαγή στις ρυθμίσεις των παραμέτρων των μοντέλων, ώστε να βελτιστοποιείται η ανακάλυψη κρυμμένων σχέσεων και να υποστηρίζεται η δυνατότητα γενίκευσης σε νέα δεδομένα. Πολύ σημαντικό πλεονέκτημα των μοντέλων μηχανικής μάθησης είναι η προσαρμοστικότητά τους, καθώς εκπαιδεύονται δυναμικά σε νέα δεδομένα που μεταβάλλονται συνεχώς, βελτιώνοντας την επίδοσή τους. Επιπλέον, σε εφαρμογές όπως είναι η αναγνώριση εικόνων ή η πρόβλεψη χρονοσειρών, φαίνεται ότι οι μέθοδοι μηχανικής μάθησης παρουσιάζουν υψηλή ακρίβεια, ξεπερνώντας σε επίδοση τις κλασικές στατιστικές μεθόδους [43].

Η βραχυπρόθεσμη πρόβλεψη της Φ/Β και αιολικής παραγωγής είναι μία αρκετά απαιτητική διαδικασία, κυρίως λόγω της περίπλοκης εξάρτησης αυτών των συστημάτων από μεγάλο αριθμό στοχαστικών μεταβλητών (π.χ. μετεωρολογικές συνθήκες). Επομένως, οι μέθοδοι πρόβλεψης που στηρίζονται στην μηχανική μάθηση διευκολύνουν την συσχέτιση τέτοιου είδους δεδομένων, βελτιώνουν την επίδοση και μειώνουν το μέσο σφάλμα πρόβλεψης, ειδικά όταν πρόκειται για βραχυπρόθεσμες προβλέψεις [44]. Για αυτόν τον λόγο, λοιπόν, υπάρχει αυξανόμενη υιοθέτηση τέτοιων προσεγγίσεων για την παραγωγή πιο αξιόπιστων προβλέψεων για την Φ/Β και αιολική ισχύ, συμβάλλοντας στην ενσωμάτωση περισσότερων ΑΠΕ στο δίκτυο με καλύτερους όρους.

Ενώ πολλά είδη μοντέλων μηχανικής μάθησης προσφέρουν σημαντικά πλεονεκτήματα, τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks – ANN) αναδεικνύονται ως ιδιαίτερα ισχυρές τεχνικές για την βελτιστοποίηση της πρόβλεψης παραγωγής από ΑΠΕ. Τα ANN είναι υπολογιστικά συστήματα επεξεργασίας πληροφοριών, εμπνευσμένα από την βιολογική δομή και λειτουργία του ανθρώπινου εγκεφάλου. Αποτελούνται από διασυνδεδεμένες μονάδες επεξεργασίας, τους νευρώνες, οι οποίοι λειτουργούν σε παράλληλα επίπεδα. Κάθε σύνδεση μεταξύ των νευρώνων έχει ένα βάρος, το οποίο προσαρμόζεται συνεχώς κατά την εκπαίδευση μέσω αλγορίθμων βελτιστοποίησης, ώστε να ελαχιστοποιούνται τα σφάλματα πρόβλεψης [43].

Ένα από τα πλεονεκτήματα των ANN είναι ότι μπορούν να αναγνωρίζουν σύνθετες και μη γραμμικές σχέσεις, μέσω των οποίων συνδέονται τα δεδομένα εισόδου και εξόδου, ακόμη και όταν το πλήθος τους είναι μεγάλο ή η πολυπλοκότητά τους υψηλή. Επιπλέον, τα

ANN διαθέτουν ισχυρή ικανότητα γενίκευσης σε νέα, άγνωστα δεδομένα που είναι όμοια μόνο κατά προσέγγιση με τα αρχικά δεδομένα εκπαίδευσης, και ενδέχεται να είναι θορυβώδη ή ατελή. Επίσης, μία δομική ιδιότητα των ANN είναι ότι πολλές πανομοιότυπες πράξεις μπορούν να εκτελεστούν ανεξάρτητα και ταυτόχρονα, οπότε με την αξιοποίηση του κατάλληλου υλικού (π.χ. GPU/TPU) γίνεται παράλληλη επεξεργασία των δεδομένων, γεγονός που καθιστά τις συγκεκριμένες τεχνικές μηχανικής μάθησης ταχύτερες συγκριτικά με κλασικές μεθόδους, όπως είναι οι στατιστικές [43], [45].

Λαμβάνοντας υπόψη την κατεύθυνση της ροής της πληροφορίας, τα ANN διακρίνονται σε δύο θεμελιώδεις κατηγορίες: στα ANN Εμπρόσθιας Τροφοδότησης (Feed Forward Neural Network – FFNN) και στα Αναδρομικά ANN (Recurrent Neural Network – RNN). Τα FFNN χαρακτηρίζονται από μονόδρομη ροή της πληροφορίας, δηλαδή από την είσοδο προς την έξοδο, χωρίς να περιλαμβάνουν βρόχους ανάδρασης και κυκλικές συνδέσεις. Αντίθετα, στα RNN υπάρχουν μηχανισμοί ανάδρασης και η πληροφορία ανατροφοδοτείται, για παράδειγμα, η έξοδος ενός νευρώνα μπορεί να ανατροφοδοτηθεί ξανά ως είσοδος σε αυτόν, επιτρέποντας στο δίκτυο να διατηρεί εσωτερική μνήμη των προηγούμενων καταστάσεων [43].


3.2 ΔΙΚΤΥΑ FFNN

Τα δίκτυα FFNN αποτελούν μία από τις πιο κλασικές αρχιτεκτονικές ANN, όπου η πληροφορία ρέει αποκλειστικά προς μία κατεύθυνση, χωρίς βρόχους ανάδρασης. Χάρη στην ικανότητά τους να προσεγγίζουν μη γραμμικές συναρτήσεις μεγάλης πολυπλοκότητας, βρίσκουν ευρεία εφαρμογή τόσο σε προβλήματα ταξινόμησης (classification), όσο και σε προβλήματα παλινδρόμησης (regression). Ο MLP είναι ένας από τους πιο γνωστούς και διαδεδομένους τύπους FFNN [46].

Ο βασικός υπολογιστικός πυρήνας των MLP είναι ο νευρώνας. Όπως φαίνεται από το Σχήμα 3.1 [46], κάθε νευρώνας λαμβάνει m σήματα εισόδου (input signals) $x_1, x_2, \dots, x_m$, τα οποία πολλαπλασιάζονται με αντίστοιχους συντελεστές βάρους $w_{k1}, w_{k2}, \dots, w_{km}$ και συνδυάζονται γραμμικά. Στην συνέχεια, σε αυτόν τον γραμμικό συνδυασμό προστίθεται ένας όρος πόλωσης (bias) b_k , και έπειτα εφαρμόζεται μία συνάρτηση ενεργοποίησης (activation function) φ , μέσω της οποίας καθορίζεται η έξοδος του νευρώνα [46]. Μαθηματικά, λοιπόν, η είσοδος z ενός νευρώνα δίνεται από την σχέση (3.1), ενώ η έξοδος y_k εκφράζεται μέσω της εισόδου και της συνάρτησης ενεργοποίησης από την (3.2) :

$$z = \sum_{i=1}^m w_{ki} x_i + b_k \quad (3.1)$$

$$y_k = \varphi(z) \quad (3.2)$$




Σχήμα 3.1: Μαθηματικό μοντέλο της δομής ενός νευρώνα [46]

Όταν οι νευρώνες ενός ANN διατάσσονται παράλληλα, σχηματίζουν στρώματα (layers). Τα στρώματα των νευρώνων στην αρχιτεκτονική των δικτύων FFNN διακρίνονται σε τρεις κατηγορίες: το στρώμα εισόδου (input layer), το οποίο ακολουθείται από ένα ή περισσότερα κρυφά στρώματα (hidden layers) και αυτά με την σειρά τους συνδέονται με το στρώμα εξόδου (output layer). Το στρώμα εισόδου λαμβάνει τα αρχικά δεδομένα του εκάστοτε προβλήματος (π.χ. ταχύτητα ανέμου, θερμοκρασία) και τα μεταφέρει, με τους αντίστοιχους συντελεστές βάρους, στα κρυφά στρώματα. Κάθε νευρώνας του στρώματος εισόδου αντιστοιχεί σε μία από τις μεταβλητές εισόδου. Τα κρυφά στρώματα εκτελούν μη γραμμικούς μετασχηματισμούς στα δεδομένα εισόδου, επιτρέποντας στο δίκτυο να εξάγει σύνθετα χαρακτηριστικά και συσχετίσεις που δεν γίνονται αντιληπτές από το στρώμα εισόδου [43]. Σε ένα FFNN με πολλαπλά κρυφά στρώματα, κάθε επόμενο στρώμα επεξεργάζεται και αφαιρεί περιττές λεπτομέρειες ή θόρυβο, διατηρώντας μόνο τα σημαντικά μοτίβα και χαρακτηριστικά για την τελική έξοδο. Το στρώμα εξόδου συνδέεται με το τελευταίο κρυφό στρώμα και εφαρμόζοντας την κατάλληλη συνάρτηση ενεργοποίησης, παράγει την τελική έξοδο του δικτύου [47]. Στην αρχιτεκτονική ενός MLP, κάθε στρώμα του δικτύου είναι πλήρως συνδεδεμένο με αυτό που ακολουθεί (fully connected), δηλαδή κάθε νευρώνας του προηγούμενου στρώματος τροφοδοτεί όλους τους νευρώνες του επόμενου. Στην 3.2 φαίνεται η δομή ενός FFNN με ένα κρυφό στρώμα, όπου κάθε κύκλος αντιπροσωπεύει έναν νευρώνα του δικτύου και τα βέλη αντιπροσωπεύουν τα βάρη [48].

Οι συναρτήσεις ενεργοποίησης είναι πολύ σημαντικές για την λειτουργία ενός δικτύου FFNN, καθώς εισάγουν σε αυτό την απαραίτητη μη-γραμμικότητα, μετασχηματίζοντας τον γραμμικό συνδυασμό της σχέσης (3.1) σε μη-γραμμική έξοδο. Χωρίς αυτό το βήμα, το δίκτυο θα αδυνατούσε να μοντελοποιήσει σύνθετες και πολύπλοκες σχέσεις μεταξύ των δεδομένων εισόδου-εξόδου. Μία από τις πιο διαδεδομένες επιλογές για συνάρτηση ενεργοποίησης είναι η σιγμοειδής (sigmoid), η οποία βρίσκει εφαρμογή κυρίως ως συνάρτηση ενεργοποίησης του στρώματος εξόδου σε προβλήματα ταξινόμησης, καθώς περιορίζει την έξοδό της στο διάστημα $(0, 1)$ [46]. Επιπλέον, στα σύγχρονα βαθύτερα FFNN έχει επικρατήσει η συνάρτηση ReLU (Rectified Linear Unit) ως συνάρτηση ενεργοποίησης των κρυφών στρωμάτων, λόγω της

απλότητάς της και της ταχείας σύγκλισής της κατά την διαδικασία εκπαίδευσης [43]. Επίσης, για την ενεργοποίηση των κρυφών στρωμάτων χρησιμοποιείται και η υπερβολική εφαιπτομένη, η έξοδος της οποίας βρίσκεται στο διάστημα $(-1, 1)$ και έχει κέντρο της το 0 [46]. Όσον αφορά τα προβλήματα παλινδρόμησης (regression), εκτός από τις παραπάνω συναρτήσεις, το στρώμα εξόδου μπορεί να ενεργοποιηθεί και από την γραμμική συνάρτηση (linear), διότι οι τιμές εξόδου δεν περιορίζονται σε συγκεκριμένο εύρος και είναι συνεχείς, συμβαδίζοντας με την φύση αυτών των προβλημάτων [49]. Στον Πίνακα 3.1 παρουσιάζονται οι μαθηματικοί τύποι των παραπάνω συναρτήσεων.



Σχήμα 3.2: Διάγραμμα δομής ενός FFNN με ένα κρυφό στρώμα [48]

Πίνακας 3.1: Ευρέως διαδεδομένες συναρτήσεις ενεργοποίησης.

Συνάρτηση Ενεργοποίησης	Μαθηματικός Τύπος
Σιγμοειδής	$\varphi(z) = \frac{1}{1 + e^{-z}}$
ReLU	$\varphi(z) = \max(0, z)$
Υπερβολική Εφαιπτομένη	$\varphi(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$
Γραμμική	$\varphi(z) = z$

3.3 ΑΛΓΟΡΙΘΜΟΙ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ

Κατά την διάρκεια εκπαίδευσης ενός ANN, βασικός στόχος είναι η ελαχιστοποίηση ή μεγιστοποίηση μίας αντικειμενικής συνάρτησης ή συνάρτησης κόστους, η οποία, ουσιαστικά, ποσοτικοποιεί την απόκλιση μεταξύ των παραγόμενων από το δίκτυο εξόδων και των επιθυμητών τιμών. Αυτή η διαδικασία πραγματοποιείται μέσω της επαναληπτικής ρύθμισης των βαρών και των πολώσεων του ANN. Για την κατάλληλη, λοιπόν, ενημέρωση αυτών των παραμέτρων του δικτύου, ανάλογα με την εκάστοτε αντικειμενική συνάρτηση, απαιτείται η χρήση ενός αλγόριθμου βελτιστοποίησης, ο οποίος καθορίζει τον τρόπο με τον οποίο τα βάρη και οι πολώσεις τροποποιούνται σε κάθε επανάληψη της εκπαίδευσης.


3.3.1 Αλγόριθμοι μείωσης της κλίσης

Οι πιο ευρέως χρησιμοποιούμενοι αλγόριθμοι βελτιστοποίησης για την εκπαίδευση των ANN, είναι οι αλγόριθμοι μείωσης της κλίσης (gradient descent), οι οποίοι στοχεύουν στην ελαχιστοποίηση της αντικειμενικής συνάρτησης. Σε κάθε επανάληψη της διαδικασίας εκπαίδευσης, με βάση το διάνυσμα της κλίσης της συνάρτησης κόστους, δηλαδή με βάση τις μερικές παραγώγους της ως προς κάθε βάρος w_i και ως προς κάθε πόλωση b_i , πραγματοποιείται η αναπροσαρμογή αυτών των παραμέτρων, ακολουθώντας την αρνητική κατεύθυνση της κλίσης, δηλαδή την κατεύθυνση όπου η αντικειμενική συνάρτηση μειώνεται. Η επαναληπτική ενημέρωση των βαρών και των πολώσεων γίνεται μέχρι να εντοπιστεί το τοπικό ή ολικό ελάχιστο της συνάρτησης κόστους [43]. Ο γενικός κανόνας ενημέρωσης των βαρών w_i (και των πολώσεων b_i αντίστοιχα) διατυπώνεται στην σχέση (3.3) [47]

$$w_i(\tau + 1) = w_i(\tau) - \eta \frac{\partial J}{\partial w_i} \quad (3.3)$$

όπου τ ο αριθμός της τρέχουσας επανάληψης, η ο ρυθμός μάθησης (learning rate) και J η συνάρτηση κόστους. Ο ρυθμός μάθησης είναι ένας θετικός παράγοντας που καθορίζει το μέγεθος των βημάτων με τα οποία τροποποιούνται τα βάρη και οι πολώσεις και επηρεάζει άμεσα την ταχύτητα σύγκλισης και την σταθερότητα του αλγόριθμου βελτιστοποίησης: αν είναι υπερβολικά υψηλός ενδέχεται να προκαλέσει ταλαντώσεις γύρω από το ελάχιστο ή και εκτροπή από αυτό (divergence), ενώ αν είναι πολύ μικρός θα επιβραδύνει τον ρυθμό σύγκλισης, απαιτώντας περισσότερες επαναλήψεις στην διαδικασία εκπαίδευσης για να φτάσει στο επιθυμητό ελάχιστο [47]. Στο Σχήμα 3.3 φαίνεται η σχηματική αναπαράσταση ενός αλγόριθμου μείωσης της κλίσης [50].

Για την εκπαίδευση των περισσότερων ANN, εφαρμόζονται αλγόριθμοι μείωσης της κλίσης σε συνδυασμό με την οπίσθια διάδοση σφάλματος (backpropagation). Αρχικά, παράγεται η τελική έξοδος από το στρώμα εξόδου και υπολογίζεται ένα σφάλμα που καθορίζεται από την αντικειμενική συνάρτηση (forward pass). Έπειτα, το σφάλμα, μέσω του κανόνα της αλυσίδας (chain rule), διανέμεται από το στρώμα εξόδου προς τα πίσω κρυφά στρώματα και ταυτόχρονα υπολογίζεται η μερική παράγωγος της συνάρτησης κόστους ως προς κάθε βάρος και πόλωση (backward pass). Με βάση αυτές τις παραγώγους, τροποποιούνται οι παράμετροι του δικτύου και η διαδικασία επαναλαμβάνεται μέχρι να υπάρξει σύγκλιση σε κάποιο ελάχιστο της αντικειμενικής συνάρτησης [47].



Σχήμα 3.3: Σχηματική αναπαράσταση του τρόπου λειτουργίας του αλγόριθμου μείωσης της κλίσης [50]

Ανάλογα με το πλήθος των δεδομένων που χρησιμοποιούνται για την ενημέρωση των βαρών και των πολώσεων, διακρίνονται τρεις κύριες παραλλαγές του αλγόριθμου μείωσης της κλίσης. Στην Batch Gradient Descent (BGD), χρησιμοποιείται όλο το σύνολο των δεδομένων εκπαίδευσης σε κάθε επανάληψη, εξασφαλίζοντας σταθερή αλλά αργή σύγκλιση. Αντίθετα, η Stochastic Gradient Descent (SGD) ενημερώνει τις παραμέτρους για κάθε δείγμα ξεχωριστά, επιταχύνοντας σημαντικά την εκπαίδευση, αλλά εισάγοντας και μεγάλες απότομες μεταβολές που ενδέχεται να οδηγήσουν σε ταλαντώσεις κι όχι σε σύγκλιση στο ελάχιστο. Μία ενδιαφέρουσα λύση αποτελεί η Mini-Batch Gradient Descent, η οποία επιλέγει ένα μικρό υποσύνολο των δεδομένων για κάθε ενημέρωση, εξισορροπώντας την ταχύτητα σύγκλισης της SGD με την σταθερότητα της BGD [51].

Παρόλο που οι αλγόριθμοι που βασίζονται στην μείωση της κλίσης είναι τόσο ευρέως διαδεδομένοι και αξιοποιούνται σε διάφορες εφαρμογές μηχανικής μάθησης, παρουσιάζουν ορισμένα μειονεκτήματα. Ένα από τα σημαντικότερα είναι ότι όταν πρόκειται για πολύπλοκα προβλήματα με μη-κυρτές αντικειμενικές συναρτήσεις (non-convex loss functions), υπάρχει κίνδυνος εγκλωβισμού σε τοπικά βέλτιστα ή σε σαγματικά σημεία (saddle points) [43]. Επιπλέον, αυτοί οι αλγόριθμοι έχουν μεγάλη ευαισθησία στην παράμετρο του ρυθμού μάθησης η . Επίσης, η χρήση τους περιορίζεται μόνο σε εφαρμογές που οι αντικειμενικές συναρτήσεις και οι συναρτήσεις για μετρητικά σφάλματος είναι παραγωγίσιμες [23].

3.3.2 Αλγόριθμος PSO

Για την βελτιστοποίηση των παραμέτρων ενός ANN με μη-παραγωγίσιμη αντικειμενική συνάρτηση, όπου οι κλασικές μέθοδοι μείωσης της κλίσης αποτυγχάνουν, καθώς και σε εφαρμογές που είναι ανεπιθύμητη η πρόωρη σύγκλιση σε κάποιο τοπικό βέλτιστο, αξιοποιούνται οι στοχαστικοί αλγόριθμοι βελτιστοποίησης, στους οποίους δεν χρειάζεται ο

υπολογισμός παραγώγων. Διακρίνονται σε δύο κατηγορίες: τους ευρετικούς (heuristic) και τους μεταευρετικούς (metaheuristic).

Οι ευρετικοί αλγόριθμοι στηρίζονται σε γνωστούς κανόνες και πληροφορίες του προβλήματος για την εύρεση εφικτών λύσεων, οι οποίες δεν είναι απαραίτητα και οι βέλτιστες, με γνώμονα την μείωση του χρόνου υπολογισμού. Η λειτουργία τους βασίζεται στην τοπική αναζήτηση, καθώς εξετάζουν γειτονικές λύσεις για βελτίωση, χωρίς όμως να υπάρχει εγγύηση για καθολική βελτιστοποίηση [23]. Κάποιοι συχνά χρησιμοποιούμενοι ευρετικοί αλγόριθμοι είναι η άπληστη αναζήτηση (Greedy search) και η αναζήτηση με αναρρίχηση λόφων (Hill-Climbing search) [52].


Οι μεταευρετικοί αλγόριθμοι καθοδηγούν και βελτιστοποιούν τις ευρετικές αναζητήσεις, εφαρμόζοντας υψηλού επιπέδου στρατηγικές για την εξερεύνηση νέων περιοχών λύσεων (exploration) καθώς και για την αξιοποίηση ήδη γνωστών βέλτιστων (exploitation). Αυτές οι μέθοδοι βελτιστοποίησης συμβάλλουν στην ευκολότερη διαφυγή από τοπικά βέλτιστα και στην ισχυρότερη σύγκλιση σε καθολικά βέλτιστα [53]. Μερικά παραδείγματα γνωστών μεταευρετικών αλγόριθμων είναι ο γενετικός αλγόριθμος (Genetic Algorithm – GA), ο αλγόριθμος προσομοιωμένης απόπτωσης (Simulated Annealing – SA), η αναζήτηση με απαγορευμένες καταστάσεις (Tabu Search – TS) και η βελτιστοποίηση σμήνους σωματιδίων (Particle Swarm Optimization – PSO) [52].

Ο αλγόριθμος βελτιστοποίησης σμήνους σωματιδίων (αλγόριθμος PSO) είναι μεταευρετικός αλγόριθμος που στηρίζεται σε πληθυσμούς, δηλαδή παράγει πολλαπλές λύσεις σε κάθε επανάληψη [23]. Προτάθηκε από τους Kennedy και Eberhart το 1995 και εμπνεύστηκε από την κοινωνική και συλλογική συμπεριφορά κάποιων ειδών, όπως είναι τα σμήνη πτηνών όταν αυτά πετούν και αναζητούν τροφή σε μία περιοχή [54]. Ο αλγόριθμος PSO ξεκινάει με την τυχαία τοποθέτηση ενός πληθυσμού από N σωματίδια στον χώρο αναζήτησης, τα οποία αντιπροσωπεύουν τις υποψήφιες λύσεις, και με τον προσδιορισμό τριών παραμέτρων που χαρακτηρίζουν το καθένα από αυτά:

- η τρέχουσα θέση του σωματιδίου ($\vec{x}$), δηλαδή ένα διάνυσμα στο πεδίο αναζήτησης που αντιστοιχεί σε μία υποψήφια λύση.
- η ταχύτητα του σωματιδίου ($\vec{v}$), διάνυσμα που υποδηλώνει μεταβολή και καθορίζει την κατεύθυνση κίνησης του κάθε σωματιδίου.
- η προσωπική καλύτερη θέση στην οποία έχει βρεθεί το κάθε σωματίδιο ($Pbest$).

Σε περίπτωση που ο αλγόριθμος PSO εφαρμόζεται ως αλγόριθμος βελτιστοποίησης για την εκπαίδευση ενός ANN, η θέση κάθε σωματιδίου είναι ένα διάνυσμα που αντιστοιχεί στα βάρη και στις πολώσεις των νευρώνων της τρέχουσας επανάληψης, ενώ η ταχύτητα αντιπροσωπεύει το διάνυσμα μεταβολής αυτών των παραμέτρων [23]. Η προσωπική καλύτερη θέση του σωματιδίου ($Pbest$), αντιστοιχεί στην θέση όπου το σωματίδιο ικανοποίησε την αντικειμενική συνάρτηση με βέλτιστο τρόπο μέχρι την τρέχουσα επανάληψη. Η διαδικασία, λοιπόν, ξεκινάει με την αρχικοποίηση της θέσης και της ταχύτητας κάθε σωματιδίου σε τυχαίες τιμές εντός των ορίων του προβλήματος. Έπειτα, σε κάθε επανάληψη, κάθε σωματίδιο αξιολογείται μέσω της αντικειμενικής συνάρτησης και ενημερώνει την προσωπική καλύτερη θέση του αν η τρέχουσα υπολογισμένη $Pbest$ είναι βελτιωμένη. Ταυτόχρονα, συγκρίνει τις επιδόσεις του με την συνολικά καλύτερη θέση που έχει ανακαλυφθεί από όλα τα σωματίδια (σμήνος) μέχρι την τρέχουσα επανάληψη ($Gbest$). Στην συνέχεια, ανανεώνεται η ταχύτητα κάθε σωματιδίου, η οποία επηρεάζεται σημαντικά από τρεις συνιστώσες: την αδράνεια

(inertia), που εκφράζει την επιθυμία διατήρησης της τρέχουσας κατάστασης κίνησης, την γνωστική (cognitive) συνιστώσα, η οποία δείχνει κατά πόσο ένα σωματίδιο επιθυμεί να πλησιάσει στην προσωπική καλύτερη θέση του ($Pbest$), και την κοινωνική (social) συνιστώσα, η οποία αντιπροσωπεύει την ανάγκη ενός σωματιδίου να κινηθεί προς την βέλτιστη θέση που ανακάλυψε το σμήνος συνολικά ($Gbest$).



Σχήμα 3.4: Ενημέρωση ταχύτητας και θέσης ενός σωματιδίου στον αλγόριθμο PSO [55]

Μετά την ενημέρωση της ταχύτητας, πραγματοποιείται αναπροσαρμογή και της θέσης, απλώς προσθέτοντας στην τρέχουσα θέση την νέα ταχύτητα [54]. Στο Σχήμα 3.4 υπάρχει η γραφική αναπαράσταση της διαδικασίας ανανέωσης της ταχύτητας και της θέσης ενός σωματιδίου σε μία επανάληψη [55]. Τα βήματα της αξιολόγησης και της ενημέρωσης επαναλαμβάνονται μέχρι την ικανοποίηση κάποιου συγκεκριμένου κριτηρίου τερματισμού, όπως είναι ο αριθμός των επαναλήψεων ή η επαρκής τιμή της αντικειμενικής συνάρτησης.

Οι μαθηματικές σχέσεις (3.4) και (3.5) αποτυπώνουν την διαδικασία ενημέρωσης της ταχύτητας κάθε σωματιδίου και της θέσης, αντίστοιχα, σε κάθε επανάληψη και ισχύουν για μία διάσταση [23]:

$$\vec{v}(\tau + 1) = w\vec{v}(\tau) + c_1r_1(\vec{pbest} - \vec{x}(\tau)) + c_2r_2(\vec{Gbest} - \vec{x}(\tau)) \quad (3.4)$$

$$\vec{x}(\tau + 1) = \vec{x}(\tau) + \vec{v}(\tau + 1) \quad (3.5)$$

όπου τ ο αριθμός της τρέχουσας επανάληψης, w το βάρος της αδράνειας που είναι παράμετρος που λαμβάνει τιμές στο διάστημα $[0.1, 1.2]$ και ποσοτικοποιεί την δυνατότητα του σωματιδίου να αλλάζει κατεύθυνση, c_1 και c_2 συντελεστές βαρύτητας που χαρακτηρίζουν την γνωστική

και κοινωνική συνιστώσα και r_1, r_2 οι στοχαστικοί παράγοντες, οι οποίοι ανήκουν στο διάστημα $[0, 1]$ και παράγονται τυχαία για κάθε επανάληψη και σωματίδιο [32].

Ο αλγόριθμος PSO χρησιμοποιείται ευρέως λόγω της απλότητας στην υλοποίησή του και της ικανότητάς του να παρέχει ταχεία σύγκλιση με χαμηλό υπολογιστικό κόστος σε σύνθετα, μη-γραμμικά προβλήματα, χωρίς να απαιτεί την παραγωγισιμότητα της αντικειμενικής συνάρτησης. Επιπλέον, πρόκειται για έναν ευέλικτο αλγόριθμο, καθώς χρειάζεται να γίνει ρύθμιση μόνο τριών υπερπαραμέτρων (w, c_1, c_2), γεγονός που διευκολύνει την εφαρμογή του σε διάφορα προβλήματα βελτιστοποίησης [56].

3.4 ΑΝΤΙΚΕΙΜΕΝΙΚΕΣ ΣΥΝΑΡΤΗΣΕΙΣ

Οι αντικειμενικές συναρτήσεις, γνωστές και ως συναρτήσεις κόστους, ποσοτικοποιούν την απόκλιση μεταξύ των τιμών εξόδου ενός ANN και των αντίστοιχων επιθυμητών πραγματικών τιμών, παρέχοντας έτσι ένα μέτρο για την αποδοτικότητα του δικτύου. Ουσιαστικός στόχος σε κάθε επανάληψη της διαδικασίας εκπαίδευσης είναι η ελαχιστοποίηση ή η μεγιστοποίηση της αντικειμενικής συνάρτησης, γεγονός που εξαρτάται από την επιλογή αυτής και τα χαρακτηριστικά του εκάστοτε προβλήματος. Η σχεδίαση και η επιλογή της αντικειμενικής συνάρτησης που θα χρησιμοποιηθεί σε κάθε εφαρμογή γίνεται με βάση την φύση του προβλήματος (π.χ. προβλήματα ταξινόμησης ή προβλήματα παλινδρόμησης) και τις στατιστικές ιδιότητες των δεδομένων εκπαίδευσης (π.χ. ακραίες τιμές (outliers), θόρυβος). Επίσης, σημαντικός παράγοντας είναι και τα χαρακτηριστικά που επιδιώκεται να έχει το δίκτυο, όσον αφορά τα σφάλματα. Για παράδειγμα, ενδέχεται σε μία εφαρμογή να είναι επιθυμητή η ευαισθησία στις ακραίες τιμές, ενώ σε ένα άλλο πρόβλημα να συμβαίνει το αντίθετο. Η σωστή επιλογή της αντικειμενικής συνάρτησης είναι κρίσιμη για την συμπεριφορά του ANN κατά την εκπαίδευση, καθώς και για την σταθερότητα και ταχύτητα σύγκλισής του [43].

3.4.1 Ελαχιστοποίηση μέσου απόλυτου σφάλματος

Μία από τις πιο συχνά χρησιμοποιούμενες αντικειμενικές συναρτήσεις για την εκπαίδευση ενός ANN σε προβλήματα παλινδρόμησης, είναι η ελαχιστοποίηση του μέσου απόλυτου σφάλματος (Mean Absolute Error – MAE). Σε αυτό το πλαίσιο, το MAE ορίζεται ως ο μέσος όρος των απόλυτων διαφορών μεταξύ των πραγματικών τιμών και αυτών που έχουν προβλεφθεί από το δίκτυο, όπως φαίνεται και από την σχέση (3.6) [57]

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3.6)$$

όπου N ο αριθμός των δεδομένων εκπαίδευσης, y_i η πραγματική τιμή του δείγματος i και $\hat{y}_i$ η προβλεπόμενη έξοδος του ANN για το δείγμα i .

Σύμφωνα με την μαθηματική σχέση (3.6), τα σφάλματα που υπολογίζονται δεν υψώνονται σε κάποια δύναμη, γεγονός που σημαίνει ότι το MAE είναι ανθεκτικό σε ακραίες τιμές των δεδομένων και δεν δίνει υπερβολικά μεγάλη βαρύτητα στα μεγάλα σφάλματα. Επιπλέον, το αποτέλεσμα του MAE είναι αρκετά ερμηνεύσιμο, διότι μετριέται στις ίδιες μονάδες με τα δεδομένα εκπαίδευσης, διευκολύνοντας την ανάλυση της επίδοσης του δικτύου

[57]. Βέβαια, εξαιτίας της απόλυτης τιμής, η συγκεκριμένη συνάρτηση είναι μη-παραγωγίσιμη στο σημείο που το σφάλμα είναι μηδέν, και άρα δημιουργεί προβλήματα στην διαδικασία βελτιστοποίησης με αλγόριθμους μείωσης της κλίσης [43].

3.4.2 Ελαχιστοποίηση μέσου τετραγωνικού σφάλματος

Η ελαχιστοποίηση του μέσου τετραγωνικού σφάλματος (Mean Squared Error – MSE) εφαρμόζεται ευρέως για την εκπαίδευση ενός ANN σε προβλήματα παλινδρόμησης και, σύμφωνα με την μαθηματική σχέση (3.7) [57], ορίζεται ως η μέση τιμή των τετραγωνικών διαφορών μεταξύ των πραγματικών τιμών και των τιμών που προβλέπει το δίκτυο [57].

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3.7)$$

Στην σχέση (3.7), N είναι ο αριθμός των δεδομένων εκπαίδευσης, y_i είναι η επιθυμητή τιμή του δείγματος i και $\hat{y}_i$ είναι η πρόβλεψη του ANN για το δείγμα i .

Η συγκεκριμένη αντικειμενική συνάρτηση είναι διαδεδομένη, διότι είναι απλή στην υλοποίηση και είναι ομαλή και διαφορίσιμη σε όλα τα σημεία της, επιτρέποντας αποδοτική βελτιστοποίηση με χρήση αλγορίθμων μείωσης της κλίσης. Λόγω της ύψωσης στο τετράγωνο, το MSE είναι ευαίσθητο σε ακραίες τιμές και επιβάλλει αυξημένες ποινές σε μεγάλες αποκλίσεις, παράγοντας συντηρητικότερες προβλέψεις, γεγονός που μπορεί να θεωρηθεί ως πλεονέκτημα, αν τα μεγάλα σφάλματα είναι ιδιαίτερα ανεπιθύμητα [57]. Ωστόσο, αυτή η ευαισθησία ενδέχεται να οδηγήσει σε ασταθή εκπαίδευση σε περιπτώσεις που τα διαθέσιμα δεδομένα δεν ακολουθούν κανονική κατανομή, όπως συμβαίνει, για παράδειγμα, σε δεδομένα που περιγράφουν μεταβαλλόμενες καιρικές συνθήκες [58]. Το γεγονός αυτό οδηγεί σε παραγωγή εξομαλυμένων καμπυλών πρόβλεψης, οι οποίες μπορεί να ελαχιστοποιούν το σφάλμα MSE, αλλά δεν ανταποκρίνονται στις πραγματικές απότομες μεταβολές της υπό εξέταση μεταβλητής [5].

3.4.3 Ελαχιστοποίηση μέσου τόξου εφαπτομένης του απόλυτου ποσοστιαίου σφάλματος

Η ελαχιστοποίηση του μέσου τόξου εφαπτομένης του απόλυτου ποσοστιαίου σφάλματος (Mean Arctangent Absolute Percentage Error – MAAPE) περιγράφεται μαθηματικά από την σχέση (3.8) [59]

$$MAAPE = \frac{1}{N} \sum_{i=1}^N \arctan \left(\left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \quad (3.8)$$

όπου N ο αριθμός των δεδομένων εκπαίδευσης, y_i η πραγματική τιμή του δείγματος i και $\hat{y}_i$ η προβλεπόμενη έξοδος για το δείγμα i . Η συνάρτηση για τον υπολογισμό του MAAPE αποτελεί μία παραλλαγή της συνάρτησης για τον υπολογισμό του μέσου απόλυτου ποσοστιαίου σφάλματος (Mean Absolute Percentage Error – MAPE), η οποία δίνεται από τον τύπο (3.9) [59].

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left(\left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \quad (3.9)$$

Η ανάγκη για αυτή την τροποποίηση προέκυψε επειδή για τα πραγματικά δεδομένα που ήταν ίσα με το μηδέν ή είχαν πολύ μικρή τιμή, η τιμή του MAPE ήταν απροσδιόριστη ή εξαιρετικά μεγάλη αντίστοιχα, ενώ με την προσθήκη του όρου του τόξου εφαπτομένης, η τιμή του σφάλματος οριοθετείται πλέον στο διάστημα $[0, \frac{\pi}{2}]$ [59]. Επομένως, το MAAPE μπορεί να διαχειριστεί σειρές δεδομένων που έχουν αρκετές μηδενικές τιμές, όπως συμβαίνει στα δεδομένα παραγωγής των ΑΠΕ, και λόγω της φραγμένης συμπεριφοράς του τόξου εφαπτομένης η ποινή για τα μεγάλα σφάλματα δεν απειρίζεται, προσφέροντας σταθερότερη εκπαίδευση σε δεδομένα με ακραίες τιμές.

3.4.4 Ελαχιστοποίηση σφάλματος $\log\text{--cosh}$

Η ελαχιστοποίηση του σφάλματος $\log\text{--cosh}$ εφαρμόζεται και αυτή σε προβλήματα παλινδρόμησης και ορίζεται ως ο μέσος όρος του λογαριθμικού υπερβολικού συνημιτόνου των σφαλμάτων πρόβλεψης και περιγράφεται από την σχέση (3.10) [60]

$$\text{Logcosh} = \frac{1}{N} \sum_{i=1}^N \log(\cosh(y_i - \hat{y}_i)) \quad (3.10)$$

όπου N ο αριθμός των δεδομένων εκπαίδευσης, y_i η πραγματική τιμή του δείγματος i και $\hat{y}_i$ η πρόβλεψη του δικτύου για το δείγμα i . Η συνάρτηση $\log(\cosh(x))$ έχει την εξής ιδιότητα: για μικρές τιμές του x κοντά στο μηδέν, έχει παρόμοια συμπεριφορά με την συνάρτηση $\frac{1}{2}x^2$, ενώ για μεγάλες τιμές του x προσεγγίζει την συνάρτηση $|x| - \log 2$. Αυτό σημαίνει, ότι στα πλαίσια χρήσης της ως αντικειμενική συνάρτηση, προσομοιάζει την λειτουργία της ελαχιστοποίησης του MSE, όταν πρόκειται για μικρά σφάλματα $y_i - \hat{y}_i$. Αντίστοιχα, για μεγάλες αποκλίσεις μεταξύ της πραγματικής και της προβλεπόμενης τιμής, συμπεριφέρεται σαν την ελαχιστοποίηση του MAE. Επομένως, η αντικειμενική συνάρτηση $\log\text{--cosh}$ αποτελεί μία πιο ανθεκτική εναλλακτική και για το MSE αλλά και για το MAE, καθώς εξισορροπεί την ευαισθησία σε μικρά σφάλματα και την ομαλότητα και σταθερότητα σε σφάλματα μεγάλης τιμής. Επιπλέον, η $\log\text{--cosh}$ είναι ομαλή και διαφορίσιμη σε όλα τα σημεία της, διευκολύνοντας την διαδικασία βελτιστοποίησης με αλγόριθμους μείωσης της κλίσης [60].

3.4.5 Μεγιστοποίηση δείκτη F1

Ο δείκτης F1 (F1 score) είναι ένα μετρητικό το οποίο μετράει την ικανότητα ενός μοντέλου να εντοπίζει συγκεκριμένα συμβάντα σε συνδυασμό με την ικανότητά του να ελαχιστοποιεί τους λανθασμένους συναγερμούς. Σύμφωνα με το άρθρο *Ramp Rate Metric Suitable for Solar Forecasting* των Nouri et al. [5], σε εφαρμογές πρόβλεψης παραγωγής από ΑΠΕ, ο δείκτης F1 μετράει την δυνατότητα ανίχνευσης συμβάντων απότομης μεταβολής, όπως

αυτά ορίστηκαν στην Ενότητα 2.7. Υπολογίζεται από τον τύπο (3.11) [5] και αποτελεί έναν δείκτη ισορροπίας ανάμεσα στην ακρίβεια (*precision*) και στην ανάκληση (*recall*). Η ακρίβεια είναι ένα μετρητικό που, ουσιαστικά, απαντάει στην ερώτηση: από το σύνολο των συμβάντων απότομης μεταβολής που προβλέφθηκαν από το μοντέλο, πόσα από αυτά πραγματοποιήθηκαν; Η ανάκληση, από την άλλη πλευρά, απαντάει στην εξής ερώτηση: από το σύνολο των απότομων μεταβολών που καταγράφηκαν στην πραγματικότητα, πόσα από αυτά προβλέφθηκαν από το μοντέλο; Τα δύο αυτά μετρητικά υπολογίζονται σύμφωνα με τους τύπους (3.12) [5] και (3.13) [5]:

$$F1 = \frac{2 \cdot precision \cdot recall}{(precision + recall)} \quad (3.11)$$

$$Precision = \frac{TP}{TP + FP} \quad (3.12)$$

$$Recall = \frac{TP}{TP + FN} \quad (3.13)$$

όπου *TP* (True Positive) αληθινά θετικό αποτέλεσμα (συνέβη απότομη μεταβολή και προβλέφθηκε), *FP* (False Positive) ψευδώς θετικό αποτέλεσμα (προβλέφθηκε συμβάν απότομης μεταβολής που δεν συνέβη) και *FN* (False Negative) ψευδώς αρνητικό αποτέλεσμα (συνέβη απότομη μεταβολή που δεν προβλέφθηκε). Ο δείκτης F1 λαμβάνει τιμές στο διάστημα [0, 1] και όσο η τιμή του πλησιάζει στην μονάδα, τόσο πιο ικανό και αξιόπιστο είναι το μοντέλο στην πρόβλεψη συμβάντων απότομης μεταβολής [5]. Επομένως, η χρήση του δείκτη F1 ως αντικειμενική συνάρτηση συνεπάγεται την μεγιστοποίησή του κατά την διάρκεια της εκπαίδευσης. Γίνεται κατανοητό ότι ένα ANN που εκπαιδεύεται με αυτόν τον δείκτη ως αντικειμενική συνάρτηση, εκπαιδεύεται με γνώμονα την ανίχνευση συμβάντων απότομης μεταβολής κι όχι την ελαχιστοποίηση του μέσου σφάλματος πρόβλεψης.

ΑΝΑΛΥΣΗ ΔΕΔΟΜΕΝΩΝ ΚΑΙ ΜΕΘΟΔΟΛΟΓΙΑ ΓΙΑ ΤΑ ΜΟΝΤΕΛΑ ΠΡΟΒΛΕΨΗΣ

Στο παρόν κεφάλαιο περιγράφεται η διαδικασία ανάλυσης και προεπεξεργασίας των δεδομένων αιολικής και Φ/Β παραγωγής, καθώς και η μεθοδολογία που ακολουθήθηκε για την υλοποίηση των στατιστικών μοντέλων πρόβλεψης Persistence και ARIMA, και του μοντέλου FFNN, το οποίο έχει την αρχιτεκτονική ενός MLP.

4.1 ΕΠΕΞΕΡΓΑΣΙΑ ΑΙΟΛΙΚΩΝ ΔΕΔΟΜΕΝΩΝ

Τα αιολικά δεδομένα που χρησιμοποιήθηκαν για την παραγωγή προβλέψεων αιολικής ισχύος αφορούν σε μία Α/Γ. Τα διαθέσιμα αριθμητικά δεδομένα περιλαμβάνουν τιμές για 3 μεταβλητές:

- για την ταχύτητα του ανέμου μετρημένη σε m/s
- για την κατεύθυνση του ανέμου μετρημένη σε $\hat{A}^\circ$
- για την παραγόμενη ισχύ της Α/Γ μετρημένη σε kW

4.1.1 Προέλευση και ανάλυση των δεδομένων αιολικής παραγωγής

Τα δεδομένα αιολικής παραγωγής της παρούσας διπλωματικής εργασίας προέρχονται από δημόσια διαθέσιμες μετρήσεις για μία Α/Γ του αιολικού πάρκου Penmanshiel, το οποίο βρίσκεται στην πόλη Grantshouse του Ηνωμένου Βασιλείου [61],[62]. Η εν λόγω Α/Γ είναι η Penmanshiel 15, έχει διάμετρο δρομέα 82m και η ονομαστική της ισχύς είναι 2050kW [61]. Οι συγκεκριμένες μετρήσεις έχουν παρθεί σε χρονικό διάστημα δύο ετών, από 01/01/2017 και ώρα 12 π.μ. έως και 31/12/2018 και ώρα 11:50 μ.μ., με χρονική ανάλυση δέκα λεπτών. Αναλυτικότερα, το αρχείο με τα αιολικά δεδομένα είναι σε μορφή φύλλου εργασίας Microsoft Excel (.xlsx), το οποίο περιέχει τέσσερις στήλες:

- Στήλη A: Περιλαμβάνει την ημερομηνία και ώρα για κάθε μέτρηση (Date and Time).
- Στήλη B: Περιέχει μετρήσεις για την ταχύτητα του ανέμου (Wind speed (m/s))
- Στήλη C: Περιέχει μετρήσεις για την κατεύθυνση του ανέμου (Wind direction ($\hat{A}^\circ$))
- Στήλη D: Έχει μετρήσεις για την ισχύ εξόδου όπως Α/Γ (Power (kW))

Τα διαθέσιμα στοιχεία συλλέχθηκαν με συχνότητα δέκα λεπτών, επομένως, για κάθε μέγεθος, υπάρχουν $(2 \text{ έτη}) \times (8760 \text{ ώρες/έτος}) \times (6 \text{ καταγραφές/ώρα}) = 105120$ καταγραφές. Προκειμένου να διευκολυνθούν όλες οι διαδικασίες επεξεργασίας των δεδομένων και να διασφαλιστεί η ακρίβεια των αποτελεσμάτων της παρούσας διπλωματικής εργασίας, πραγματοποιήθηκε

έλεγχος για κενές τιμές και καθαρισμός αυτών, οπότε ο αριθμός των μετρήσεων για κάθε μέγεθος έγινε 104831.

Πριν την υλοποίηση των μοντέλων πρόβλεψης, πραγματοποιήθηκε στατιστική ανάλυση των αιολικών δεδομένων. Πιο συγκεκριμένα, επειδή η συγκεκριμένη εργασία επικεντρώνεται στην πρόβλεψη των απότομων μεταβολών στην παραγωγή ισχύος από ΑΠΕ, δημιουργήθηκαν δύο διαγράμματα σχετικά με τα συμβάντα απότομης μεταβολής που έχουν παρατηρηθεί (Observed Ramp Events – ORE), σύμφωνα με τις διαθέσιμες μετρήσεις. Με βάση το άρθρο *Ramp Rate Metric Suitable for Solar Forecasting* των Nouri et al. [5], όταν πρόκειται για δεδομένα που έχουν χρονική ανάλυση ίση με τον επιθυμητό χρονικό ορίζοντα πρόβλεψης, τα συμβάντα απότομης μεταβολής παρατηρούνται όταν ικανοποιείται η σχέση (4.1):


$$|y(t + FH) - y(t)| > \varepsilon \quad (4.1)$$

ενώ τα συμβάντα απότομης μεταβολής που έχουν προβλεφθεί (Predicted Ramp Events – PRE), ικανοποιούν την σχέση (4.2):

$$|\hat{y}(t + FH) - y(t)| > \varepsilon \quad (4.2)$$

Στις σχέσεις (4.1) και (4.2), FH είναι ο χρονικός ορίζοντας πρόβλεψης (Forecast Horizon – FH), ε το κρίσιμο κατώφλι της απότομης μεταβολής (critical ramp threshold), $y(t)$ η μετρηθείσα τιμή της αιολικής παραγωγής την χρονική στιγμή t , $y(t + FH)$ η πραγματική τιμή της αιολικής παραγωγής την χρονική στιγμή $t + FH$ και $\hat{y}(t + FH)$ η τιμή της πρόβλεψης για την αιολική παραγωγή την χρονική στιγμή $t + FH$. Η απόλυτη τιμή υπάρχει διότι, όπως αναφέρθηκε και στην Ενότητα 2.7, μία απότομη και γρήγορη μεταβολή στην παραγωγή μπορεί να αντιστοιχεί είτε σε μείωση είτε σε αύξηση, οπότε ουσιαστική σημασία έχει μόνο το μέγεθος της μεταβολής αυτής. Επίσης, το κατώφλι ε υπολογίζεται ως το 10% της ονομαστικής ισχύος της Α/Γ [5], δηλαδή το κατώφλι ε είναι ίσο με 205kW για τη συγκεκριμένη Α/Γ Penmanshiel 15 του αιολικού πάρκου Penmanshiel.


Λαμβάνοντας υπόψη την σχέση (4.1), δημιουργήθηκε το ιστόγραμμα του Σχήματος 4.1 το οποίο αναπαριστά την συχνότητα εμφάνισης των συμβάντων απότομης μεταβολής στα αιολικά δεδομένα, όπου ο οριζόντιος άξονας είναι το ποσοστό του μεγέθους της απότομης μεταβολής ως προς την ονομαστική ισχύ, και ο κάθετος άξονας αντιπροσωπεύει το πλήθος των παρατηρήσεων. Στο Σχήμα 4.1, οι κόκκινες στήλες αντιστοιχούν στα ORE, δηλαδή απότομες μεταβολές των οποίων το μέγεθος ξεπερνάει το κατώφλι ε , το οποίο συμβολίζεται με διακεκομμένη κατακόρυφη μαύρη γραμμή. Επιπλέον, υπολογίστηκε το ποσοστό των ORE ως προς το σύνολο των συνολικών απότομων μεταβολών που παρατηρήθηκαν και όπως αναγράφεται στο διάγραμμα είναι ίσο με 14,8%, ποσοστό που αντιστοιχεί σε 15520 καταγεγραμμένα συμβάντα απότομης μεταβολής που υπερέβησαν το κατώφλι ε . Η μορφή του ιστογράμματος στο Σχήμα 4.1 φαίνεται ότι είναι κατά προσέγγιση καμπανοειδής και συμμετρική γύρω από το μηδέν, φαίνεται δηλαδή ότι η κατανομή που ακολουθεί η συχνότητα εμφάνισης συμβάντων απότομης μεταβολής σε σχέση με το μέγεθος αυτών προσεγγίζει την κανονική κατανομή, με τα περισσότερα ORE να έχουν σχετικά χαμηλή ένταση που εκτείνεται από το 10% της ονομαστικής ισχύος έως το 20% της ονομαστικής ισχύος (205kW έως 410kW). Τα μεγαλύτερα σε ένταση ORE καταγράφονται πιο σπάνια, και εκτείνονται έως και το 50% της ονομαστικής ισχύος. Η μέση τιμή του μεγέθους των ORE είναι ίση με 347kW.



Σχήμα 4.1: Συχνότητα εμφάνισης συμβάντων απότομης μεταβολής στα αιολικά δεδομένα

Στο Σχήμα 4.2 υπάρχει το θηκόγραμμα για την κατανομή των συμβάντων απότομης μεταβολής, ομαδοποιημένα σε πέντε εύρη ταχυτήτων ανέμου (0–6 m/s, 6–12 m/s, 12–18 m/s, 18–24 m/s, 24–30 m/s). Για κάθε εύρος ταχυτήτων, η θήκη αναπαρίσταται από το μπλε ορθογώνιο σχήμα, ενώ η οριζόντια γραμμή εντός του είναι η διάμεσος και το κόκκινο σταυρόνημο δείχνει την μέση τιμή της κατανομής των συμβάντων απότομης μεταβολής. Το ύψος της θήκης αποτελεί δείγμα της διασποράς των δεδομένων. Για παράδειγμα, για το εύρος 0–6 m/s, το ύψος της θήκης είναι περίπου 100kW, γεγονός που σημαίνει ότι το 50% των ORE σε αυτή την κλίμακα ταχυτήτων κυμαίνεται περίπου ± 50 kW γύρω από την τιμή της διαμέσου. Στο συγκεκριμένο διάγραμμα, μέσα στους φράκτες οριοθετείται το 82% των απότομων μεταβολών, ενώ αυτές που βρίσκονται εκτός αυτού του διαστήματος, δηλαδή τα σημεία που απεικονίζονται ως κύκλοι, είναι οι ακραίες τιμές. Η διακεκομμένη οριζόντια γραμμή αντιπροσωπεύει το κατώφλι ε , πάνω από το οποίο οι απότομες μεταβολές είναι κρίσιμες, δηλαδή όταν καταγράφεται ORE. Το γενικό συμπέρασμα που προκύπτει από το Σχήμα 4.2 είναι ότι το μέγεθος των συμβάντων απότομης μεταβολής δεν φαίνεται να επηρεάζεται ιδιαίτερα από την ταχύτητα του ανέμου, γεγονός που σχετίζεται με την σιγμοειδή μορφή της θεωρητικής καμπύλης ισχύος μίας Α/Γ (Σχήμα 2.4), σύμφωνα με την οποία, μικρές αλλαγές στην ταχύτητα του ανέμου, ειδικά γύρω από την περιοχή λειτουργίας κοντά στην ονομαστική ταχύτητα, οδηγούν σε μεγάλες μεταβολές της ισχύος εξόδου. Επειδή τα επιλεγμένα διαστήματα τιμών για το Σχήμα 4.2 έχουν σημαντικό εύρος (ανά 6 m/s), οι μεταβολές αυτές φαίνονται εξομαλυσμένες. Επίσης, όπως αναγράφεται και στο Σχήμα 4.1, τα ORE αντιστοιχούν στο 14.8% των συνολικών απότομων μεταβολών, επομένως στο Σχήμα 4.2, εκπροσωπούνται κυρίως από τις ακραίες τιμές και όχι από τις θήκες. Όσον αφορά στις ακραίες τιμές, φαίνεται ότι για ταχύτητες ανέμου μέχρι 24 m/s είναι αρκετές σε πλήθος, γεγονός που ερμηνεύεται και αυτό βάσει της σιγμοειδούς μορφής της θεωρητικής καμπύλης ισχύος μίας Α/Γ. Για ταχύτητες

ανέμου στο εύρος από 24m/s έως 30m/s, η Α/Γ βρίσκεται συνήθως στην περιοχή ονομαστικής λειτουργίας, οπότε είναι αναμενόμενο τα συμβάντα απότομης μεταβολής να είναι χαμηλότερης έντασης και οι ακραίες τιμές να είναι πολύ λίγες, όπως επιβεβαιώνεται και στο Σχήμα 4.2. Σχετικά με τους φράκτες, γίνεται αντιληπτό ότι για εύρος ταχυτήτων ανέμου από 0m/s έως 6m/s, ο άνω φράκτης είναι σχετικά μειωμένος σε σχέση με τα υπόλοιπα εύρη. Αυτό είναι λογικό, καθώς για τέτοιες ταχύτητες ανέμου η Α/Γ βρίσκεται σε χαμηλά επίπεδα παραγωγής, επομένως τα περιθώρια διακύμανσης στην ισχύ είναι μικρότερα.



Σχήμα 4.2: Θηκόγραμμα των συμβάντων απότομης μεταβολής στην αιολική παραγωγή για διαφορετικά εύρη ταχυτήτων ανέμου

4.1.2 Προεπεξεργασία των δεδομένων αιολικής παραγωγής

Προκειμένου να εξασφαλιστεί η παραγωγή αξιόπιστων αποτελεσμάτων στην παρούσα διπλωματική εργασία, πραγματοποιήθηκε επεξεργασία και έλεγχος στα αιολικά δεδομένα πριν αυτά χρησιμοποιηθούν ως είσοδοι στα μοντέλα υπερβραχυπρόθεσμης πρόβλεψης αιολικής ισχύος. Όπως αναφέρθηκε στην Ενότητα 4.1.1, το πρώτο βήμα επεξεργασίας ήταν ο έλεγχος για κενές ή ελλιπείς τιμές και ο καθαρισμός αυτών από το αρχείο των διαθέσιμων μετρήσεων, ώστε τα δεδομένα να είναι ομοιογενή και τα μοντέλα να παράγουν ακριβείς και αξιόπιστες προβλέψεις.

Έπειτα, όσον αφορά στα στατιστικά μοντέλα Persistence και ARIMA, έγινε διαχωρισμός των δεδομένων σε δύο ομάδες: στα δεδομένα που θα χρησιμοποιήσει το μοντέλο ως ιστορικές παρατηρήσεις για να παράγει τις προβλέψεις και στα δεδομένα που θα αξιοποιηθούν για δοκιμή και έλεγχο της επίδοσης του μοντέλου, μέσω των μετρητικών

σφάλματος. Στην πρώτη ομάδα ανήκει το 75% του συνόλου των αιολικών δεδομένων, ενώ στην δεύτερη ανήκει το υπόλοιπο 25%, καθώς με αυτή την αναλογία εξασφαλίζεται αρκετά μεγάλο ιστορικό υλικό που είναι απαραίτητο για αυτές τις μεθόδους πρόβλεψης, αλλά και επαρκές σύνολο δοκιμής για την αξιολόγηση της επίδοσης των μοντέλων. Επιπλέον, για το μοντέλο ARIMA, πραγματοποιήθηκε έλεγχος για την στασιμότητα των δεδομένων, ώστε να διαπιστωθεί αν υπάρχει ανάγκη διαφορίσης, σύμφωνα και με ό,τι αναφέρεται στην Ενότητα 2.5.1.1, και προέκυψε ότι τα δεδομένα είναι στάσιμα. Ο έλεγχος έγινε μέσω της συνάρτησης *adfuller* της βιβλιοθήκης *statsmodels* της προγραμματιστικής γλώσσας Python, η οποία εκτελεί τον επαυξημένο έλεγχο Dickey-Fuller (Augmented Dickey-Fuller test – ADF test) που εξετάζει αν μία χρονοσειρά είναι στάσιμη ή μη-στάσιμη. Περισσότερες πληροφορίες για τον έλεγχο ADF περιέχονται στην κλασική μελέτη των S. E. Said and D. A. Dickey *Testing for Unit Roots in Autoregressive-Moving Average Models of Unknown Order* [64] καθώς και στο Κεφάλαιο 4 του βιβλίου *Applied Econometric Time Series* του W. Enders [65].

Για την κατάλληλη και αποδοτική εκπαίδευση του MLP, πραγματοποιήθηκε διαχωρισμός του συνόλου των αιολικών δεδομένων σε δεδομένα εκπαίδευσης (train), δεδομένα επικύρωσης (validation) και σε δεδομένα τελικής αξιολόγησης (test) με ποσοστά 50%, 25% και 25% αντίστοιχα. Η συγκεκριμένη κατανομή παρέχει επαρκή δεδομένα εκπαίδευσης στο μοντέλο για την εκμάθηση σύνθετων μοτίβων και διασφαλίζει την αξιόπιστη αξιολόγησή του ως προς την ακρίβεια και την ικανότητα προσαρμογής του σε νέα δεδομένα [43]. Επίσης, έγινε κανονικοποίηση των δεδομένων, η οποία, στο πλαίσιο της εκπαίδευσης μοντέλων μηχανικής μάθησης, ορίζεται ως ο μετασχηματισμός των τιμών των διάφορων μεταβλητών εισόδου, ώστε να βρίσκονται σε ένα κοινό εύρος, συνήθως εντός των διαστημάτων $[0, 1]$ ή $[-1, 1]$. Αυτή η διαδικασία είναι απαραίτητη για την αποτελεσματική και αμερόληπτη εκπαίδευση ενός μοντέλου μηχανικής μάθησης, καθώς αποτρέπει τα δεδομένα μίας μεταβλητής με μεγάλη φυσική μονάδα μέτρησης να κυριαρχήσουν στην εκπαίδευση, και μειώνει την επίδραση των ακραίων τιμών [43]. Στην παρούσα διπλωματική εργασία, τα δεδομένα αιολικής παραγωγής κανονικοποιήθηκαν χρησιμοποιώντας την συνάρτηση *StandardScaler* της βιβλιοθήκης *scikit-learn* της Python, η οποία δεν περιορίζει τις τιμές σε κάποιο συγκεκριμένο διάστημα και τις μετασχηματίζει ώστε να έχουν μηδενικό μέσο όρο και μοναδιαία τυπική απόκλιση, χρησιμοποιώντας για κάθε δείγμα x_i του συνόλου εκπαίδευσης την σχέση (4.3) [66]:

$$x_{i, \text{scaled}} = \frac{x_i - \mu}{\sigma} \quad (4.3)$$

όπου $x_{i, \text{scaled}}$ η κανονικοποιημένη τιμή του δείγματος x_i , και μ , σ ο μέσος όρος και η τυπική απόκλιση της εκάστοτε μεταβλητής στην οποία ανήκει το δείγμα.

4.2 ΕΠΕΞΕΡΓΑΣΙΑ ΦΩΤΟΒΟΛΤΑΪΚΩΝ ΔΕΔΟΜΕΝΩΝ

Τα δεδομένα που αξιοποιήθηκαν για την πρόβλεψη της Φ/Β παραγωγής αφορούν ένα Φ/Β πάρκο. Περιλαμβάνουν μετρήσεις για 6 κατηγορίες μεταβλητών:

- για την ζενιθιακή γωνία του ήλιου μετρημένη σε μοίρες (°)

- για την ένταση της προσπίπτουσας ηλιακής ακτινοβολίας σε ένα σημείο του Φ/Β πάρκου (W/m^2)
- για την ένταση της προσπίπτουσας ηλιακής ακτινοβολίας σε ένα δεύτερο σημείο του Φ/Β πάρκου (W/m^2)
- για την θερμοκρασία λειτουργίας των Φ/Β πλαισίων σε ένα σημείο ($^{\circ}\text{C}$)
- για την θερμοκρασία λειτουργίας των Φ/Β πλαισίων σε ένα εναλλακτικό σημείο ($^{\circ}\text{C}$)
- για την παραγόμενη ενεργό ισχύ (kW)

4.2.1 Προέλευση και ανάλυση των δεδομένων φωτοβολταϊκής παραγωγής

Τα διαθέσιμα Φ/Β δεδομένα προέρχονται από ένα Φ/Β πάρκο στην Βοιωτία με συνολική εγκατεστημένη ισχύ 1200 kW . Οι μετρήσεις έχουν συγκεντρωθεί στο χρονικό διάστημα από τις 16/11/2023 και ώρα 13:12 μ.μ. έως τις 29/11/2023 και ώρα 07:17 π.μ., με χρονική ανάλυση ενός λεπτού. Πιο συγκεκριμένα, το αρχείο με τα δεδομένα εισόδου είναι σε μορφή φύλλου εργασίας Microsoft Excel (.xlsx), το οποίο περιέχει επτά στήλες:

- Στήλη A: Περιλαμβάνει την ημερομηνία και ώρα για κάθε μέτρηση
- Στήλη B: Περιλαμβάνει μετρήσεις για την ζενιθιακή γωνία του ήλιου
- Στήλη C: Περιέχει τις τιμές για την ένταση της προσπίπτουσας ηλιακής ακτινοβολίας σε ένα σημείο του Φ/Β πάρκου
- Στήλη D: Καταγράφονται οι θερμοκρασίες λειτουργίας των Φ/Β πλαισίων σε ένα συγκεκριμένο σημείο
- Στήλη E: Περιλαμβάνει τις θερμοκρασίες λειτουργίας των Φ/Β πλαισίων σε ένα διαφορετικό σημείο
- Στήλη F: Περιέχει τις τιμές για την ένταση της προσπίπτουσας ηλιακής ακτινοβολίας σε ένα δεύτερο σημείο του Φ/Β πάρκου
- Στήλη G: Καταγράφονται οι τιμές της ενεργού ισχύος εξόδου

Το συνολικό πλήθος δεδομένων για κάθε κατηγορία μεταβλητής είναι 5783 δείγματα. Όπως και στα αιολικά δεδομένα, για την διασφάλιση της αξιοπιστίας και της ακρίβειας των παραγόμενων προβλέψεων, πραγματοποιήθηκε έλεγχος για κενές ή ελλιπείς τιμές και διαπιστώθηκε ότι δεν υπάρχουν τέτοιου είδους καταγραφές στο συγκεκριμένο αρχείο.

Πριν την χρήση των εν λόγω μετρήσεων ως δεδομένα εισόδου στα μοντέλα πρόβλεψης, έγινε στατιστική ανάλυση αυτών, με ανάλογο τρόπο με τα αιολικά δεδομένα, υλοποιώντας, δηλαδή, ένα ιστόγραμμα και ένα θηκόγραμμα για τα συμβάντα απότομης μεταβολής. Μία ιδιαιτερότητα των Φ/Β δεδομένων σε σχέση με τα αντίστοιχα αιολικά, είναι ότι διαθέτουν χρονική ανάλυση ενός λεπτού, αλλά ως επιθυμητός χρονικός ορίζοντας πρόβλεψης παραμένουν τα δέκα λεπτά. Επομένως, λαμβάνοντας υπόψη το άρθρο *Ramp Rate Metric Suitable for Solar Forecasting* των Nouri et al. [5], σε περιπτώσεις που η χρονική ανάλυση είναι μικρότερη από τον χρονικό ορίζοντα πρόβλεψης, ένα ORE καθορίζεται από την σχέση (4.4):

$$ORE_{t, FH} = \max_{j \in \{-\Delta t + res, -\Delta t + 2res, \dots, \Delta T\}} \left| \left\{ \frac{y(t + FH + j) - y(t + FH + j - res)}{res} \right\} \right| > \varepsilon \quad (4.4)$$


ενώ ένα PRE καθορίζεται από την σχέση (4.5):

$$PRE_{t,FH} = \max_{j \in \{-\Delta t + res, -\Delta t + 2res, \dots, \Delta t\}} \left| \frac{\hat{y}(t + FH + j) - \hat{y}(t + FH + j - res)}{res} \right| > \varepsilon \quad (4.5)$$


όπου FH ο ορίζοντας πρόβλεψης, Δt το χρονικό παράθυρο ανοχής γύρω από την χρονική στιγμή $t + FH$, res (resolution – res) η χρονική ανάλυση των δεδομένων και ε το κατώφλι της κρίσιμης απότομης μεταβολής. Με y συμβολίζεται η πραγματική τιμή της ενεργού ισχύος εξόδου του Φ/Β πάρκου, ενώ με $\hat{y}$ συμβολίζεται η τιμή της πρόβλεψης. Για την συγκεκριμένη διπλωματική εργασία επιλέχθηκε: $FH = 10 \text{ min}$, $\Delta t = 5 \text{ min}$, $res = 1 \text{ min}$ και $\varepsilon = 120 \text{ kW}$ (ίσο με το 10% της ονομαστικής ισχύος). Δηλαδή, για τον επιλεγμένο ορίζοντα πρόβλεψης, για το παράθυρο ανοχής και για την χρονική στιγμή t , οι δύο τύποι «ψάχνουν» μέσα στο διάστημα από $t + 5 \text{ min}$ έως $t + 15 \text{ min}$ την μέγιστη απόλυτη διαφορά ισχύος μεταξύ δύο διαδοχικών παρατηρήσεων (χρονικής ανάλυσης ενός λεπτού). Αν αυτή η τιμή υπερβαίνει το κρίσιμο κατώφλι ε , τότε το συμβάν καταγράφεται ή προβλέπεται σαν συμβάν απότομης μεταβολής. Η απόλυτη τιμή υπάρχει, διότι ουσιαστική σημασία έχει το μέγεθος της μεταβολής και όχι το είδος της (αύξηση ή μείωση).

Με βάση την σχέση (4.4), υλοποιήθηκε το ιστόγραμμα του Σχήματος 4.3, όπου ο οριζόντιος άξονας αντιπροσωπεύει το ποσοστό του μεγέθους των συμβάντων απότομων μεταβολών ως προς την ονομαστική ισχύ του Φ/Β πάρκου, ενώ ο κατακόρυφος άξονας δείχνει το πλήθος των παρατηρήσεων. Σε αναλογία με το ιστόγραμμα του Σχήματος 4.1 για τα αιολικά δεδομένα, οι στήλες με κόκκινο χρώμα υποδηλώνουν τα κρίσιμα συμβάντα απότομης μεταβολής, δηλαδή τα ORE, ενώ το κατώφλι ε συμβολίζεται με διακεκομμένη κατακόρυφη μαύρη γραμμή. Επίσης, στο Σχήμα 4.3 αναγράφεται το ποσοστό των ORE ως προς το σύνολο των Φ/Β δεδομένων που αναλύθηκαν και είναι ίσο με 26.5%, τιμή η οποία αντιστοιχεί σε 1531 συμβάντα απότομης μεταβολής που έχουν υπερβεί το κατώφλι ε , και είναι μεγαλύτερη από την τιμή του αντίστοιχου ποσοστού για τα δεδομένα της Α/Γ. Το γεγονός αυτό είναι αναμενόμενο, καθώς, όπως αναφέρθηκε και στην Ενότητα 2.7, όσο υψηλότερη χρονική ανάλυση διαθέτουν τα δεδομένα προς επεξεργασία, τόσο πιο λεπτομερώς και συχνά θα καταγράφονται τα συμβάντα απότομης μεταβολής. Το ιστόγραμμα του Σχήματος 4.3 είναι συμμετρικό γύρω από το μηδέν, ωστόσο η μορφή του αποκλίνει από την μορφή της κανονικής κατανομής και μοιάζει περισσότερο με κατανομή με βαριές ουρές (heavy-tailed distribution), καθώς καταγράφονται σχετικά συχνά συμβάντα απότομης μεταβολής μεγάλης έντασης — είτε πρόκειται για αυξήσεις είτε για μειώσεις στην ισχύ — που εμφανίζονται πολύ συχνότερα από ό,τι θα έδειχνε μια κανονική κατανομή. Το γεγονός ότι τα ORE αποτελούν σχεδόν το 30% των συνολικών απότομων μεταβολών είναι κρίσιμο, καθώς υποδεικνύει ότι τα κρίσιμα συμβάντα απότομης μεταβολής δεν είναι ακραία φαινόμενα που καταγράφονται σπάνια, αλλά αντίθετα καταγράφονται αρκετά συχνά.

Εκτός από το ιστόγραμμα, κατασκευάστηκε και το θηκόγραμμα του Σχήματος 4.4, το οποίο παρέχει στοιχεία για την κατανομή των συμβάντων απότομης μεταβολής για πέντε διαστήματα τιμών της ζενιθιακής γωνίας του ήλιου ($55^\circ\text{--}60^\circ$, $60^\circ\text{--}65^\circ$, $65^\circ\text{--}70^\circ$, $70^\circ\text{--}75^\circ$, $75^\circ\text{--}80^\circ$) και υλοποιήθηκε όμοια με το Σχήμα 4.2 που αντιστοιχεί στα αιολικά δεδομένα.



Σχήμα 4.3: Συχνότητα εμφάνισης συμβάντων απότομων μεταβολών στην Φ/Β παραγωγή



Σχήμα 4.4: Θηκόγραμμα των συμβάντων απότομων μεταβολών στην Φ/Β παραγωγή για διαφορετικά εύρη ζενιθιακής γωνίας του ήλιου

Η γενική παρατήρηση που προκύπτει από το Σχήμα 4.4 είναι ότι για μικρές ζενιθιακές γωνίες, δηλαδή όταν ο ήλιος βρίσκεται ψηλά, η ένταση και η μεταβλητότητα των απότομων μεταβολών ισχύος είναι αυξημένη. Για παράδειγμα, για το εύρος 55° – 60° το ύψος της θήκης και ο μέσος όρος φαίνεται ότι είναι τα υψηλότερα, ενώ μεγάλο ποσοστό των συμβάντων απότομης μεταβολής ξεπερνάει την διακεκομμένη γραμμή που αντιπροσωπεύει το κρίσιμο κατώφλι ε . Αντίθετα, όσο αυξάνεται το εύρος ζενιθιακών γωνιών, δηλαδή όσο χαμηλώνει η θέση του ήλιου, τόσο το ύψος της θήκης όσο και ο μέσος όρος μειώνονται, γεγονός που σημαίνει ότι τα συμβάντα απότομης μεταβολής γίνονται πιο ήπια και λιγότερο διασκορπισμένα, και ελάχιστο ποσοστό αυτών υπερβαίνει το κατώφλι ε , μειώνεται δηλαδή το πλήθος των ORE. Το γεγονός αυτό σχετίζεται με την τυπική ημερήσια καμπύλη Φ/Β ισχύος, η οποία έχει καμπανοειδή μορφή, και σύμφωνα με αυτή, υπό συνθήκες καθαρού ουρανού, κατά τις μεσημβρινές ώρες η Φ/Β παραγωγή είναι αρκετά υψηλή. Επομένως, σε περίπτωση εμφάνισης νεφών εκείνες τις ώρες, τα περιθώρια έντασης των συμβάντων απότομης μεταβολής είναι αυξημένα.

4.2.2 Προεπεξεργασία των φωτοβολταϊκών δεδομένων

Όπως και στα δεδομένα αιολικής παραγωγής, έτσι και τα Φ/Β δεδομένα υπέστησαν διαδικασίες ελέγχου και προεπεξεργασίας, ώστε τα μοντέλα πρόβλεψης να παράγουν ακριβείς προβλέψεις με σωστό και αξιόπιστο τρόπο. Η πρώτη και βασική διαδικασία επεξεργασίας ήταν η διερεύνηση για την ύπαρξη κενών ή ελλিপών τιμών στο αρχείο με τις μετρήσεις, όπως αναφέρεται και στην Ενότητα 4.2.1.

Πριν τα Φ/Β δεδομένα χρησιμοποιηθούν ως είσοδοι στο στατιστικό μοντέλο Persistence, πραγματοποιήθηκε διαχωρισμός αυτών σε δύο σύνολα, ένα σύνολο ιστορικών δεδομένων για την παραγωγή των προβλέψεων, και ένα σύνολο για την δοκιμή και την αξιολόγηση της επίδοσης του μοντέλου. Τα ποσοστά διαχωρισμού που επιλέχτηκαν είναι ίσα με αυτά για τα αιολικά δεδομένα, δηλαδή 75% και 25% αντίστοιχα.

Όσον αφορά στην προετοιμασία των Φ/Β δεδομένων για την κατάλληλη εκπαίδευση του MLP, ακολουθήθηκαν τα ίδια βήματα με την αντίστοιχη προεπεξεργασία των αιολικών δεδομένων. Δηλαδή, οι διαθέσιμες μετρήσεις κατανεμήθηκαν σε τρία σύνολα: στο σύνολο εκπαίδευσης, στο σύνολο επικύρωσης και στο σύνολο τελικής αξιολόγησης, με ποσοστά 50%, 25% και 25% αντίστοιχα. Επίσης, η κανονικοποίηση των δεδομένων πραγματοποιήθηκε, και σε αυτήν την περίπτωση, με χρήση της συνάρτησης *StandardScaler* της βιβλιοθήκης *scikit-learn*, η οποία εφαρμόζει τον τύπο (4.3) για τον μετασχηματισμό των τιμών.

4.3 ΜΕΤΡΗΤΙΚΑ ΣΦΑΛΜΑΤΟΣ

Στην παρούσα διπλωματική εργασία, για την ποσοτικοποίηση της επίδοσης και της ακρίβειας των μοντέλων πρόβλεψης για την αιολική και Φ/Β παραγωγή, αξιοποιήθηκαν τα παρακάτω μετρητικά σφάλματος και δείκτες:

- **Μέσο απόλυτο σφάλμα (Mean Absolute Error – MAE):** Το MAE είναι ένα από τα πιο συχνά χρησιμοποιούμενα μετρητικά αξιολόγησης της επίδοσης μοντέλων παλινδρόμησης [32] και υπολογίζεται από την σχέση (4.6):

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (4.6)$$

όπου N το πλήθος των δειγμάτων, y_i ανήκει στο σύνολο των δεδομένων δοκιμής και τελικής αξιολόγησης και είναι η πραγματική τιμή για το δείγμα i , και $\hat{y}_i$ είναι η τιμή της πρόβλεψης. Οι ιδιότητες του MAE περιγράφονται στην Ενότητα 3.4.1. Όσο πιο χαμηλή είναι η τιμή του MAE, τόσο πιο χαμηλό είναι και το μέσο μέγεθος των σφαλμάτων των προβλέψεων [32].

- **Ρίζα του μέσου τετραγωνικού σφάλματος (Root Mean Squared Error – RMSE):** Το RMSE αποτελεί ένα από τα πιο διαδεδομένα μετρητικά σφάλματος σε προβλήματα παλινδρόμησης και πρόβλεψης χρονοσειρών. Ορίζεται ως η τετραγωνική ρίζα του MSE, πληροφορίες για το οποίο υπάρχουν στην Ενότητα 3.4.2, και υπολογίζεται από την σχέση (4.7):

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (4.7)$$

όπου N το πλήθος των δειγμάτων, y_i η πραγματική τιμή του δείγματος i του συνόλου δεδομένων δοκιμής και τελικής αξιολόγησης και $\hat{y}_i$ η τιμή της πρόβλεψης για το δείγμα i . Ένας από τους λόγους που το RMSE επιλέγεται για την αξιολόγηση της επίδοσης ενός μοντέλου, έναντι του MSE, είναι ότι, λόγω της τετραγωνικής ρίζας, εκφράζεται στις ίδιες μονάδες μέτρησης με την υπό εξέταση μεταβλητή, είναι δηλαδή ευκολότερα ερμηνεύσιμο. Χαμηλές τιμές του RMSE υποδεικνύουν ότι το μοντέλο παράγει προβλέψεις με αρκετά ικανοποιητική ακρίβεια.

- **Μεροληψία (Bias):** Ονομάζεται συχνά και μέσο σφάλμα μεροληψίας (Mean Bias Error – MBE) και μετρά το μέσο προσανατολισμένο σφάλμα ενός μοντέλου. Υπολογίζεται ως ο μέσος όρος των διαφορών μεταξύ των προβλέψεων και των πραγματικών τιμών, σύμφωνα με την σχέση (4.8) [67]:

$$\text{MBE} = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i) \quad (4.8)$$

όπου N το πλήθος των δειγμάτων, y_i η πραγματική τιμή του δείγματος i του συνόλου δεδομένων δοκιμής και τελικής αξιολόγησης, και $\hat{y}_i$ η τιμή της πρόβλεψης για το δείγμα i . Θετική τιμή του MBE δείχνει συστηματική υπερεκτίμηση από το μοντέλο, ενώ αρνητική τιμή υποδηλώνει συστηματική υποεκτίμηση [67]. Επομένως, το MBE χρησιμοποιείται ως μέτρο της κατεύθυνσης του μέσου σφάλματος και είναι χρήσιμο για την ανίχνευση και την διόρθωση συστηματικών αποκλίσεων. Ωστόσο, επειδή δεν αποτυπώνει την ένταση ή την διασπορά των σφαλμάτων, δηλαδή δεν μπορεί να αντικαταστήσει μετρητικά σφάλματος όπως το MAE και το RMSE, συνίσταται να

χρησιμοποιείται σε συνδυασμό με αυτά, ώστε η αξιολόγηση της επίδοσης ενός μοντέλου να είναι πλήρης.

- **Δείκτης Skill Score:** Ο δείκτης Skill Score είναι ένας μετρητικός δείκτης που συγκρίνει την επίδοση ενός συγκεκριμένου μοντέλου πρόβλεψης σε σχέση με ένα απλό μοντέλο αναφοράς και υπολογίζεται με βάση την σχέση (4.9) [5]:

$$SkillScore = 1 - \frac{S_{model}}{S_{benchmark}} \quad (4.9)$$

όπου S_{model} κάποιο μετρητικό σφάλματος του υπό εξέταση μοντέλου πρόβλεψης (π.χ. MAE) και $S_{benchmark}$ το αντίστοιχο μετρητικό σφάλματος του μοντέλου αναφοράς. Θετική τιμή του Skill Score σημαίνει ότι η επίδοση του μοντέλου πρόβλεψης είναι βελτιωμένη συγκριτικά με το μοντέλο αναφοράς, ενώ αρνητική τιμή σημαίνει ότι το υπό εξέταση μοντέλο έχει χειρότερη επίδοση από το μοντέλο αναφοράς [5]. Πρέπει να σημειωθεί ότι ο τύπος (4.9) εφαρμόζεται, όταν επιδιώκεται όσο το δυνατόν χαμηλότερη τιμή στα μετρητικά σφάλματος. Στην αντίθετη περίπτωση, ο δείκτης Skill Score υπολογίζεται από την σχέση (4.10):

$$SkillScore = \frac{S_{model}}{S_{benchmark}} - 1 \quad (4.10)$$

Στην παρούσα διπλωματική εργασία, ως μοντέλο αναφοράς επιλέχθηκε το μοντέλο Persistence, καθώς χρησιμοποιείται ευρέως με αυτή την ιδιότητα σε προβλήματα πρόβλεψης [68].

- **Δείκτης F1:** Ο δείκτης F1 σχετίζεται με την ικανότητα ενός μοντέλου να προβλέπει συμβάντα απότομης μεταβολής και αποτελεί έναν δείκτη ισορροπίας ανάμεσα στην ακρίβεια και στην ανάκληση. Υπολογίζεται από την σχέση (4.11):

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (4.11)$$

όπου *Precision* η ακρίβεια του μοντέλου και *Recall* η ανάκληση του μοντέλου. Το συγκεκριμένο μετρητικό σφάλματος χρησιμοποιείται στην παρούσα διπλωματική εργασία, διότι κύριος σκοπός αυτής είναι η διερεύνηση της ικανότητας των στατιστικών μοντέλων και του MLP να ανιχνεύουν κρίσιμα συμβάντα απότομης μεταβολής στην αιολική και Φ/Β παραγωγή. Περισσότερες πληροφορίες για τις ιδιότητες του δείκτη F1 υπάρχουν στην Ενότητα 3.4.5.

4.4 ΠΕΡΙΓΡΑΦΗ ΜΕΘΟΔΟΛΟΓΙΑΣ ΤΩΝ ΜΟΝΤΕΛΩΝ ΠΡΟΒΛΕΨΗΣ ΑΙΟΛΙΚΗΣ ΠΑΡΑΓΩΓΗΣ

Τις διαδικασίες προεπεξεργασίας και ανάλυσης των αιολικών δεδομένων, οι οποίες περιγράφονται στην Ενότητα 4.1, ακολούθησε η κατασκευή των μοντέλων Persistence και

ARIMA, καθώς και η δοκιμή των πέντε αντικειμενικών συναρτήσεων της Ενότητας 3.4 για την εκπαίδευση του MLP. Η υλοποίηση όλων των μοντέλων πραγματοποιήθηκε με χρήση της προγραμματιστικής γλώσσας Python μέσω του Jupyter Notebook, το οποίο είναι ένα διαδραστικό περιβάλλον εργασίας που επιτρέπει την συγγραφή και την εκτέλεση κώδικα, υποστηρίζοντας μεγάλο αριθμό βιβλιοθηκών και εργαλείων. Η εκτέλεση του κώδικα έγινε σε φορητή υπολογιστική συσκευή, η οποία διαθέτει επεξεργαστή AMD Ryzen 7-3750H με Radeon Vega Mobile Gfx και έχει εγκατεστημένη RAM μεγέθους 32 GB.

Όσον αφορά στο μοντέλο Persistence, οι βιβλιοθήκες που αξιοποιήθηκαν είναι οι εξής:

- η βιβλιοθήκη *pandas*, η οποία είναι βιβλιοθήκη της Python για χειρισμό και ανάλυση δομημένων δεδομένων και περιέχει τύπους και συναρτήσεις που διευκολύνουν τον καθαρισμό, την ομαδοποίηση και την επεξεργασία χρονοσειρών [69],
- η βιβλιοθήκη *numpy* η οποία είναι η βασική βιβλιοθήκη της Python για αριθμητικούς υπολογισμούς και πράξεις [70],
- το υποπακέτο *pyplot* της βιβλιοθήκης *matplotlib* [71], η οποία είναι η ιδιαίτερα χρήσιμη για την δημιουργία γραφικών παραστάσεων,
- και το υποπακέτο *sklearn.metrics* της βιβλιοθήκης *scikit-learn* που παρέχει συναρτήσεις αξιολόγησης μοντέλων [72].

Για το μοντέλο ARIMA, εκτός από τις προαναφερθείσες βιβλιοθήκες, χρησιμοποιήθηκε η *pmdarima* [73] και η *statsmodels.tsa.arima.model* [74]. Όπως αναφέρεται και στην Ενότητα 2.5.1.1, οι παράμετροι (p, d, q) χαρακτηρίζουν ένα μοντέλο ARIMA και εξαρτώνται από την φύση και τα χαρακτηριστικά των δεδομένων, επομένως η κατάλληλη επιλογή αυτών είναι κρίσιμη για την επίδοση του μοντέλου. Στην παρούσα διπλωματική εργασία, η εκτίμηση των βέλτιστων τιμών των παραμέτρων (p, d, q) έγινε με αυτόματη επιλογή μέσω της συνάρτησης *auto-arima* της *pmdarima*, και προέκυψαν ίσοι με (2, 1, 2). Στην συνέχεια, μέσω της ARIMA της *statsmodels.tsa.arima.model*, υλοποιείται το μοντέλο ARIMA με τις παραμέτρους (2, 1, 2) που βρήκε η *auto-arima*, το οποίο χρησιμοποιεί το 75% των αιολικών δεδομένων ως ιστορικό παρατηρήσεων. Η διαδικασία παραγωγής και αποθήκευσης των προβλέψεων γίνεται σε τόσες επαναλήψεις όσες ο αριθμός των δεδομένων αξιολόγησης (25% του συνόλου).

Στην συνέχεια, πραγματοποιήθηκε η υλοποίηση του MLP. Για τα αιολικά δεδομένα, το συγκεκριμένο μοντέλο FFNN διαθέτει ένα κρυφό στρώμα και 16 νευρώνες, χρησιμοποιεί ως συνάρτηση ενεργοποίησης του κρυφού στρώματος την ReLU, ενώ στο στρώμα εξόδου εφαρμόζεται η γραμμική συνάρτηση ενεργοποίησης, διότι τα δεδομένα εξόδου δεν κανονικοποιήθηκαν και δεν ήταν επιθυμητός ο περιορισμός των αιολικών προβλέψεων σε συγκεκριμένο διάστημα τιμών. Ως αλγόριθμος βελτιστοποίησης χρησιμοποιείται ο αλγόριθμος PSO. Οι παράμετροι του αλγόριθμου έχουν επιλεγεί, με βάση την διπλωματική εργασία της Ε. Γκίκα με τίτλο *Σύγκριση Μεθόδων Πρόβλεψης Παραγωγής από Ανανεώσιμες Πηγές Ενέργειας*, ως εξής: ο αριθμός σωματιδίων ίσος με 40, $c_1 = 0.5$, $c_2 = 0.5$, $w_{min} = 0.1$ και $w_{max} = 0.9$ [32].

Κατόπιν κατασκευής του μοντέλου MLP, έγινε η δοκιμή του, δηλαδή εκτέλεση του κώδικα, πέντε φορές. Σε κάθε μία από τις πέντε επαναλήψεις δοκιμής του MLP, εφαρμόστηκε μία από τις πέντε αντικειμενικές συναρτήσεις της Ενότητας 3.4 για την εκπαίδευσή του, και αφού παρήχθησαν οι προβλέψεις, υπολογίστηκαν τα MAE, RMSE, MBE, Skill Score και F1. Να σημειωθεί ότι ο υπολογισμός του Skill Score για τα μετρητικά σφάλματος MAE και RMSE έγινε με βάση τη σχέση (4.9), ενώ για το F1 έγινε λαμβάνοντας υπόψη τη σχέση (4.10). Στην

συνέχεια, μετά την ολοκλήρωση των πέντε επαναλήψεων, συγκρίθηκε η επίδραση που είχε κάθε αντικειμενική συνάρτηση στην επίδοση και στην αξιοπιστία του μοντέλου, ειδικά όσον αφορά στην ικανότητα πρόβλεψης απότομων μεταβολών στην παραγωγή, δίνοντας βαρύτητα στο μετρητικό F1.

Πίνακας 4.1: Χαρακτηριστικά και τιμές παραμέτρων του MLP-PSO για την πρόβλεψη αιολικής και Φ/Β ισχύος

Χαρακτηριστικό MLP	Πρόβλεψη Αιολικής Παραγωγής	Πρόβλεψη Φ/Β Παραγωγής
Συνάρτηση ενεργοποίησης κρυφού στρώματος	ReLU	ReLU
Συνάρτηση ενεργοποίησης στρώματος εξόδου	Γραμμική	Γραμμική
Νευρώνες κρυφού στρώματος	16	16
Αριθμός σωματιδίων (PSO)	40	120
c_1	0.5	2.0
c_2	0.5	2.0
w_{min}	0.1	0.4
w_{max}	0.9	0.9

4.5 ΠΕΡΙΓΡΑΦΗ ΜΕΘΟΔΟΛΟΓΙΑΣ ΤΩΝ ΜΟΝΤΕΛΩΝ ΠΡΟΒΛΕΨΗΣ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

Τα μοντέλα πρόβλεψης για την Φ/Β παραγωγή, δηλαδή το μοντέλο Persistence και ο MLP, υλοποιήθηκαν με χρήση της γλώσσας Python στο περιβάλλον εργασίας Jupyter Notebook, όπως έγινε και για την αιολική παραγωγή. Η συγγραφή του κώδικα έγινε σε φορητή υπολογιστική συσκευή, η οποία διαθέτει επεξεργαστή AMD Ryzen 7-3750H με Radeon Vega Mobile Gfx και έχει εγκατεστημένη RAM μεγέθους 32 GB.

Το μοντέλο Persistence κατασκευάστηκε με την ίδια απλή λογική που εφαρμόστηκε και στα αιολικά δεδομένα, αξιοποιώντας τις βιβλιοθήκες *pandas* [69], *numpy* [70], *matplotlib* [71] και το υποπακέτο *sklearn.metrics* [72]. Η βασική ιδιαιτερότητα είναι ότι τα Φ/Β δεδομένα έχουν χρονική ανάλυση ενός λεπτού, ενώ ο χρονικός ορίζοντας πρόβλεψης είναι τα δέκα λεπτά. Οπότε, το μοντέλο Persistence στην συγκεκριμένη περίπτωση εκφράζει ότι για κάθε χρονική στιγμή t για την οποία παράγονται οι προβλέψεις θα ισχύει η σχέση (4.12):

$$\hat{y}(t + i') = y(t), \text{ για } i \in [1, 10] \quad (4.12)$$

όπου i το χρονικό βήμα του ορίζοντα πρόβλεψης, $\hat{y}(t + i')$ η πρόβλεψη την χρονική στιγμή $t + i'$, και $y(t)$ η πραγματική τιμή της Φ/Β ισχύος την χρονική στιγμή t .

Όσον αφορά στον MLP, υλοποιήθηκε ο αντίστοιχος κώδικας για την πρόβλεψη Φ/Β παραγωγής. Ο συγκεκριμένος κώδικας είναι όμοιος με τον κώδικα για τα αιολικά δεδομένα, με την μόνη διαφοροποίηση να είναι οι τιμές των παραμέτρων του αλγόριθμου PSO, για τις οποίες ισχύει: ο αριθμός σωματιδίων ίσος με 120, $c_1 = 2.0$, $c_2 = 2.0$, $w_{min} = 0.4$ και $w_{max} = 0.9$.

Οι τιμές των παραμέτρων αυτών πάρθηκαν, και σε αυτή την περίπτωση, από την διπλωματική εργασία της Ε. Γκίκα με τίτλο *Σύγκριση Μεθόδων Πρόβλεψης Παραγωγής από Ανανεώσιμες Πηγές Ενέργειας* [32]. Ως συνάρτηση ενεργοποίησης του στρώματος εξόδου επιλέχτηκε ξανά η γραμμική. Έπειτα, έγινε η δοκιμή των πέντε αντικειμενικών συναρτήσεων της Ενότητας 3.4 στην εκπαίδευση του MLP και υπολογίστηκαν τα MAE, RMSE, MBE, Skill Score και F1. Ο δείκτης Skill Score για τα μετρητικά σφάλματος MAE και RMSE υπολογίστηκε με βάση τη σχέση (4.9), ενώ για το F1 υπολογίστηκε λαμβάνοντας υπόψη τη σχέση (4.10). Ο δείκτης F1 υπολογίστηκε στο περιβάλλον του κώδικα χρησιμοποιώντας τις σχέσεις (3.11), (3.12), (3.13), (4.4) και (4.5). Στον Πίνακα 4.1 φαίνονται συνοπτικά οι τιμές των παραμέτρων και τα χαρακτηριστικά του MLP-PSO για την πρόβλεψη της αιολικής και της Φ/Β παραγωγής.


ΑΠΟΤΕΛΕΣΜΑΤΑ

5.1 ΑΠΟΤΕΛΕΣΜΑΤΑ ΠΡΟΒΛΕΨΕΩΝ ΑΙΟΛΙΚΗΣ ΠΑΡΑΓΩΓΗΣ


Στα Σχήματα 5.1 και 5.2 παρουσιάζονται τα αποτελέσματα για τις προβλέψεις της αιολικής παραγωγής από τα στατιστικά μοντέλα Persistence και ARIMA αντίστοιχα, όπου συγκρίνονται οι πραγματικές τιμές της ισχύος με τις προβλεπόμενες τιμές. Με την μπλε καμπύλη απεικονίζονται οι αληθινές τιμές παραγωγής, ενώ με την πορτοκαλί διακεκομμένη καμπύλη φαίνονται οι αντίστοιχες προβλέψεις. Τα εν λόγω διαγράμματα αντιπροσωπεύουν μόνο τα τελευταία 1000 δείγματα των δεδομένων, δηλαδή από τις 25/12/2018 και ώρα 1:10 π.μ. έως τις 31/12/2018 και ώρα 11:50 μ.μ., ώστε να υπάρχει πιο λεπτομερής οπτική απεικόνιση των χρονοσειρών. Στο συγκεκριμένο χρονικό διάστημα, φαίνεται ότι η πραγματική αιολική παραγωγή χαρακτηρίζεται από αρκετές έντονες αυξομειώσεις στην ισχύ, και πιο συγκεκριμένα τα συμβάντα απότομης μεταβολής που παρατηρήθηκαν (τα ORE) είναι 224 στο πλήθος, δηλαδή αποτελούν το 22,4% των δεδομένων υπό εξέταση. Μάλιστα, το μέγιστο ORE στο σύνολο των 104832 διαθέσιμων δειγμάτων είναι μεγέθους 2052,91kW και καταγράφηκε στις 29/12/2018 στο δεκάλεπτο μεταξύ 7:40 π.μ. και 7:50 π.μ., δηλαδή εντός του χρονικού διαστήματος που απεικονίζεται στα Σχήματα 5.1 και 5.2. Στα Σχήματα 5.3 και 5.4 παρουσιάζεται η πραγματική και η προβλεπόμενη αιολική ισχύς από τα μοντέλα Persistence και ARIMA, αντίστοιχα, συγκεκριμένα για τις 29/12/2018 από τις 00:00π.μ. έως τις 11:50 μ.μ. Παρατηρώντας τα Σχήματα 5.1, 5.2, 5.3 και 5.4, γίνεται αντιληπτό ότι οι προβλέψεις των στατιστικών μοντέλων, και ιδιαίτερα του Persistence ακολουθούν την μορφή και τις απότομες μεταβολές της χρονοσειράς της πραγματικής παραγωγής σε πολύ αξιοπρεπή βαθμό, γεγονός που υποδηλώνει ότι τα συγκεκριμένα μοντέλα παράγουν ακριβείς και αξιόπιστες υπερβραχυπρόθεσμες προβλέψεις.

Στα Σχήματα 5.5, 5.6, 5.7, 5.8, 5.9 παρουσιάζονται οι προβλέψεις για την αιολική ισχύ από το μοντέλο MLP χρησιμοποιώντας για την εκπαίδευσή του τις αντικειμενικές συναρτήσεις MAE, MSE, MAAPE, Log-cosh και F1 της Ενότητας 3.4, αντίστοιχα. Η μπλε καμπύλη αντιπροσωπεύει την πραγματική αιολική παραγωγή, ενώ με την κόκκινη διακεκομμένη καμπύλη απεικονίζονται οι προβλεπόμενες τιμές. Σε αναλογία με τα Σχήματα 5.1 και 5.2, στα διαγράμματα των Σχημάτων 5.5, 5.6, 5.7, 5.8, 5.9 φαίνονται μόνο τα τελευταία 1000 δείγματα των διαθέσιμων αιολικών δεδομένων. Παρατηρώντας το Σχήμα 5.5, φαίνεται ότι το μοντέλο MLP με το MAE ως αντικειμενική συνάρτηση (MLP – MAE) έχει την δυνατότητα να συμβαδίζει με την πραγματική αιολική παραγωγή, ως επί το πλείστον σε ικανοποιητικό βαθμό, εκτός από ορισμένα σημεία που υπάρχουν απότομες και μεγάλες σε μέγεθος αυξομειώσεις στην ισχύ, όπως είναι για παράδειγμα το σημείο που υποδεικνύεται με κόκκινο βέλος. Στο Σχήμα 5.6 που αντιστοιχεί στο μοντέλο MLP με το MSE ως αντικειμενική συνάρτηση (MLP – MSE), φαίνεται ότι υπάρχει παρόμοια συμπεριφορά με το MLP – MAE. Βέβαια,


παρατηρώντας το Σχήμα 5.6 με προσοχή, διακρίνεται ότι το MLP – MSE παράγει ελαφρώς πιο συντηρητικές προβλέψεις και παρουσιάζει λίγο μεγαλύτερη δυσκολία στον εντοπισμό των έντονων συμβάντων απότομης μεταβολής, όπως φαίνεται στο σημείο που επισημαίνεται με κόκκινο βέλος που είναι το ίδιο σημείο με αυτό του Σχήματος 5.5. Στο Σχήμα 5.7 φαίνονται οι προβλέψεις για την αιολική παραγωγή όταν ο MLP εκπαιδεύεται με χρήση του MAAPE (MLP – MAAPE). Με εποπτική εξέταση του σχήματος φαίνεται ότι το μοντέλο δεν παράγει τόσο συντηρητικές προβλέψεις όσο το MLP – MSE, αλλά γενικότερα η συμπεριφορά του είναι σχεδόν όμοια με το μοντέλο MLP – MAE. Τα αποτελέσματα της χρήσης της log-cosh ως αντικειμενική συνάρτηση απεικονίζονται στο Σχήμα 5.8, όπου φαίνεται ότι το μοντέλο MLP – Logcosh παράγει σχετικά ακριβείς προβλέψεις και μπορεί να ακολουθήσει ελαφρώς καλύτερα τις έντονες απότομες μεταβολές σε σύγκριση με τα μοντέλα MLP – MAE, MLP – MSE και MLP – MAAPE, αλλά όχι και σε τόσο αισθητό βαθμό. Τέλος, παρατηρώντας το Σχήμα 5.9, όπου υπάρχουν τα αποτελέσματα του MLP με χρήση του δείκτη F1 ως αντικειμενική συνάρτηση, γίνεται εύκολα κατανοητό ότι οι παραγόμενες προβλέψεις δεν παρουσιάζουν τόσο μεγάλη ακρίβεια σε σύγκριση με τα προαναφερθέντα μοντέλα. Το γεγονός αυτό είναι αναμενόμενο, καθώς, όπως αναφέρεται και στην Ενότητα 3.4.5, ο δείκτης F1 δεν λαμβάνει υπόψη το μέσο απόλυτο ή σχετικό σφάλμα εξ ορισμού. Αντίθετα, επικεντρώνεται μόνο στην ικανότητα ανίχνευσης συμβάντων απότομης μεταβολής. Στο Σχήμα 5.9, λοιπόν, φαίνεται ότι όντως το μοντέλο έχει εντοπίσει τα μοτίβα αυξομειώσης της πραγματικής ισχύος πιο αποτελεσματικά σε σχέση με τα υπόλοιπα μοντέλα. Στα Σχήματα 5.10, 5.11, 5.12, 5.13 και 5.14 υπάρχουν τα αντίστοιχα διαγράμματα με τα Σχήματα 5.5, 5.6, 5.7, 5.8, 5.9, αλλά απεικονίζεται η πραγματική και η προβλεπόμενη αιολική παραγωγή μόνο για τις 29/12/2018 από τις 00:00π.μ. έως τις 11:50μ.μ.




Σχήμα 5.1: Πραγματική αιολική παραγωγή και αντίστοιχες προβλέψεις του μοντέλου Persistence για τα τελευταία 1000 δείγματα




Σχήμα 5.2: Πραγματική αιολική παραγωγή και αντίστοιχες προβλέψεις του μοντέλου ARIMA για τα τελευταία 1000 δείγματα




Σχήμα 5.3: Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου Persistence για τις 29/12/2018




Σχήμα 5.4: Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου ARIMA για τις 29/12/2018




Σχήμα 5.5: Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-MAE για τα τελευταία 1000 δείγματα




Σχήμα 5.6: Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-MSE για τα τελευταία 1000 δείγματα




Σχήμα 5.7: Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-MAAPE για τα τελευταία 1000 δείγματα




Σχήμα 5.8: Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-Logcosh για τα τελευταία 1000 δείγματα




Σχήμα 5.9: Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-F1 για τα τελευταία 1000 δείγματα




Σχήμα 5.10: Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-MAE για τις 29/12/2018




Σχήμα 5.11: Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-MSE για τις 29/12/2018



Σχήμα 5.12: Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-MAAPE για τις 29/12/2018



Σχήμα 5.13: Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-Logcosh για τις 29/12/2018




Σχήμα 5.14: Πραγματική και αντίστοιχη προβλεπόμενη αιολική παραγωγή του μοντέλου MLP-F1 για τις 29/12/2018

5.2 ΑΠΟΤΕΛΕΣΜΑΤΑ ΠΡΟΒΛΕΨΕΩΝ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

Όπως αναφέρεται και στην Ενότητα 4.2.1, τα Φ/Β δεδομένα έχουν χρονική ανάλυση ενός λεπτού, αλλά στην συγκεκριμένη εφαρμογή ο επιθυμητός χρονικός ορίζοντας πρόβλεψης είναι τα δέκα λεπτά. Στα σχήματα της παρούσας ενότητας απεικονίζονται οι πραγματικές τιμές της Φ/Β ισχύος για την χρονική στιγμή $t + 10'$, οι οποίες είναι οι ίδιες με αυτές της χρονικής στιγμής t , και οι αντίστοιχες προβλέψεις για την χρονική στιγμή $t + 10'$. Ο λόγος που επιλέγεται η απεικόνιση των προβλέψεων μόνο για το συγκεκριμένο βήμα του χρονικού ορίζοντα πρόβλεψης είναι επειδή οι προβλέψεις σε εκείνη την χρονική στιγμή παρουσιάζουν την μεγαλύτερη αβεβαιότητα, καθώς όσο αυξάνεται η χρονική απόσταση μεταξύ της πρόβλεψης και της πραγματικής τιμής, τόσο πιο απαιτητική γίνεται η παραγωγή προβλέψεων με ακρίβεια. Βέβαια, η ποσοτική αξιολόγηση των προβλέψεων μέσω των μετρητικών σφάλματος πραγματοποιήθηκε καθολικά, για όλα τα βήματα του ορίζοντα πρόβλεψης, ώστε να υπάρξει σαφέστερη εικόνα της γενικότερης επίδοσης των μοντέλων πρόβλεψης. Τα αποτελέσματα αυτής της αξιολόγησης παρουσιάζονται στην Ενότητα 5.3.

Το Σχήμα 5.15 αντιπροσωπεύει την πραγματική Φ/Β ισχύ σε σύγκριση με την προβλεπόμενη από το στατιστικό μοντέλο Persistence, όπου η μπλε καμπύλη αντιστοιχεί στην πραγματική παραγωγή και η πορτοκαλί διακεκομμένη καμπύλη δείχνει τις αντίστοιχες προβλέψεις. Το Σχήμα 5.15 αντιπροσωπεύει μόνο τα 461 δείγματα που αντιστοιχούν στην ημερομηνία 28/11/2023 από την ώρα 06:29 π.μ. έως την ώρα 02:10 μ.μ., όπου στο συγκεκριμένο χρονικό διάστημα καταγράφηκαν 46 ORE, που αποτελούν περίπου το 10% των υπό εξέταση δειγμάτων. Επιπλέον, ο μέγιστος αριθμός διαδοχικών ORE στις 28/11/2023


ισούται με 25 και καταγράφηκαν από τις 01:04 μ.μ. έως τις 01:28 μ.μ. Παρατηρώντας το Σχήμα 5.15, γίνεται αντιληπτό ότι οι προβλέψεις του μοντέλου Persistence ακολουθούν την μορφή της χρονοσειράς των πραγματικών τιμών με αρκετά μεγάλη ακρίβεια. Βέβαια, διακρίνεται μία χρονική μετατόπιση στην καμπύλη των προβλέψεων σε σχέση με την καμπύλη των πραγματικών τιμών, γεγονός που σχετίζεται με την επιλογή ανάδειξης του τελευταίου βήματος του χρονικού ορίζοντα πρόβλεψης, σύμφωνα και με ό,τι περιγράφεται στην Ενότητα 4.5.




Σχήμα 5.15: Πραγματική και αντίστοιχη προβλεπόμενη Φ/Β παραγωγή του μοντέλου Persistence για τις 28/11/2023

Στα Σχήματα 5.16, 5.17, 5.18, 5.19 και 5.20 παρουσιάζονται τα αποτελέσματα των προβλέψεων για την Φ/Β ισχύ από το μοντέλο MLP χρησιμοποιώντας για την εκπαίδευσή του τις αντικειμενικές συναρτήσεις MAE, MSE, MAAPE, Log-cosh και F1 της Ενότητας 3.4, αντίστοιχα. Η μπλε καμπύλη αντιπροσωπεύει την πραγματική Φ/Β παραγωγή, ενώ με την κόκκινη διακεκομμένη καμπύλη απεικονίζονται οι αντίστοιχες προβλεπόμενες τιμές. Σε αναλογία με το Σχήμα 5.15, τα Σχήματα 5.16, 5.17, 5.18, 5.19 και 5.20 αντιπροσωπεύουν μόνο τα 461 δείγματα που αντιστοιχούν στην ημερομηνία 28/11/2023 από την ώρα 06:29 π.μ. έως την ώρα 02:10 μ.μ. Με εποπτική εξέταση του Σχήματος 5.16, φαίνεται ότι το μοντέλο MLP – MAE δεν παρουσιάζει ιδιαίτερα μεγάλη ακρίβεια στην παραγωγή των προβλέψεων, ενώ δείχνει ότι διαθέτει κάποια δυνατότητα πρόβλεψης των απότομων μεταβολών, αλλά όχι σε ικανοποιητικό βαθμό. Πιο συγκεκριμένα, στην χρονοσειρά της πραγματικής Φ/Β παραγωγής διακρίνονται τρεις απότομες μεταβολές (ακίδες – spikes), οι οποίες επισημαίνονται με κόκκινα βέλη, και φαίνεται ότι το MLP – MAE καθυστερεί να ανιχνεύσει τις πρώτες δύο, ενώ καταφέρνει να εντοπίσει την τρίτη έγκαιρα αλλά υποεκτιμά το μέγεθός της. Στο Σχήμα 5.17, το οποίο αντιστοιχεί στο μοντέλο MLP – MSE, γίνεται αντιληπτό ότι η καμπύλη των προβλέψεων του συγκεκριμένου μοντέλου είναι ικανότερη στην παρακολούθηση των απότομων μεταβολών της χρονοσειράς των πραγματικών τιμών ισχύος, σε σύγκριση με το μοντέλο MLP – MAE, καθώς ανιχνεύει και τα τρία spikes που επισημαίνονται με κόκκινα βέλη


χωρίς καθυστέρηση. Ωστόσο, διακρίνεται μια συστηματική υπερεκτίμηση της παραγωγής, η οποία υπάρχει και στα δύο πρώτα spikes, αλλά όχι στο τρίτο. Στο Σχήμα 5.18 που αντιστοιχεί στο μοντέλο MLP – MAAPE, γίνεται ξεκάθαρη η τάση που αυτό διαθέτει για υπερεκτίμηση, καθώς και η έλλειψη ακρίβειας στις παραγόμενες προβλέψεις. Επίσης, φαίνεται ότι μπορεί να ακολουθήσει κάποιες απότομες μεταβολές της πραγματικής παραγωγής, αλλά σε μη ικανοποιητικό βαθμό. Παρατηρώντας το Σχήμα 5.19, φαίνεται ότι το μοντέλο MLP – LOGCOSH παρουσιάζει περίπου όμοια συμπεριφορά με το μοντέλο MLP – MSE όσον αφορά στην ακρίβεια των προβλέψεων, και ίσως ελαφρώς καλύτερη, αλλά δεν είναι τόσο ικανό στην παρακολούθηση των μεταβολών της πραγματικής παραγωγής, όσο είναι το MLP – MSE. Τέλος, παρατηρώντας το Σχήμα 5.9, όπου υπάρχουν τα αποτελέσματα του MLP – F1, γίνεται εύκολα σαφές ότι οι παραγόμενες προβλέψεις παρουσιάζουν αρκετά μικρότερη ακρίβεια σε σύγκριση με τα προαναφερθέντα μοντέλα, με σαφή υποεκτίμηση της τελικής τιμής ισχύος. Όμως, φαίνεται ότι καταφέρνει να ακολουθήσει τις περιοχές των απότομων μεταβολών αρκετά ικανοποιητικά, καθώς ανιχνεύει σωστά την ένταση και των τριών έντονων spikes, απλώς ξεκινάει από χαμηλότερη τιμή παραγωγής. Όπως αναφέρεται και στην Ενότητα 5.1, η συμπεριφορά αυτή του συγκεκριμένου μοντέλου είναι αναμενόμενη, διότι ο δείκτης F1 σχετίζεται αποκλειστικά με την ικανότητα ανίχνευσης συμβάντων απότομης μεταβολής, χωρίς να λαμβάνει καθόλου υπόψη τα σφάλματα μεταξύ των προβλέψεων και των πραγματικών τιμών.




Σχήμα 5.16: Πραγματική και προβλεπόμενη Φ/Β παραγωγή του μοντέλου MLP - MAE για τις 28/11/2023




Σχήμα 5.17: Πραγματική και προβλεπόμενη Φ/Β παραγωγή του μοντέλου MLP - MSE για τις 28/11/2023



Σχήμα 5.18: Πραγματική και προβλεπόμενη Φ/Β παραγωγή του μοντέλου MLP - MAAPE για τις 28/11/2023



Σχήμα 5.19: Πραγματική και προβλεπόμενη Φ/Β παραγωγή του μοντέλου MLP - LOGCOSH για τις 28/11/2023



Σχήμα 5.20: Πραγματική και προβλεπόμενη Φ/Β παραγωγή του μοντέλου MLP – F1 για τις 28/11/2023

5.3 ΣΥΓΚΡΙΣΗ ΤΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ

Η ποσοτική αξιολόγηση της επίδοσης των μοντέλων πρόβλεψης αιολικής και Φ/Β παραγωγής έγινε με χρήση των πέντε μετρητικών σφάλματος της Ενότητας 4.3. Στον Πίνακα 5.1 παρουσιάζονται συγκεντρωτικά τα αποτελέσματα για τα MAE, RMSE και MBE διαιρεμένα με την ονομαστική ισχύ της Α/Γ (2050kW), και τα αποτελέσματα για τον δείκτη F1 (%), για όλα τα μοντέλα πρόβλεψης της αιολικής παραγωγής. Με έντονο πράσινο χρώμα υποδεικνύονται τα καλύτερα αποτελέσματα για κάθε μετρητικό σφάλματος.

Πίνακας 5.1: Αποτελέσματα για τα MAE, RMSE, MBE και F1 των μοντέλων πρόβλεψης αιολικής παραγωγής

	Persistence	ARIMA	MLP – MAE	MLP – MSE	MLP – MAAPE	MLP – LOGCOSH	MLP – F1
MAE (p.u.)	0.039	0.039	0.047	0.051	0.049	0.062	0.155
RMSE (p.u.)	0.065	0.064	0.07	0.073	0.07	0.089	0.248
MBE (p.u.)	0	0	0.004	0.004	0.001	0	0.117
F1 (%)	0	0.9	3.9	2.9	3.8	4.9	42.8

Όπως φαίνεται από τον Πίνακα 5.1, τα στατιστικά μοντέλα Persistence και ARIMA έχουν τιμή MAE ίση με 0.039 p.u., η οποία είναι η μικρότερη τιμή σε σύγκριση με τα υπόλοιπα μοντέλα, με το μοντέλο ARIMA να διαθέτει και την μικρότερη τιμή RMSE ίση με 0.064 p.u., γεγονός που επιβεβαιώνει ότι τα στατιστικά μοντέλα παρουσιάζουν αρκετά αξιόπιστη συμπεριφορά ως προς την μέση ακρίβεια των προβλέψεων, όταν πρόκειται για υπερβραχυπρόθεσμες προβλέψεις. Ωστόσο, γίνεται αντιληπτό ότι το μοντέλο ARIMA αδυνατεί να προβλέψει τα συμβάντα απότομης μεταβολής, καθώς η τιμή του δείκτη F1 είναι εξαιρετικά χαμηλή, κοντά στο 1%. Ο λόγος που ο δείκτης F1 για το μοντέλο Persistence είναι ίσος με μηδέν είναι ότι, όπως αναφέρεται στην Ενότητα 2.5.1.2, το συγκεκριμένο μοντέλο υποθέτει ότι η προβλεπόμενη τιμή της ισχύος την χρονική στιγμή $t + FH$ ισούται με την πραγματική τιμή της παραγωγής την χρονική στιγμή t . Οπότε, σύμφωνα με την σχέση (4.2), το μοντέλο Persistence δεν προβλέπει κανένα συμβάν απότομης μεταβολής. Όσον αφορά στο μοντέλο MLP, προκύπτει ότι η εκπαίδευση με την αντικειμενική συνάρτηση MAE οδηγεί στις ακριβέστερες προβλέψεις σε σύγκριση με τις αντικειμενικές συναρτήσεις MSE, MAAPE, LOGCOSH και F1, με τιμές MAE και RMSE ίσες με 0.047 p.u. και 0.070 p.u. Παρόμοια συμπεριφορά ως προς την ακρίβεια των προβλέψεων φαίνεται να έχει και το μοντέλο MLP – MAAPE με τιμές MAE και RMSE ίσες με 0.049 p.u. και 0.076 p.u., αντίστοιχα. Ωστόσο, και το μοντέλο MLP – MAE και το μοντέλο MLP – MAAPE έχουν αρκετά χαμηλό δείκτη F1, ο

οποίος είναι ίσος με 3.9% και 3.8%, αντίστοιχα. Το μοντέλο MLP – MSE παρουσιάζει χαμηλότερη ακρίβεια πρόβλεψης συγκριτικά με τα MLP – MAE και MLP – MAAPE και η τιμή του δείκτη F1 είναι χαμηλότερη και ίση με 2.9%. Το μοντέλο MLP – LOGCOSH παράγει προβλέψεις με μη ικανοποιητική ακρίβεια και διαθέτει και αυτό αρκετά χαμηλό δείκτη F1 με τιμή 4.9%, η οποία, όμως, είναι ελάχιστα βελτιωμένη σε σχέση με τα μοντέλα MLP – MAE , MLP – MSE και MLP – MAAPE. Το γεγονός ότι τα μοντέλα MLP – MAE , MLP – MSE, MLP – MAAPE και MLP – LOGCOSH παρουσιάζουν τόσο χαμηλή ικανότητα στην ανίχνευση συμβάντων απότομης μεταβολής στην αιολική παραγωγή, υποδεικνύει ότι οι συγκεκριμένες αντικειμενικές συναρτήσεις, οι οποίες στοχεύουν σχεδόν αποκλειστικά στην ελαχιστοποίηση του μέσου σφάλματος, παρουσιάζουν αδυναμία στον έγκαιρο εντοπισμό των συμβάντων απότομης μεταβολής. Το μοντέλο MLP – F1 είναι το πιο ικανό μοντέλο όσον αφορά στην ανίχνευση των συμβάντων απότομης μεταβολής, καθώς διαθέτει την μέγιστη τιμή του δείκτη F1, η οποία είναι ίση με 42.8%, σημαντικά μεγαλύτερη σε σχέση με όλα τα υπόλοιπα μοντέλα πρόβλεψης. Αυτό σημαίνει ότι η εκπαίδευση του MLP με χρήση του δείκτη F1 ως αντικειμενική συνάρτηση βελτιώνει κατά πολύ την ικανότητα ανίχνευσης απότομων μεταβολών στην αιολική παραγωγή. Πιο συγκεκριμένα, ο δείκτης F1 του μοντέλου MLP – F1 βελτιώθηκε κατά 773.5% σε σχέση με τον δείκτη του μοντέλου MLP – LOGCOSH, που είναι το αμέσως επόμενο καλύτερο μοντέλο, όσον αφορά στην ικανότητα ανίχνευσης απότομων μεταβολών! Ωστόσο, το MLP – F1 παρουσιάζει την χειρότερη συμπεριφορά ως προς την ακρίβεια των προβλέψεων, με τιμές MAE και RMSE ίσες με 0.155 p.u. και 0.248 p.u., αντίστοιχα, αποτέλεσμα που ήταν αναμενόμενο, καθώς ο δείκτης F1 δεν λαμβάνει καθόλου υπόψη το μέσο απόλυτο ή σχετικό σφάλμα. Όσον αφορά στο μετρητικό σφάλματος MBE, φαίνεται από τον Πίνακα 5.1 ότι κανένα από τα μοντέλα, εκτός του MLP – F1, δεν υποεκτιμά ή υπερεκτιμά συστηματικά την παραγωγή, καθώς οι τιμές είναι πολύ κοντά στο μηδέν.

Στον Πίνακα 5.2 υπάρχουν οι τιμές του Skill Score ως προς το MAE και το RMSE για κάθε μοντέλο πρόβλεψης, χρησιμοποιώντας ως μοντέλο αναφοράς το μοντέλο Persistence. Από τις τιμές του Πίνακα 5.2 και σύμφωνα με την Ενότητα 4.3, γίνεται αντιληπτό ότι μόνο το μοντέλο ARIMA ξεπερνάει ελαφρώς την επίδοση του μοντέλου Persistence, όσον αφορά στην ακρίβεια πρόβλεψης, βελτιώνοντας το MAE και το MSE κατά 0.1% και 1.7%, αντίστοιχα. Επίσης, το μοντέλο MLP – MAE είναι αυτό που πλησιάζει περισσότερο την ακρίβεια πρόβλεψης του μοντέλου αναφοράς.

Πίνακας 5.2: Skill Score για τα MAE και RMSE των μοντέλων πρόβλεψης αιολικής παραγωγής

	ARIMA	MLP – MAE	MLP – MSE	MLP – MAAPE	MLP – LOGCOSH	MLP – F1
Skill Score – MAE	0.001	–0.199	–0.316	–0.259	–0.590	–2.974
Skill Score – RMSE	0.017	–0.075	–0.123	–0.173	–0.369	–2.815

Επομένως, για την αιολική παραγωγή προκύπτει ότι αν οι προβλέψεις παράγονται με γνώμονα την μείωση του μέσου σφάλματος, θα μπορούσε να επιλεγεί το μοντέλο Persistence, καθώς έχει αρκετά ικανοποιητική επίδοση με μέσο απόλυτο σφάλμα μικρότερο από 4% και παραμένει το απλούστερο μοντέλο στην υλοποίηση και στην υπολογιστική πολυπλοκότητα. Βέβαια, αν ο βασικός στόχος είναι η πρόβλεψη συμβάντων απότομης μεταβολής, τότε το μόνο κατάλληλο μοντέλο πρόβλεψης είναι ο MLP με τον δείκτη F1 ως αντικειμενική συνάρτηση, καθώς είναι το μόνο μοντέλο με ικανοποιητική ικανότητα ανίχνευσης απότομων μεταβολών.

Στον Πίνακα 5.3 παρουσιάζονται τα συγκεντρωτικά αποτελέσματα για τα MAE, RMSE και MBE διαιρεμένα με την ονομαστική ισχύ του Φ/Β πάρκου (1200kW), και τα αποτελέσματα για τον δείκτη F1 (%), για όλα τα μοντέλα πρόβλεψης της Φ/Β παραγωγής. Με έντονο πράσινο χρώμα υποδεικνύονται τα καλύτερα αποτελέσματα για κάθε μετρητικό σφάλματος.

Πίνακας 5.3: Αποτελέσματα για τα MAE, RMSE, MBE και F1 των μοντέλων πρόβλεψης Φ/Β παραγωγής

	Persistence	MLP – MAE	MLP – MSE	MLP – MAAPE	MLP – LOGCOSH	MLP – F1
MAE (p.u.)	0.058	0.080	0.075	0.142	0.069	0.265
RMSE (p.u.)	0.122	0.116	0.109	0.184	0.105	0.349
MBE (p.u.)	0.001	-0.001	-0.017	0.104	-0.003	-0.232
F1 (%)	0	38.7	47.3	44.2	37.7	48.3

Από τα αποτελέσματα του Πίνακα 5.3 προκύπτει το συμπέρασμα ότι το μοντέλο Persistence επιτυγχάνει το μικρότερο μέσο απόλυτο σφάλμα, καθώς η τιμή του MAE, η οποία είναι ίση με 0.058 p.u., είναι η χαμηλότερη σε σχέση με όλα τα υπόλοιπα μοντέλα πρόβλεψης. Σε αναλογία με τα αποτελέσματα του Πίνακα 5.1 για την πρόβλεψη της αιολικής παραγωγής και σύμφωνα με ό,τι αναφέρεται στις Ενότητες 2.5.1.2 και 4.5, το μοντέλο Persistence αδυνατεί να ανιχνεύσει οποιαδήποτε απότομη μεταβολή, επομένως ο δείκτης F1 ισούται με 0. Επιπλέον, η αντικειμενική συνάρτηση LOGCOSH οδηγεί στις πιο ακριβείς προβλέψεις για το MLP, καθώς το συγκεκριμένο μοντέλο έχει την μικρότερη τιμή RMSE σε σύγκριση με τα άλλα μοντέλα, η οποία είναι ίση με 0.105 p.u. Επίσης, το MLP – LOGCOSH διαθέτει τιμή MAE ίση με 0.069 p.u., τιμή η οποία είναι αρκετά χαμηλή. Ωστόσο, το MLP – LOGCOSH έχει την χαμηλότερη τιμή όσον αφορά στον δείκτη F1 (37.7%), γεγονός που σημαίνει ότι παρουσιάζει την μεγαλύτερη δυσκολία στον εντοπισμό των συμβάντων απότομης μεταβολής. Τα παραπάνω αποτελούν ένδειξη ότι το συγκεκριμένο μοντέλο τείνει να λειτουργήσει όμοια με το μοντέλο Persistence, δηλαδή τείνει να μετατοπίσει χρονικά την καμπύλη της πραγματικής παραγωγής,

και επειδή ο χρονικός ορίζοντας πρόβλεψης των δέκα λεπτών είναι πολύ μικρός, τα μέσα σφάλματα πρόβλεψης τείνουν να μειωθούν, αλλά ταυτόχρονα ελαττώνεται και η ικανότητα ανίχνευσης συμβάντων απότομης μεταβολής. Το μοντέλο MLP – F1 διαθέτει τον υψηλότερο δείκτη F1, ίσο με 48.3%, έχει δηλαδή, την καλύτερη επίδοση συγκριτικά με τα υπόλοιπα μοντέλα, σε ότι αφορά την ικανότητα πρόβλεψης συμβάντων απότομης μεταβολής στην Φ/Β παραγωγή, αλλά η μέση ακρίβεια των προβλέψεων είναι η χαμηλότερη. Η συμπεριφορά της συγκεκριμένης αντικειμενικής συνάρτησης είναι αναμενόμενη, καθώς, εξ ορισμού, ο δείκτης F1 δεν σχετίζεται καθόλου με τα μέσα σφάλματα, αλλά αποκλειστικά με την ανίχνευση συμβάντων απότομης μεταβολής. Το μοντέλο που φαίνεται να ισορροπεί ανάμεσα στην ακρίβεια πρόβλεψης και στην δυνατότητα εντοπισμού απότομων μεταβολών στην Φ/Β παραγωγή είναι το MLP – MSE, διότι διαθέτει αρκετά ικανοποιητικές τιμές MAE (0.075 p.u.) και RMSE (0.109 p.u.) και ταυτόχρονα έχει υψηλό δείκτη F1 (47.3%). Όσον αφορά στο μοντέλο MLP – MAE, δεν παρουσιάζει τόσο ικανοποιητικά αποτελέσματα, καθώς οι τιμές MAE (0.080 p.u.) και RMSE (0.116 p.u.) είναι αυξημένες σε σχέση με τα μοντέλα MLP – MSE και MLP – LOGCOSH και έχει αρκετά χαμηλό δείκτη F1 (38.7%). Μη ικανοποιητική επίδοση φαίνεται να έχει και το μοντέλο MLP – MAAPE, με τα MAE (0.142 p.u.) και RMSE (0.184 p.u.) να είναι αρκετά υψηλά, όπως είναι και το MBE (0.104 p.u.), τιμή η οποία δείχνει σαφή υπερεκτίμηση της Φ/Β παραγωγής.

Στον Πίνακα 5.4 υπάρχουν οι τιμές του Skill Score ως προς το MAE και το RMSE για κάθε μοντέλο πρόβλεψης της Φ/Β παραγωγής, χρησιμοποιώντας ως μοντέλο αναφοράς το μοντέλο Persistence. Από τις τιμές του Πίνακα 5.4 και σύμφωνα με την Ενότητα 4.3, γίνεται αντιληπτό ότι τα μοντέλα MLP – LOGCOSH, MLP – MSE και MLP – MAE έχουν καταφέρει να ξεπεράσουν, αλλά σε μικρό βαθμό, την επίδοση του μοντέλου Persistence, όσον αφορά στο RMSE. Τη μεγαλύτερη ποσοστιαία βελτίωση του RMSE επιτυγχάνει το MLP-LOGCOSH, η οποία προσεγγίζει το 14.5%. Επίσης, μέσω του Πίνακα 5.4, επιβεβαιώνεται ότι το μοντέλο MLP – LOGCOSH είναι αυτό που πλησιάζει περισσότερο στην επίδοση του μοντέλου Persistence, σε ό,τι αφορά το μέσο απόλυτο σφάλμα.

Πίνακας 5.4: Skill Score για τα MAE και RMSE των μοντέλων πρόβλεψης Φ/Β παραγωγής

	MLP – MAE	MLP – MSE	MLP – MAAPE	MLP – LOGCOSH	MLP – F1
Skill Score – MAE	-0.383	-0.293	-1.455	-0.184	-3.650
Skill Score – RMSE	0.052	0.109	-0.502	0.144	-1.859

Το γενικό συμπέρασμα που προκύπτει για την Φ/Β παραγωγή είναι, ότι στην περίπτωση που είναι σημαντική η μείωση του μέσου σφάλματος πρόβλεψης, μπορεί να επιλεγεί είτε το μοντέλο Persistence είτε το μοντέλο MLP – LOGCOSH, καθώς και τα δύο έχουν μέσο απόλυτο σφάλμα μικρότερο από 7%. Αν ο κύριος σκοπός της παραγωγής προβλέψεων είναι η ανίχνευση συμβάντων απότομης μεταβολής, κατάλληλο μοντέλο είναι το μοντέλο MLP – F1, αφού διαθέτει δείκτη F1 σχεδόν ίσο με 50%. Τέλος, αν είναι ταυτόχρονα επιθυμητές η μέση

ακρίβεια πρόβλεψης αλλά και η ικανότητα εντοπισμού απότομων μεταβολών, το μοντέλο MLP – MSE είναι αυτό που ισορροπεί μεταξύ των δύο αυτών κριτηρίων.

Επιπλέον, από τους πίνακες 5.1 και 5.3 φαίνεται μία μεγάλη διαφορά, όσον αφορά στα αποτελέσματα για τον δείκτη F1, μεταξύ της αιολικής και της Φ/Β παραγωγής. Σύμφωνα με τον Πίνακα 5.1 για τα αιολικά δεδομένα, μόνο το μοντέλο MLP – F1 επιτυγχάνει την πρόβλεψη των συμβάντων απότομης μεταβολής ως έναν βαθμό, καθώς όλα τα υπόλοιπα μοντέλα πρόβλεψης έχουν δείκτη F1 μικρότερο από 5%, ενώ σύμφωνα με τον Πίνακα 5.3 για την Φ/Β παραγωγή, ο δείκτης F1 για όλα σχεδόν τα μοντέλα κυμαίνεται στο εύρος από 37.7% έως 48.3%. Αυτό συμβαίνει διότι η χρονική ανάλυση των Φ/Β δεδομένων είναι μικρότερη από τον χρονικό ορίζοντα πρόβλεψης, επομένως χρησιμοποιήθηκαν οι σχέσεις (4.4) και (4.5) για τον υπολογισμό του δείκτη F1, επιτρέποντας την εισαγωγή ενός παράθυρου ανοχής Δt , όπως περιγράφεται στην Ενότητα 4.2. Το γεγονός αυτό σημαίνει ότι ο εντοπισμός ενός συμβάντος απότομης μεταβολής δεν είναι απαραίτητο να επιτευχθεί ακριβώς στην σωστή χρονική στιγμή για να θεωρηθεί κατάλληλη πρόβλεψη, απλώς αρκεί η χρονική διαφορά μεταξύ των διαδοχικών τιμών ισχύος που συγκρίνονται, να είναι μικρότερη από το παράθυρο ανοχής Δt . Όμως, στα αιολικά δεδομένα, στα οποία η χρονική ανάλυση είναι ίση με τον χρονικό ορίζοντα πρόβλεψης, χρησιμοποιήθηκαν οι σχέσεις (4.1) και (4.2) για τον υπολογισμό του δείκτη F1, οι οποίες είναι πολύ πιο αυστηρές, οπότε είναι λογικό μόνο το μοντέλο MLP που εκπαιδεύτηκε με τον δείκτη F1 ως αντικειμενική συνάρτηση να έχει ικανοποιητική επίδοση σε ότι αφορά την ανίχνευση συμβάντων απότομης μεταβολής. Προκύπτει, δηλαδή, ότι και ο μαθηματικός ορισμός των συμβάντων απότομης μεταβολής για την εκάστοτε εφαρμογή επιδρά στα τελικά αποτελέσματα. Επίσης, από την παραπάνω ανάλυση, θα μπορούσε να προκύψει ως λογική συνέχεια ότι όσο μικρότερο είναι το παράθυρο ανοχής στον ορισμό των συμβάντων απότομης μεταβολής, τόσο μεγαλύτερη δυσκολία παρουσιάζει ένα μοντέλο MLP, που εκπαιδεύεται με αντικειμενικές συναρτήσεις που στοχεύουν στην ελαχιστοποίηση των μέσων σφαλμάτων (π.χ. η MAE), στο να ανιχνεύει σωστά συμβάντα απότομης μεταβολής.

ΣΥΜΠΕΡΑΣΜΑΤΑ

6.1 ΣΥΝΟΨΗ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ ΤΗΣ ΕΡΓΑΣΙΑΣ

Στην παρούσα διπλωματική εργασία πραγματοποιήθηκε η εφαρμογή πέντε διαφορετικών αντικειμενικών συναρτήσεων για την εκπαίδευση ενός μοντέλου MLP, με στόχο την υπερβραχυπρόθεσμη πρόβλεψη της αιολικής και Φ/Β παραγωγής, με χρονικό ορίζοντα πρόβλεψης τα δέκα λεπτά. Ακολούθησε η σύγκριση και ο σχολιασμός της επίδρασης των συγκεκριμένων αντικειμενικών συναρτήσεων στην επίδοση του μοντέλου, με επίκεντρο την ικανότητα αυτού να ανιχνεύει αποτελεσματικά τα συμβάντα απότομης μεταβολής στην αιολική και Φ/Β παραγωγή. Για την εκπαίδευση του μοντέλου MLP και στις δύο περιπτώσεις, χρησιμοποιήθηκε ο μεταερευτικός αλγόριθμος βελτιστοποίησης σμήνους σωματιδίων. Εκτός από το μοντέλο μηχανικής μάθησης, υλοποιήθηκε και τα στατιστικό μοντέλο πρόβλεψης Persistence για την αιολική και την Φ/Β παραγωγή, καθώς και το στατιστικό μοντέλο ARIMA για την πρόβλεψη της αιολικής παραγωγής, ώστε να υπάρχει γενικότερη σύγκριση μεταξύ μοντέλων πρόβλεψης διαφορετικού τύπου. Για την διασφάλιση της αξιοπιστίας και της ακρίβειας των παραγόμενων προβλέψεων, χρησιμοποιήθηκαν ως δεδομένα εισόδου σε όλα τα μοντέλα, μετρήσεις από μία πραγματική Α/Γ και ένα πραγματικό Φ/Β πάρκο, οι οποίες υπέστησαν την κατάλληλη προεπεξεργασία, ώστε να απομακρυνθούν τυχόν κενές ή ελλιπείς τιμές.

Κατόπιν της προεπεξεργασίας των δεδομένων, υλοποιήθηκαν τα στατιστικά μοντέλα πρόβλεψης για την αιολική και Φ/Β παραγωγή. Στην συνέχεια, αφού καθορίστηκαν οι υπερπαραμέτροι του μοντέλου MLP, πραγματοποιήθηκε η εκπαίδευσή του και παρήχθησαν οι ζητούμενες προβλέψεις, σε χρονικό ορίζοντα πρόβλεψης των δέκα λεπτών. Η εκπαίδευσή του έγινε πέντε φορές για τα αιολικά δεδομένα και πέντε φορές για τα Φ/Β δεδομένα, ώστε να δοκιμαστούν και οι πέντε αντικειμενικές συναρτήσεις. Για την αποτελεσματική αξιολόγηση και σύγκριση της επίδοσης των μοντέλων πρόβλεψης ως προς την μέση ακρίβεια πρόβλεψης και την ικανότητα ανίχνευσης απότομων μεταβολών, χρησιμοποιήθηκαν πέντε μετρητικά αξιολόγησης για κάθε μοντέλο πρόβλεψης.

Τα συμπεράσματα που προέκυψαν από την ανάλυση των αποτελεσμάτων είναι τα εξής:

- Αμφότερα για την αιολική και την Φ/Β παραγωγή, το MLP που εκπαιδεύτηκε με τον δείκτη F1 ως αντικειμενική συνάρτηση καταφέρνει να προβλέψει τα συμβάντα απότομης μεταβολής σε ικανοποιητικό βαθμό, με τον δείκτη F1 να προσεγγίζει το 43% και το 48.3% για την αιολική και τη Φ/Β παραγωγή, αντίστοιχα.
- Αμφότερα για την αιολική και την Φ/Β παραγωγή, το καλύτερο μοντέλο σε ότι αφορά το μέσο απόλυτο σφάλμα είναι το στατιστικό μοντέλο Persistence, με τιμές μικρότερες από 4% και 6% για την αιολική και τη Φ/Β παραγωγή, αντίστοιχα. Τα αποτελέσματα

αυτά επιβεβαιώνουν την υψηλή επίδοση του μοντέλου Persistence σε υπερβραχυπρόθεσμους χρονικούς ορίζοντες, όσον αφορά τη μέση ακρίβεια πρόβλεψης.

- Για την πρόβλεψη της Φ/Β παραγωγής, βέλτιστη επίδοση επιτυγχάνει και το μοντέλο MLP – LOGCOSH, όσον αφορά στην μέση ακρίβεια πρόβλεψης, καθώς έχει μέσο απόλυτο σφάλμα μικρότερο από 7% και πετυχαίνει την μικρότερη τιμή RMSE (10.5%) σε σχέση με όλα τα υπόλοιπα μοντέλα.
- Για την πρόβλεψη της Φ/Β παραγωγής, το μοντέλο που ισορροπεί μεταξύ της μέσης ακρίβειας πρόβλεψης και της ικανότητας ανίχνευσης συμβάντων απότομης μεταβολής, ικανοποιώντας και τα δύο κριτήρια, είναι το μοντέλο MLP – MSE, με σχετικά χαμηλή τιμή για το MAE (7.5%), και τη δεύτερη καλύτερη τιμή για το RMSE (10.9%) και τον δείκτη F1 (47.3%).
- Η ικανότητα ανίχνευσης συμβάντων απότομης μεταβολής εξαρτάται και από τον μαθηματικό ορισμό των ίδιων των συμβάντων απότομης μεταβολής. Όταν εφαρμόζεται παράθυρο ανοχής Δt για τον υπολογισμό του δείκτη F1, όπως συμβαίνει στην πρόβλεψη Φ/Β παραγωγής, οι δείκτες F1 προκύπτουν αρκετά ικανοποιητικοί για όλα τα μοντέλα πρόβλεψης και κυμαίνονται στο εύρος από 37.7% έως 48.3%. Όταν ο ορισμός των συμβάντων απότομης μεταβολής είναι αυστηρός, όπως συμβαίνει στην πρόβλεψη αιολικής παραγωγής, μόνο το MLP – F1 πετυχαίνει ικανοποιητική ανίχνευση συμβάντων απότομης μεταβολής, με τα υπόλοιπα μοντέλα πρόβλεψης να οδηγούν σε πολύ χαμηλές τιμές για τον δείκτη F1, μικρότερες του 5%.
- Γενικά, οι αντικειμενικές συναρτήσεις που βασίζονται στην ελαχιστοποίηση των μέσων σφαλμάτων, δεν παρουσιάζουν ικανοποιητική επίδοση στον ορθό εντοπισμό των συμβάντων απότομης μεταβολής, ενώ τα μοντέλα MLP που εκπαιδεύτηκαν με τον δείκτη F1 παρουσιάζουν την χαμηλότερη επίδοση σε ότι αφορά την μέση ακρίβεια πρόβλεψης. Συνεπώς, η αξιολόγηση των μοντέλων πρόβλεψης επηρεάζεται καθοριστικά από την επιλογή του κριτηρίου αξιολόγησης.

6.2 ΜΕΛΛΟΝΤΙΚΕΣ ΕΠΕΚΤΑΣΕΙΣ

Μία πιθανή επέκταση της παρούσας διπλωματικής εργασίας αποτελεί η ενσωμάτωση πολυκριτηριακής βελτιστοποίησης στην διαδικασία εκπαίδευσης του MLP. Δηλαδή, αντί το μοντέλο να βελτιστοποιείται μέσω μίας αντικειμενικής συνάρτησης και βάσει ενός, μόνο, συγκεκριμένου κριτηρίου, θα μπορούσε να εκπαιδευτεί ταυτόχρονα με δύο αντικειμενικές συναρτήσεις που θα εστιάζουν σε διαφορετικούς, αλλά συμπληρωματικούς στόχους. Για παράδειγμα, θα μπορούσε να χρησιμοποιηθεί ο δείκτης F1 για την ορθή ανίχνευση συμβάντων απότομης μεταβολής σε συνδυασμό με το MSE για την μείωση του μέσου σφάλματος. Μία τέτοια προσέγγιση αποτελεί μία συμβιβαστική λύση, που θα διευκόλυνε την ορθή πρόβλεψη απότομων μεταβολών, χωρίς να υποβαθμίζεται υπερβολικά η γενική ποιότητα και ακρίβεια των προβλέψεων, και θα προσέφερε πιο ρεαλιστικά και λειτουργικά αποτελέσματα για εφαρμογές με υψηλές απαιτήσεις αξιοπιστίας.

Μία ακόμα πιθανή επέκταση της παρούσας διπλωματικής εργασίας είναι η ανάπτυξη κατάλληλων αλγορίθμων βελτιστοποίησης ή η προσαρμογή των ήδη υπαρχόντων, ώστε να ικανοποιούνται οι προϋποθέσεις της πολυκριτηριακής εκπαίδευσης. Ένας τέτοιος αλγόριθμος θα πρέπει να επιτρέπει την αναζήτηση λύσεων, οι οποίες ικανοποιούν ταυτόχρονα πολλαπλά,

και ενδεχομένως αντικρουόμενα κριτήρια, παρέχοντας παράλληλα σταθερότητα και αξιοπιστία στην εκπαίδευση των τεχνητών νευρωνικών δικτύων. Η υλοποίηση ή η χρήση, καθώς και η αξιολόγηση ενός γενικού και ευέλικτου αλγορίθμου βελτιστοποίησης, θα διευκόλυνε την προσαρμογή των μεθόδων πρόβλεψης σε διαφορετικά δεδομένα και εφαρμογές, και θα ενίσχυε τη δυνατότητα εξαγωγής πρακτικών συμπερασμάτων για την συνολική επίδοση αυτών.

Η επέκταση της παρούσας διπλωματικής εργασίας θα μπορούσε να αφορά και στην δοκιμή μοντέλων μηχανικής μάθησης με πιο σύνθετη αρχιτεκτονική, όπως είναι για παράδειγμα τα μοντέλα CNN, καθώς και στην αξιοποίηση επιπλέον δεδομένων εισόδου, όπως είναι για παράδειγμα οι εικόνες ουρανού από αισθητήρες και κάμερες. Τέτοιες προσεγγίσεις μπορούν να βελτιώσουν την ικανότητα του μοντέλου να ανιχνεύει πολύπλοκα χωροχρονικά μοτίβα, τα οποία δεν αποτυπώνονται πλήρως σε απλές χρονοσειρές, προσφέροντας, ενδεχομένως, πιο αξιόπιστες προβλέψεις, ειδικά υπό συνεχώς μεταβαλλόμενες μετεωρολογικές συνθήκες.

Επιπλέον, η δοκιμή διαφορετικών μεγεθών του παραθύρου ανοχής Δt και η μελέτη της επίδρασής τους στην ικανότητα ανίχνευσης συμβάντων απότομης μεταβολής από τα μοντέλα πρόβλεψης, θα μπορούσε να αποτελεί μία ακόμη επέκταση της παρούσας διπλωματικής εργασίας. Με την μεταβολή του Δt , και την ανάλυση των αποτελεσμάτων μπορεί να προσδιοριστεί το κατάλληλο σημείο ισορροπίας μεταξύ ευαισθησίας στην έγκαιρη ανίχνευση των απότομων μεταβολών και αντοχής του μοντέλου σε ψευδείς συναγερμούς, και να γίνει πιο σαφής η εξάρτηση της επίδοσης από τον μαθηματικό ορισμό των συμβάντων απότομης μεταβολής και από την χρονική ανάλυση των δεδομένων. Με αυτόν τον τρόπο, θα διευκολυνθεί πρακτικά ο ορισμός των συμβάντων απότομης μεταβολής ανάλογα με το είδος της εφαρμογής και τα χαρακτηριστικά των διαθέσιμων δεδομένων.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1]. IRENA, *Renewable Capacity Statistics 2025: Executive Summary*, International Renewable Energy Agency, Abu Dhabi, 2025. Available at: <https://www.irena.org/Publications/2025/Mar/Renewable-capacity-statistics-2025>
- [2]. A. Ulbig and G. Andersson, "Analyzing Operational Flexibility of Power Systems," *IEEE Transactions on Power Systems*, vol. 30, no. 2, pp. 1027–1038, Mar. 2015, doi: [10.1109/TPWRS.2014.2331298](https://doi.org/10.1109/TPWRS.2014.2331298)
- [3]. ENTSO-E, *Congestion Management Report 2023*. Available at: <https://www.entsoe.eu>
- [4]. Y. Dou, S. Tan, and D. Xie, "Comparison of machine learning and statistical methods in the field of renewable energy power generation forecasting: a mini review," *Frontiers in Energy Research*, vol. 11, Jul. 2023, doi: <https://doi.org/10.3389/fenrg.2023.1218603>.
- [5]. B. Nouri, Y. Fabel, N. Blum, D. Schnaus, L. F. Zarzalejo, A. Kazantzidis, and S. Wilbert, "Ramp Rate Metric Suitable for Solar Forecasting," *Solar RRL*, vol. 8, no. 2400468, 2024, doi : [10.1002/solr.202400468](https://doi.org/10.1002/solr.202400468)
- [6]. L. Han, Y. Qiao, M. Li, and L. Shi, "Wind Power Ramp Event Forecasting Based on Feature Extraction and Deep Learning," *Energies*, vol. 13, no. 23, p. 6449, Dec. 2020, doi: <https://doi.org/10.3390/en13236449>.
- [7]. D. Markovics and M. J. Mayer, "Comparison of machine learning methods for photovoltaic power forecasting based on numerical weather prediction," *Renewable and Sustainable Energy Reviews*, vol. 161, p. 112364, Jun. 2022, doi: <https://doi.org/10.1016/j.rser.2022.112364>.
- [8]. Q. Chen and K. A. Folly, "Wind Power Forecasting," *IFAC-PapersOnLine*, vol. 51, no. 28, pp. 414–419, 2018, doi: <https://doi.org/10.1016/j.ifacol.2018.11.738>.
- [9]. J. Schaible *et al.*, "Application of nowcasting to reduce the impact of irradiance ramps on PV power plants," *EPJ Photovoltaics*, vol. 15, pp. 15–15, Jan. 2024, doi: <https://doi.org/10.1051/epjpv/2024009>.
- [10]. IPCC, *Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*, IPCC, Geneva, Switzerland, 2023. Available at: <https://www.ipcc.ch/report/ar6/syr/>

- [11]. WMO, *Greenhouse Gas Bulletin – The State of Greenhouse Gases in the Atmosphere Based on Global Observations through 2023*, No. 20, World Meteorological Organization, Geneva, Switzerland, 2024. Available at: <https://wmo.int/publication-series/wmo-greenhouse-gas-bulletin-no-20>
- [12]. UNFCCC, *The Paris Agreement*, United Nations Framework Convention on Climate Change (UNFCCC), 2024. Available at: <https://unfccc.int/process-and-meetings/the-paris-agreement>
- [13]. UNEP, *Emissions Gap Report 2024: Broken Record – Temperatures Hit New Highs, Yet World Fails to Cut Emissions (Again)*, United Nations Environment Programme, Nairobi, Kenya, 2024. Available at: <https://www.unep.org/resources/emissions-gap-report-2024>
- [14]. The Green Tank, “New record for renewables in December 2024,” *The Green Tank*, Jan. 30, 2025. Available at: <https://thegreentank.gr/en/2025/01/30/admie-dec2024/>
- [15]. G. Hatzigeorgiou, “Πάνω από 2,5 GW οι εγκαταστάσεις φωτοβολταϊκών στην Ελλάδα το 2024,” *EnergyMag*, Jan. 2025. Available at: https://www.energymag.gr/energeia/ape/104900_pano-apo-25-gw-oi-egkatastaseis-fotovoltaikon-stin-ellada-2024
- [16]. Hellenic Wind Energy Association (ELETAEN), *Wind Energy Statistics – June 2025*, Athens, Greece, Jul. 2025. Available at: <https://eletaen.gr/hwea-wind-statistics/>
- [17]. Energy Institute, *Statistical Review of World Energy 2025 – 74th Edition*, London, UK, 2025. Available at: <https://www.energyinst.org/statistical-review>
- [18]. J. F. Manwell, J. G. McGowan, and A. L. Rogers, *Wind Energy Explained: Theory, Design and Application*, 2nd ed. Chichester, UK: Wiley, 2009.
- [19]. M. Promponas, *Εφαρμογή πολυεπιπέδου τεχνητού νευρωνικού δικτύου για την ανάλυση των επιδόσεων ανεμογεννητριών κοινής ωφελείας*, Πτυχιακή εργασία, Τμήμα Φυσικής, Εθνικό και Καποδιστριακό Πανεπιστήμιο Αθηνών, Αθήνα, Ελλάδα, 2017.
- [20]. T. Burton, D. Sharpe, N. Jenkins, and E. Bossanyi, *Wind Energy Handbook*, 3rd ed. Hoboken, NJ: Wiley, 2021.
- [21]. A. Bensalah, G. Barakat, and Y. Amara, “Electrical generators for large wind turbine: Trends and challenges,” *Energies*, vol. 15, no. 18, pp. 6700, Sep. 2022, doi: [10.3390/en15186700](https://doi.org/10.3390/en15186700).
- [22]. Y. A. Katsigiannis and G. S. Stavrakakis, “Estimation of wind energy production in various sites in Australia for different wind turbine classes: A comparative technical and economic assessment,” *Renewable Energy*, vol. 67, pp. 230–236, Jul. 2014, doi: [10.1016/j.renene.2013.11.051](https://doi.org/10.1016/j.renene.2013.11.051).
- [23]. M. A. Κουσουνάδης-Κνούσεν, *Πιθανοτική πρόβλεψη αιολικής παραγωγής με χρήση τεχνητών νευρωνικών δικτύων*, Διπλωματική εργασία, Σχολή

- Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Εθνικό Μετσόβιο Πολυτεχνείο, Αθήνα, Ελλάδα, Ιούλ. 2021.
- [24]. O. Singh, S. K. Rajput, "Mathematical modelling and simulation of solar photovoltaic array system," *2016 International Conference on Research Advances in Integrated Navigation Systems (RAINS)*, May 2016, doi: [10.1109/RAINS.2016.7764395](https://doi.org/10.1109/RAINS.2016.7764395).
- [25]. C. S. Solanki, *Solar Photovoltaics: Fundamentals, Technologies and Applications*, 3rd ed. New Delhi, India: Prentice Hall, 2015.
- [26]. K. L. Chopra, P. Paulson, and V. Dutta, "Thin-film solar cells: An overview," *Progress in Photovoltaics: Research and Applications*, vol. 12, no. 2-3, pp. 69–92, Mar. 2004, doi: [10.1002/pip.541](https://doi.org/10.1002/pip.541).
- [27]. Ν. Ι. Ζωίδης, «Υβριδικό μοντέλο βαθιάς μάθησης για βραχυπρόθεσμη πρόβλεψη παραγωγής φωτοβολταϊκών και εφαρμογή στην αγορά ηλεκτρικής ενέργειας», Διπλωματική Εργασία, Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Εθνικό Μετσόβιο Πολυτεχνείο, Αθήνα, Οκτ. 2023.
- [28]. Z. Wu, Z. Chen, C. Wang, M. Zhou, J. Wang, and L. Chen, "Unlocking the potential of rooftop solar panels: An incentive rate structure design," *Energy policy*, vol. 190, pp. 114159–114159, Jul. 2024, doi: <https://doi.org/10.1016/j.enpol.2024.114159>.
- [29]. E. Rani and K. N. Sujatha, "Performance Computation of Sustainable Energy System Using PVLIB-Python," *2023 IEEE 3rd International Conference on Sustainable Energy and Future Electric Transportation (SeFeT)*, Aug. 2023, doi: [10.1109/SeFeT57834.2023.10245622](https://doi.org/10.1109/SeFeT57834.2023.10245622).
- [30]. S. Jain and V. Agarwal, *Advances in Solar Photovoltaic Power Plants*. Springer, 2016.
- [31]. G. M. Lohmann, "Irradiance Variability Quantification and Small-Scale Averaging in Space and Time: A Short Review," *Atmosphere*, vol. 9, no. 7, p. 264, Jul. 2018, doi: [10.3390/atmos9070264](https://doi.org/10.3390/atmos9070264).
- [32]. Ε. Γκίκα, *Σύγκριση Μεθόδων Πρόβλεψης Παραγωγής από Ανανεώσιμες Πηγές Ενέργειας*, Διπλωματική εργασία, Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Εθνικό Μετσόβιο Πολυτεχνείο, Αθήνα, Ελλάδα, 2024.
- [33]. W. J. Cole, D. Greer, P. Denholm, T. Mai, N. Vincent, and S. F. Baldwin, "Quantifying the challenge of reaching a 100% renewable energy power system for the United States," *Joule*, vol. 5, no. 7, pp. 1732–1748, Jul. 2021, doi: [10.1016/j.joule.2021.05.011](https://doi.org/10.1016/j.joule.2021.05.011).
- [34]. M. Kraiczy *et al.*, "Benefits of advanced PV power forecasts for congestion management and reactive power management at the distribution level," *ETG Congress 2021*, Berlin/Offenbach, Germany, May 2021, pp. 1–6.

- [35]. Y. Song, M. Chae, Y. Chu, Y. Yoon, and Y. Jin, "Impact of Penalty Structures on Virtual Power Plants in a Day-Ahead Electricity Market," *Energies*, vol. 17, no. 23, Art. no. 6042, Dec. 2024, doi: 10.3390/en17236042.
- [36]. Π. Φιλίππου, *Πρόβλεψη ηλιακής ακτινοβολίας με χρήση μεθόδων μηχανικής μάθησης και αξιοποίησης δεδομένων νεφοκάλυψης*, Διπλωματική Εργασία, Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Εθνικό Μετσόβιο Πολυτεχνείο, Αθήνα, Οκτ. 2024.
- [37]. G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5th ed. Hoboken, NJ, USA: Wiley, 2015.
- [38]. R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*, 3rd ed. Melbourne, Australia: OTexts, 2021.
- [39]. R. H. Inman, H. T. C. Pedro, and C. F. M. Coimbra, "Solar forecasting methods for renewable energy integration," *Progress in Energy and Combustion Science*, vol. 39, no. 6, pp. 535–576, 2013, doi: 10.1016/j.pecs.2013.06.002.
- [40]. P. Bauer, A. Thorpe, and G. Brunet, "The quiet revolution of numerical weather prediction," *Nature*, vol. 525, no. 7567, pp. 47–55, Sep. 2015, <https://doi.org/10.1038/nature14956>
- [41]. A. Florita, B.-M. Hodge, and K. Orwig, "Identifying wind and solar ramping events," in *Proc. IEEE Green Technologies Conf.*, Denver, CO, Apr. 4–5, 2013, NREL/TP-5500-57447, Jan. 2013
- [42]. M. J. E. Alam, K. Muttaqi, and D. Sutanto, "Battery energy storage to mitigate rapid voltage/power fluctuations in power grids due to fast variations of solar/wind outputs," *IEEE Access*, vol. 9, pp. 12191–12202, Jan. 2021, doi: 10.1109/ACCESS.2021.3051283.
- [43]. I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
- [44]. 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, pp. 78–111, Oct. 2016, doi: <https://doi.org/10.1016/j.solener.2016.06.069>.
- [45]. P. S. Georgilakis, *Spotlight on Modern Transformer Design*. London: Springer-Verlag, 2009.
- [46]. S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Upper Saddle River, N.J.: Pearson Education, 2009.
- [47]. C. M. Bishop, *Pattern Recognition and Machine Learning*, Springer, 2006.
- [48]. M. Husein and I.-Y. Chung, "Day-Ahead Solar Irradiance Forecasting for Microgrids Using a Long Short-Term Memory Recurrent Neural Network: A Deep Learning Approach," *Energies*, vol. 12, no. 10, p. 1856, May 2019, doi: <https://doi.org/10.3390/en12101856>.

- [49]. W. Pedrycz and S.-M. Chen, *Deep learning: algorithms and applications*. Cham: Springer International Publishing, 2020.
- [50]. B. Ghosh, I. K. Dutta, A. Carlson, M. Totaro, and M. Bayoumi, “An Empirical Analysis of Generative Adversarial Network Training Times with Varying Batch Sizes,” *2020 11th IEEE Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON)*, Oct. 2020, doi: <https://doi.org/10.1109/uemcon51285.2020.9298092>.
- [51]. E. M. Dogo, O. J. Afolabi, N. I. Nwulu, B. Twala, and C. O. Aigbavboa, “A Comparative Analysis of Gradient Descent-Based Optimization Algorithms on Convolutional Neural Networks,” *2018 International Conference on Computational Techniques, Electronics and Mechanical Systems (CTEMS)*, Dec. 2018, doi: <https://doi.org/10.1109/ctems.2018.8769211>.
- [52]. R. Aron and A. Abraham, “Resource scheduling methods for cloud computing environment: The role of meta-heuristics and artificial intelligence,” *Engineering Applications of Artificial Intelligence*, vol. 116, p. 105345, Nov. 2022, doi: <https://doi.org/10.1016/j.engappai.2022.105345>.
- [53]. M. Gendreau and Jean-Yves Potvin, *Handbook of Metaheuristics*, Berlin: Springer Us, 2009.
- [54]. L. Abualigah, “Particle Swarm Optimization: Advances, Applications, and Experimental Insights,” *Computers, Materials & Continua*, vol. 82, no. 2, pp. 1539–1592, 2025, doi: <https://doi.org/10.32604/cmc.2025.060765>.
- [55]. A. A. Amponsah, F. Han, Q.-H. Ling, and P. K. Kudjo, “An enhanced class topper algorithm based on particle swarm optimizer for global optimization,” *Applied Intelligence*, vol. 51, no. 2, pp. 1022–1040, Sep. 2020, doi: <https://doi.org/10.1007/s10489-020-01856-4>.
- [56]. A. G. Gad, “Particle Swarm Optimization Algorithm and Its Applications: A Systematic Review,” *Archives of Computational Methods in Engineering*, vol. 29, pp. 2531–2561, 2022, doi:10.1007/s11831-021-09694-4.
- [57]. A. Jadon, A. Patil, and S. Jadon, “A Comprehensive Survey of Regression Based Loss Functions for Time Series Forecasting,” *arXiv.org*, Nov. 05, 2022. <https://arxiv.org/abs/2211.02989>
- [58]. T. Hastie, J. Friedman, and R. Tibshirani, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. New York, Ny Springer New York Imprint: Springer, 2009.
- [59]. S. Kim and H. Kim, “A new metric of absolute percentage error for intermittent demand forecasts,” *International Journal of Forecasting*, vol. 32, no. 3, pp. 669–679, Jul. 2016, doi: <https://doi.org/10.1016/j.ijforecast.2015.12.003>.
- [60]. J. Terven, Diana-Margarita Cordova-Esparza, Julio-Alejandro Romero-González, A. Ramírez-Pedraza, and E. A. Chávez-Urbiola, “A comprehensive survey of loss functions and metrics in deep learning,” *Artificial Intelligence*

- Review, vol. 58, no. 7, Apr. 2025, doi: <https://doi.org/10.1007/s10462-025-11198-7>.
- [61]. “Penmanshiel (United-Kingdom) - Wind farms - Online access - The Wind Power”, *Thewindpower.net*, 2025. Available at: https://www.thewindpower.net/windfarm_en_23147_penmanshiel.php
- [62]. C. Plumley, “Penmanshiel Wind Farm Data”. Zenodo, Feb. 07, 2022. doi: [10.5281/zenodo.5946807](https://doi.org/10.5281/zenodo.5946807)
- [63]. D. C. Montgomery and G. C. Runger, *Applied statistics and probability for engineers*, 7th ed. Hoboken, NJ: Wiley, Jan. 2018.
- [64]. S. E. Said and D. A. Dickey, “Testing for Unit Roots in Autoregressive-Moving Average Models of Unknown Order,” *Biometrika*, vol. 71, no. 3, pp. 599–607, Dec. 1984, doi: <https://doi.org/10.1093/biomet/71.3.599>
- [65]. W. Enders, *Applied Econometric Time Series*, 4th ed., Wiley, 2014.
- [66]. D.K. Thara, B.G. PremaSudha, and F. Xiong, “Auto-detection of epileptic seizure events using deep neural network with different feature scaling techniques,” *Pattern Recognition Letters*, vol. 128, pp. 544–550, Dec. 2019, doi: <https://doi.org/10.1016/j.patrec.2019.10.029>.
- [67]. D. S. Kumar, G. M. Yagli, M. Kashyap, and D. Srinivasan, “Solar irradiance resource and forecasting: a comprehensive review,” *IET Renewable Power Generation*, vol. 14, no. 10, pp. 1641–1656, Jul. 2020, doi: <https://doi.org/10.1049/iet-rpg.2019.1227>.
- [68]. H. Hewamalage, K. Ackermann, and C. Bergmeir, “Forecast evaluation for data scientists: common pitfalls and best practices,” *Data Mining and Knowledge Discovery*, Dec. 2022, doi: <https://doi.org/10.1007/s10618-022-00894-5>.
- [69]. R. Pandas Team, “pandas-dev/pandas: Pandas,” Zenodo, 2020, doi: 10.5281/zenodo.3509134.
- [70]. T. E. Oliphant, *Guide to NumPy*. Austin, Tex.: Continuum Press, Cop, 2015
- [71]. J. D. Hunter, “Matplotlib: A 2D Graphics Environment,” in *Computing in Science & Engineering*, vol. 9, no. 3, pp. 90-95, May-June 2007, doi: 10.1109/MCSE.2007.55.
- [72]. F. Pedregosa et al., “Scikit-learn: Machine Learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011. Available at: <http://www.jmlr.org/papers/v12/pedregosa11a.html>
- [73]. T. G. Smith et al., “pmdarima: ARIMA estimators for Python,” Alkaline-ML / pmdarima project, 2017–. Available at: <https://alkaline-ml.com/pmdarima>
- [74]. S. Seabold and J. Perktold, “Statsmodels: Econometric and Statistical Modeling with Python,” in *Proceedings of the 9th Python in Science Conference*, 2010. Available at: <https://conference.scipy.org/proceedings/scipy2010/pdfs/seabold.pdf>