



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

**Πιθανοτική βραχυπρόθεσμη πρόβλεψη  
παραγωγής από αιολικά και φωτοβολταϊκά  
συστήματα με τεχνικές μηχανικής μάθησης**

**ΔΙΔΑΚΤΟΡΙΚΗ ΔΙΑΤΡΙΒΗ**

Ιωάννης Κ. Μπαζιώνης

Αθήνα, Νοέμβριος 2024





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

**Πιθανοτική βραχυπρόθεσμη πρόβλεψη  
παραγωγής από αιολικά και φωτοβολταϊκά  
συστήματα με τεχνικές μηχανικής μάθησης**

**ΔΙΔΑΚΤΟΡΙΚΗ ΔΙΑΤΡΙΒΗ**

**Ιωάννης Κ. Μπαζιώνης**

**Συμβουλευτική Επιτροπή :** Πάυλος Σ. Γεωργιάκης (Επιβλέπων)  
Νικόλαος Δ. Χατζηαργυρίου  
Γεώργιος Ν. Κορρές

Εγκρίθηκε από την επταμελή εξεταστική επιτροπή την 28<sup>η</sup> Νοεμβρίου 2024.

.....  
Π. Γεωργιάκης  
Καθηγητής Ε.Μ.Π.  
(Επιβλέπων)

.....  
Ν. Χατζηαργυρίου  
Καθηγητής Ε.Μ.Π.

.....  
Γ. Κορρές  
Καθηγητής Ε.Μ.Π.

.....  
Δ. Σούντρης  
Καθηγητής Ε.Μ.Π.

.....  
Δ. Ρεΐσης  
Καθηγητής Ε.Κ.Π.Α.

.....  
Δ. Ασκούνης  
Καθηγητής Ε.Μ.Π.

.....  
Δ. Στημονιάρης  
Αναπληρωτής Καθηγητής Π.Δ.Μ.

Αθήνα, Νοέμβριος 2024

.....  
Ιωάννης Κ. Μπαζιώνης

Διδάκτωρ Μηχανικός Ε.Μ.Π, M.Sc. Ε.Μ.Π, Γεωλόγος Ε.Κ.Π.Α.

Copyright © Ιωάννης Κ. Μπαζιώνης, 2024.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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

*Στην Μαρία και τον Κωνσταντίνο,  
τη Μάρθα και την Ιωάννα*



## Περίληψη

Η παρούσα διδακτορική διατριβή, αναπτύσσοντας πρωτότυπα μοντέλα πρόβλεψης της αιολικής και φωτοβολταϊκής παραγωγής, συμβάλλει στη διείσδυση της αιολικής και φωτοβολταϊκής παραγωγής στα συστήματα ηλεκτρικής ενέργειας.

Αρχικά, παρουσιάζονται οι κατηγορίες μοντέλων πρόβλεψης που έχουν αναπτυχθεί ανά τα χρόνια για την επιτυχή και ακριβή πρόβλεψη από συστήματα αιολικής και φωτοβολταϊκής παραγωγής αλλά και οι βασικότεροι παράγοντες που επηρεάζουν την ακρίβεια της πρόβλεψης. Ιδιαίτερη έμφαση δίνεται στην ανάλυση των Τεχνητών Νευρωνικών Δικτύων, που στα πλαίσια εξέλιξης του κλάδου της μηχανικής μάθησης έχουν παίξει καθοριστικό ρόλο στη βελτίωση της απόδοσης των μοντέλων πρόβλεψης ενέργειας από Ανανεώσιμες Πηγές. Σε αυτό το πλαίσιο και εστιάζοντας στην κατανόηση της αβεβαιότητας που περιέχεται σε μια διαδικασία πρόβλεψης παραγωγής ενέργειας, προτείνεται ένα καινοτόμο, υβριδικό μοντέλο βραχυπρόθεσμης πρόβλεψης αιολικής παραγωγής, στηριζόμενο σε τεχνικές μηχανικής μάθησης. Ένας βελτιστοποιημένος αλγόριθμος σμήνους προσαρμόζεται και εφαρμόζεται στην προτεινόμενη μεθοδολογία για την βελτιστοποίηση των υπερπαραμέτρων της προτεινόμενης αρχιτεκτονικής. Το μοντέλο εφαρμόζεται σε πραγματικά δεδομένα αιολικών συστημάτων. Η αποτελεσματικότητα του μοντέλου αποδεικνύεται μέσω της σύγκρισης των αποτελεσμάτων που προκύπτουν με τελευταίας τεχνολογίας μοντέλα πιθανοτικής πρόβλεψης αιολικής παραγωγής.

Στη συνέχεια, εστιάζοντας στην πρόβλεψη παραγωγής ενέργειας από φωτοβολταϊκά συστήματα, αναπτύσσεται ένα πρωτότυπο, υβριδικό μοντέλο βραχυπρόθεσμης, πιθανοτικής πρόβλεψης, κατάλληλο για την πρόβλεψη φωτοβολταϊκής παραγωγής. Ένας πολύπλοκος, βελτιωμένος αλγόριθμος τύπου σμήνους κοτόπουλων προσαρμόζεται στην αρχιτεκτονική του προτεινόμενου μοντέλου, καταφέροντας να βελτιώσει την απόδοσή του, αποφεύγοντας παράλληλα να επιβαρύνει το υπολογιστικό κόστος της μεθοδολογίας. Επιπλέον, ένας μηχανισμός θηράματος-θηρευτή ενσωματώνεται στο τελικό υβριδικό μοντέλο για να βελτιώσει εκ νέου τις δυνατότητες αναζήτησης του προτεινόμενου μοντέλου για τη βέλτιστη δυνατή πρόβλεψη. Το μοντέλο εφαρμόζεται σε πραγματικά δεδομένα φωτοβολταϊκών συστημάτων. Τα τελικά αποτελέσματα αναδεικνύουν, τόσο την ανωτερότητα του προτεινόμενου μοντέλου πρόβλεψης έναντι μοντέλων τελευταίας τεχνολογίας στα οποία εφαρμόστηκαν τα διαθέσιμα δεδομένα, όσο και τη δυνατότητα εφαρμογής του μοντέλου σε πραγματικά προβλήματα πρόβλεψης φωτοβολταϊκής παραγωγής.

Συμπερασματικά, τα προτεινόμενα μοντέλα εισάγουν ένα καινοτόμο πλαίσιο μεθοδολογιών πιθανοτικής βραχυπρόθεσμης πρόβλεψης με υβριδικές μεθόδους μηχανικής μάθησης, που συμβάλλουν στη διείσδυση της αιολικής και φωτοβολταϊκής παραγωγής στα συστήματα ηλεκτρικής ενέργειας.

## Λέξεις κλειδιά

Ανανεώσιμες πηγές ενέργειας, μέθοδοι μηχανικής μάθησης, συστήματα αιολικής παραγωγής, συστήματα πρόβλεψης παραγωγής ενέργειας, συστήματα φωτοβολταϊκής παραγωγής, τεχνητά νευρωνικά δίκτυα



## **Abstract**

This PhD thesis contributes to the penetration of wind and photovoltaic power generation in power systems, by developing original forecasting models of wind and photovoltaic generation.

Initially, the categories of forecasting models that have been developed over the years for the successful and accurate prediction from wind and photovoltaic generation systems are presented, as well as the main factors that affect the accuracy of the forecasts. Particular emphasis is placed on the analysis of Artificial Neural Networks, which in the context of the evolution of the machine learning industry have played a decisive role in improving the performance of renewable energy forecasting models. In this context and focusing on understanding the uncertainty involved in an energy production forecasting process, an innovative, hybrid model of short-term wind generation forecasting based on machine learning techniques is proposed. An optimized swarm algorithm is adapted and applied to the proposed methodology to optimize the hyperparameters of the proposed architecture. The effectiveness of the model is proven by comparing the results obtained with state-of-the-art probabilistic wind power generation prediction models.

Then, focusing on power prediction from photovoltaic systems, an innovative, hybrid model for short-term, probabilistic forecasting is developed, suitable for photovoltaic power forecasting. A complex, improved chicken swarm type algorithm was adapted to the architecture of the proposed model, managing to improve its performance, while avoiding increasing the computational cost of the methodology. In addition, a prey-predator mechanism is integrated into the final hybrid model to further improve the search capabilities of the proposed model for optimal predictive outcomes. The model is applied to real data of solar parks. The final results highlight both the superiority of the proposed forecasting model over state-of-the-art models to which the available data were applied, as well as its applicability to real-world photovoltaic power forecasting problems.

In conclusion, the proposed models introduce an innovative framework of methodologies that contribute to the penetration of wind and photovoltaic power generation in electric power systems.

## **Keywords**

Renewable energy sources, machine learning methods, wind generation systems, energy forecasting systems, photovoltaic generation systems, artificial neural networks



## Πρόλογος

Η παρούσα διδακτορική διατριβή άρχισε να εκπονείται τον Οκτώβριο του 2018 στο Εργαστήριο Συστημάτων Ηλεκτρικής Ενέργειας της Σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου, υπό την επίβλεψη του Καθηγητή κ. Παύλου Σ. Γεωργιλάκη.

Θα ήθελα να εκφράσω τις ευχαριστίες μου:

- Στον Καθηγητή μου κ. Παύλο Γεωργιλάκη, για την τιμή που μου έκανε αναθέτοντάς μου την εκπόνηση αυτής της διδακτορικής διατριβής και για τη συνεχή και λεπτομερή επίβλεψη και καθοδήγησή του σε όλη την πορεία εκπόνησης της εργασίας μου.
- Στον Καθηγητή μου κ. Νικόλαο Χατζηαργυρίου, μέλος της τριμελούς συμβουλευτικής επιτροπής μου, για την ευκαιρία που μου έδωσε να εκπονήσω τη διδακτορική μου διατριβή, αλλά και την καθοδήγηση και τις συμβουλές του στην πορεία του ερευνητικού μου έργου.
- Στον Καθηγητή μου κ. Γιώργο Κορρέ, μέλος της τριμελούς συμβουλευτικής επιτροπής μου, για την εξαιρετική συνεργασία και για τις εύστοχες παρατηρήσεις του σε όλη τη διάρκεια εκπόνησης της διατριβής μου.
- Στον Καθηγητή μου κ. Δημήτριο Σούντρη, για την ευκαιρία που μου έδωσε να συνεργαστούμε σε ένα άψογο και δημιουργικό περιβάλλον αμοιβαίας εκτίμησης, συμβάλλοντας σημαντικά στην ομαλή εξέλιξη της διδακτορικής μου διατριβής.
- Στον Καθηγητή κ. Διονύσιο Ρεΐση για την εξαιρετική συνεργασία που είχαμε σε ερευνητικό επίπεδο, αλλά και για την αποδοχή συμμετοχής του στην εξεταστική επιτροπή της ενδιάμεσης και της τελικής κρίσης της διδακτορικής διατριβής μου.
- Στους Καθηγητές κκ. Δημήτριο Ασκούνη και Δημήτριο Τσιαμήτρο για την αποδοχή συμμετοχής τους στην επταμελή εξεταστική επιτροπή της διδακτορικής μου διατριβής.
- Στον Prof. Dr. Francky Catthoor για την υποδειγματική συνεργασία που είχαμε στα πλαίσια εκπόνησης της διδακτορικής μου διατριβής, τις ιδιαίτερα παραγωγικές διαδικτυακές και δια ζώσης συναντήσεις μας, και την πολύτιμη βοήθεια που μου προσέφερε σε όλες τις κοινές μας δημοσιεύσεις σε διεθνή επιστημονικά περιοδικά.

Θα ήθελα να ευχαριστήσω την Ειδική Υπηρεσία Διαχείρισης και Εφαρμογής Δράσεων στους τομείς Έρευνας, Τεχνολογικής Ανάπτυξης και Καινοτομίας (ΕΥΔΕ ΕΤΑΚ) του Υπουργείου Ανάπτυξης για τη χρηματοδότηση της διδακτορικής μου διατριβής μέσω της Δράσης ΕΣΠΑ 2014–2020: «ΕΡΕΥΝΩ – ΔΗΜΙΟΥΡΓΩ – ΚΑΙΝΟΤΟΜΩ Β’ ΚΥΚΛΟΣ», η οποία συγχρηματοδοτήθηκε από την Ευρωπαϊκή Ένωση και εθνικούς πόρους μέσω του Ε.Π. Ανταγωνιστικότητα, Επιχειρηματικότητα & Καινοτομία (ΕΠΑνΕΚ) (κωδικός έργου: Τ2ΕΔΚ-00864, ακρωνύμιο έργου: ARCHON, τίτλος έργου: «Καινοτόμο, Σύγχρονο & Ανοικτό Σύστημα Πρόβλεψης & Ελέγχου Παραγωγής Φ/Β και Μεικτών Πάρκων»).

Ιδιαίτερες ευχαριστίες οφείλω προς τον διδάκτορα του Ε.Μ.Π. κ. Παναγιώτη Καραφώτη για την άριστη συνεργασία που είχαμε στα χρόνια εκπόνησης της διδακτορικής διατριβής μου, για τη βοήθεια και τις συμβουλές που μου προσέφερε, αλλά και για την εμπιστοσύνη που έδειξε στο πρόσωπό μου ως συνάδελφο και συνεργάτη.

Επιπλέον, θα ήθελα να ευχαριστήσω τον υποψήφιο διδάκτορα Ε.Μ.Π. κ. Μάρκο Κουσούνδη-Κνούσεν, για την εξαιρετική συνεργασία και τη στήριξή του σε ένα εξαιρετικό επίπεδο συνεργασίας.

Θα ήθελα να ευχαριστήσω τον διδάκτορα Νίκο Ε.Μ.Π. κ. Νικόλαο Κουτσούκη, τον διδάκτορα Ε.Μ.Π. κ. Βασίλειο Ευαγγελόπουλο και τον υποψήφιο διδάκτορα Ε.Μ.Π. κ. Χριστόφορο Μένο-Αικατερινιάδη για τις γνώσεις που μοιράστηκαν μαζί μου και για την εξαιρετική συνεργασία που είχαμε σε όλη τη διάρκεια εκπόνησης της διδακτορικής διατριβής μου.

Ευχαριστώ τους συναδέλφους μου στον Τομέα Λειτουργίας Τηλεμέτρησης του Διαχειριστή Ελληνικού Δικτύου Διανομής Ηλεκτρικής Ενέργειας (ΔΕΔΔΗΕ), κα. Θεοδώρα Σταματιάδη, κα. Μαρία Δελή, κ. Θωδωρή Μπούμη και κ. Κωνσταντίνο Μαγκανιώτη για τη στήριξη και την κατανόησή τους κατά τη διάρκεια της εκπόνησης και συγγραφής της διδακτορικής μου διατριβής.

Θα ήθελα να ευχαριστήσω την Ιωάννα, για την ψυχολογική στήριξη και την υπομονή της σε όλη τη διάρκεια εκπόνησης της διδακτορικής μου διατριβής.

Το μεγαλύτερο ευχαριστώ στην οικογένεια μου, στους γονείς μου Μαρία και Κωνσταντίνο και στην αδερφή μου Μάρθα, για την υποστήριξη και την εμπιστοσύνη τους σε μένα, δίνοντάς μου την απαραίτητη δύναμη να συνεχίσω με στοχοπροσήλωση και σιγουριά την εκπόνηση της διδακτορικής διατριβής μου.

## Κατάλογος Πινάκων

|                                                                                                                                                                                                           |     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>Πίνακας 3.1</b> Ανάλυση εποχικότητας και ακρίβεια πρόβλεψης με βάση τις καθημερινές διακυμάνσεις του καιρού για μετρητικό σφάλματος MAPE.....                                                          | 71  |
| <b>Πίνακας 3.2</b> Ποσοστιαία ανάλυση βελτίωσης του μετρητικού σφάλματος MAPE με βάση το υβριδικό μοντέλο 2, ως προς τα υπόλοιπα μοντέλα σύγκρισης, με βάση τις καθημερινές διακυμάνσεις του καιρού.....  | 71  |
| <b>Πίνακας 3.3</b> Ποσοστιαία ανάλυση βελτίωσης του μετρητικού σφάλματος MAPE με βάση το υβριδικό μοντέλο 1, ως προς τα υπόλοιπα μοντέλα σύγκρισης, με βάση τις καθημερινές διακυμάνσεις του καιρού.....  | 72  |
| <b>Πίνακας 3.4</b> Ανάλυση εποχικότητας και ακρίβεια πρόβλεψης με βάση τις καθημερινές διακυμάνσεις του καιρού για το μετρητικό σφάλματος nRMSE. ....                                                     | 72  |
| <b>Πίνακας 3.5</b> Ποσοστιαία ανάλυση βελτίωσης του μετρητικού σφάλματος nRMSE με βάση το υβριδικό μοντέλο 2, ως προς τα υπόλοιπα μοντέλα σύγκρισης, με βάση τις καθημερινές διακυμάνσεις του καιρού..... | 73  |
| <b>Πίνακας 3.6</b> Ποσοστιαία ανάλυση βελτίωσης του μετρητικού σφάλματος nRMSE με βάση το υβριδικό μοντέλο 1, ως προς τα υπόλοιπα μοντέλα σύγκρισης, με βάση τις καθημερινές διακυμάνσεις του καιρού..... | 73  |
| <b>Πίνακας 3.7</b> Ανάλυση εποχικότητας και ακρίβειας πρόβλεψης με βάση τις καθημερινές διακυμάνσεις του καιρού για μετρητικό σφάλματος MAPE.....                                                         | 77  |
| <b>Πίνακας 4.1</b> Γενικός τύπος δεδομένων που χρησιμοποιείται στην πρόβλεψη αιολικής παραγωγής, βάσει της βιβλιογραφικής ανασκόπησης του Κεφαλαίου 2. ....                                               | 82  |
| <b>Πίνακας 4.2</b> Γενικός τύπος δεδομένων που χρησιμοποιείται στην πρόβλεψη φωτοβολταϊκής παραγωγής, βάσει της βιβλιογραφικής ανασκόπησης του Κεφαλαίου 2. ....                                          | 85  |
| <b>Πίνακας 4.3</b> Ανάλυση τύπων δεδομένων που περιέχονται στην πρόβλεψη φωτοβολταϊκής παραγωγής, βάσει της βιβλιογραφικής ανασκόπησης του Κεφαλαίου 2. ....                                              | 85  |
| <b>Πίνακας 5.1</b> Βέλτιστες τιμές των υπερπαραμέτρων του προτεινόμενου μοντέλου WT-LUBE-PSO-CWC. ....                                                                                                    | 108 |
| <b>Πίνακας 5.2</b> Βέλτιστες τιμές των υπερπαραμέτρων του μοντέλου BELM.....                                                                                                                              | 108 |
| <b>Πίνακας 5.3</b> Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 1, για το καλοκαίρι του 2012, για διάστημα εμπιστοσύνης 90%.....                                                        | 109 |
| <b>Πίνακας 5.4</b> Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 1, για το φθινόπωρο του 2012, για διάστημα εμπιστοσύνης 90%. ....                                                       | 109 |
| <b>Πίνακας 5.5</b> Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 1, για τον χειμώνα του 2012/2013, για διάστημα εμπιστοσύνης 90%.....                                                    | 110 |
| <b>Πίνακας 5.6</b> Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 1, για την άνοιξη του 2013, για διάστημα εμπιστοσύνης 90%. ....                                                         | 110 |
| <b>Πίνακας 5.7</b> Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 7, για το καλοκαίρι του 2012, για διάστημα εμπιστοσύνης 90%.....                                                        | 110 |

|                                                                                                                                                                                                                                                            |     |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>Πίνακας 5.8</b> Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 7, για το φθινόπωρο του 2012, για διάστημα εμπιστοσύνης 90%. .....                                                                                                       | 111 |
| <b>Πίνακας 5.9</b> Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 7, για τον χειμώνα του 2012/2013, για διάστημα εμπιστοσύνης 90%.....                                                                                                     | 111 |
| <b>Πίνακας 5.10</b> Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 7, για την άνοιξη του 2013, για διάστημα εμπιστοσύνης 90%. .....                                                                                                        | 111 |
| <b>Πίνακας 5.11</b> Αποτελέσματα αξιολόγησης για τις Ζώνες 1 και 7, για το καλοκαίρι και το φθινόπωρο του 2012, για διάστημα εμπιστοσύνης 85%. .....                                                                                                       | 112 |
| <b>Πίνακας 5.12</b> Αποτελέσματα αξιολόγησης για τις Ζώνες 1 και 7, για το χειμώνα του 2012/2013 έως την άνοιξη του 2013, για διάστημα εμπιστοσύνης 85%.....                                                                                               | 113 |
| <b>Πίνακας 5.13</b> Αποτελέσματα αξιολόγησης για τις Ζώνες 1 και 7, για το καλοκαίρι και το φθινόπωρο του 2012, για διάστημα εμπιστοσύνης 95%. .....                                                                                                       | 113 |
| <b>Πίνακας 5.14</b> Αποτελέσματα αξιολόγησης για τις Ζώνες 1 και 7, για το χειμώνα του 2012/2013 έως την άνοιξη του 2013, για διάστημα εμπιστοσύνης 95%.....                                                                                               | 113 |
| <b>Πίνακας 5.15</b> Συνολική σύγκριση μοντέλων WT-LUBE-PSO-CWC και BELM για κάθε περίπτωση κάθε ζώνης. ....                                                                                                                                                | 115 |
| <b>Πίνακας 5.16</b> Αποτελέσματα αξιολόγησης μοντέλων WT-LUBE-PSO-CWC, LUBE-PSO-CWC και BELM, για ετήσια σύνολα δεδομένων, για τις Ζώνες 1 και 7. ....                                                                                                     | 115 |
| <b>Πίνακας 5.17</b> Μέση τιμή και τυπική απόκλιση του CWC για κάθε εποχή και για τα δυο μοντέλα, WT-LUBE-PSO-CWC και BELM και για τις 2 Ζώνες έρευνας. ....                                                                                                | 117 |
| <b>Πίνακας 5.18</b> Μέσος αριθμός παρατηρήσεων χαμηλότερα από το κάτω όριο και υψηλότερα από το άνω όριο των διαστημάτων πρόβλεψης, για το καλοκαίρι και το φθινόπωρο του 2012 και για τις 2 Ζώνες έρευνας, για διάστημα εμπιστοσύνης 90%.....             | 118 |
| <b>Πίνακας 5.19</b> Μέσος αριθμός παρατηρήσεων χαμηλότερα από το κάτω όριο και υψηλότερα από το άνω όριο των διαστημάτων πρόβλεψης, για το χειμώνα του 2012/2013 έως την άνοιξη του 2013 και για τις 2 Ζώνες έρευνας, για διάστημα εμπιστοσύνης 90%. ..... | 118 |
| <b>Πίνακας 6.1</b> Βέλτιστες τιμές των υπερπαραμέτρων του προτεινόμενου μοντέλου WT-LUBE-PSO-CWC. ....                                                                                                                                                     | 134 |
| <b>Πίνακας 6.2</b> Ελαχιστοποίηση του CWC από επτά διαφορετικά μοντέλα για το ΦΒ Πάρκο1. ....                                                                                                                                                              | 134 |
| <b>Πίνακας 6.3</b> Σύγκριση του CWC έξι μοντέλων, σε σχέση με το CWC του προτεινόμενου μοντέλου Boot-LSTM-ICSO-PP, για το ΦΒ Πάρκο 1. ....                                                                                                                 | 135 |
| <b>Πίνακας 6.4</b> Ελαχιστοποίηση του CWC από επτά διαφορετικά μοντέλα για το ΦΒ Πάρκο2. ....                                                                                                                                                              | 136 |
| <b>Πίνακας 6.5</b> Σύγκριση του CWC έξι μοντέλων, σε σχέση με το CWC του προτεινόμενου μοντέλου Boot-LSTM-ICSO-PP, για το ΦΒ Πάρκο 2. ....                                                                                                                 | 137 |
| <b>Πίνακας 6.6</b> Συγκριτικά αποτελέσματα κατασκευής διαστημάτων πρόβλεψης. ....                                                                                                                                                                          | 139 |
| <b>Πίνακας 6.7</b> Σύγκριση των τιμών τεσσάρων μετρητικών σφάλματος για την κατασκευή των διαστημάτων πρόβλεψης που υπολογίζονται από έξι διαφορετικές μεθόδους, σε                                                                                        |     |

σχέση με τις τιμές αυτών των τεσσάρων μετρητικών σφάλματος που  
υπολογίζονται από το προτεινόμενο μοντέλο Boot-LSTM-ICSO-PP..... 140

**Πίνακας 6.8** Πολυπλοκότητα μοντέλου πρόβλεψης και βελτιστοποίηση των υπερπαραμέτρων  
και του υπολογιστικού κόστους του μοντέλου..... 142



## Κατάλογος Σχημάτων

|                                                                                                                                                                                                                               |     |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>Σχήμα 1.1</b> Δομή παρούσας διδακτορικής διατριβής. ....                                                                                                                                                                   | 28  |
| <b>Σχήμα 2.1</b> Καθαρές προσθήκες παραγόμενης ηλεκτρικής ενέργειας από ΑΠΕ [2]. ....                                                                                                                                         | 32  |
| <b>Σχήμα 3.1</b> Αποτύπωση τυπικού νευρώνα τεχνητού νευρωνικού δικτύου.....                                                                                                                                                   | 54  |
| <b>Σχήμα 3.2</b> Τυπικό πολυεπίπεδο Perceptron.....                                                                                                                                                                           | 55  |
| <b>Σχήμα 3.3</b> Απλοποιημένη σχηματική απεικόνιση αναδρομικού νευρωνικού δικτύου.....                                                                                                                                        | 56  |
| <b>Σχήμα 3.4</b> Συναρτήσεις ενεργοποίησης, (α) σιγμοειδής συνάρτηση, (β) συνάρτηση υπερβολικής εφαπτομένης, (γ) συνάρτηση ReLU.....                                                                                          | 58  |
| <b>Σχήμα 3.5</b> Σχηματική απεικόνιση της αρχιτεκτονικής: (α) του υβριδικού μοντέλου με εξαγωγή μέσης τιμής προβλέψεων και (β) του υβριδικού μοντέλου με χρήση προβλέψεων ARIMA ως είσοδο του LSTM (λέξεις στα ελληνικά)..... | 69  |
| <b>Σχήμα 3.6</b> Πίνακας συσχέτισης για πρόβλεψη ΦΒ ενέργειας (παράδειγμα ηλιόλουστης ημέρας). ....                                                                                                                           | 70  |
| <b>Σχήμα 3.7</b> Παράδειγμα πραγματικών και προβλεπόμενων καμπυλών παραγωγής ΦΒ ενέργειας για (α) υβριδικό μοντέλο (1) και (β) υβριδικό μοντέλο (2). ....                                                                     | 75  |
| <b>Σχήμα 3.8</b> Μέσες τιμές MAPE για τα συγκριτικά μοντέλα για κάθε μήνα του έτους. ....                                                                                                                                     | 76  |
| <b>Σχήμα 4.1</b> Παγκόσμιες κλιματικές ζώνες βάσει της ταξινόμησης Köppen–Geiger. ....                                                                                                                                        | 83  |
| <b>Σχήμα 4.2</b> Ευρωπαϊκός χάρτης άμεσης κανονικής ακτινοβολίας. ....                                                                                                                                                        | 86  |
| <b>Σχήμα 4.3</b> Ευρωπαϊκός χάρτης παραγόμενης ηλιακής ενέργειας. ....                                                                                                                                                        | 87  |
| <b>Σχήμα 5.1</b> Συσχέτιση μεταξύ της ταχύτητας του ανέμου και της διεύθυνσης του ανέμου με τις ζωνικές και μεσημβρινές συνιστώσες τους. ....                                                                                 | 100 |
| <b>Σχήμα 5.2</b> Διαδικασία αποσύνθεσης μετασχηματισμού κυματιδίων του αρχικού σήματος. ...                                                                                                                                   | 101 |
| <b>Σχήμα 5.3</b> Αναπαράσταση ενός νευρωνικού δικτύου που χρησιμοποιείται στη μεθοδολογία LUBE για την κατασκευή του κάτω και άνω ορίου. ....                                                                                 | 102 |
| <b>Σχήμα 5.4</b> Διάγραμμα ροής της διαδικασίας αρχικοποίησης του Yam-Chow.....                                                                                                                                               | 104 |
| <b>Σχήμα 5.5</b> Πλήρες διάγραμμα ροής της προτεινόμενης μεθοδολογίας WT-LUBE-PSO-CWC. ....                                                                                                                                   | 106 |
| <b>Σχήμα 5.6</b> Διαστήματα πρόβλεψης κατασκευασμένα από το προτεινόμενο μοντέλο WT-LUBE-PSO-CWC, για το φθινοπωρινό σύνολο δεδομένων 2012 για τη Ζώνη 7.....                                                                 | 114 |
| <b>Σχήμα 5.7</b> Διαστήματα πρόβλεψης κατασκευασμένα από το προτεινόμενο μοντέλο BELM, για το φθινοπωρινό σύνολο δεδομένων 2012 για τη Ζώνη 7. ....                                                                           | 114 |
| <b>Σχήμα 5.8</b> Μέση τιμή της διάμεσης τιμής CWC μεταξύ WT-LUBE-PSO-CWC και BELM για κάθε εποχή στις ζώνες 1 και 7. ....                                                                                                     | 117 |
| <b>Σχήμα 6.1</b> Απεικόνιση τυπικών καμπυλών παραγωγής φωτοβολταϊκής ενέργειας για ημέρες με ήλιο, ελαφρά σύννεφα και βαριά σύννεφα. Παράδειγμα από ΦΒ Πάρκο1.....                                                            | 124 |
| <b>Σχήμα 6.2</b> Τυπική αρχιτεκτονική κελιού LSTM.....                                                                                                                                                                        | 125 |

|                                                                                                                                                                                                                                                                                                                                                                                                                                |     |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>Σχήμα 6.3</b> Αρχιτεκτονική προτεινόμενου μοντέλου πρόβλεψης και αλληλεπίδραση μεταξύ των σταδίων. ....                                                                                                                                                                                                                                                                                                                     | 132 |
| <b>Σχήμα 6.4</b> Αναπαράστασης παλινδρόμησης αιτιοκρατικής πρόβλεψης για: (α) μια ηλιόλουστη ημέρα, (β) μια ημέρα με ελαφριά συννεφιά και (γ) μια βαριά συννεφιασμένη ημέρα, για το ΦΒ Πάρκο1 και (δ) μια ηλιόλουστη ημέρα, (ε) μια ημέρα με ελαφριά συννεφιά και (στ) μια βαριά συννεφιασμένη ημέρα, για το ΦΒ Πάρκο2.....                                                                                                    | 138 |
| <b>Σχήμα 6.5</b> Απεικόνιση κατασκευασμένων διαστημάτων πρόβλεψης και προβλεπόμενης απόδοσης ισχύος επόμενης ημέρας για: (α) μια ηλιόλουστη ημέρα, (β) μια ημέρα με ελαφριά συννεφιά και (γ) μια βαριά συννεφιασμένη ημέρα, για το φωτοβολταϊκό πάρκο1 και (δ) μια ηλιόλουστη ημέρα, (ε) μια ημέρα με ελαφριά συννεφιά και (στ) μια βαριά συννεφιασμένη ημέρα, για το ΦΒ πάρκο2. Σύγκριση με πραγματικές καμπύλες ισχύος. .... | 141 |
| <b>Σχήμα 6.6</b> Απεικόνιση της διαμόρφωσης του χρόνου εκπαίδευσης όσον αφορά την υπολογιστική απόδοση και την ελαχιστοποίηση της CWC για: (α) ΦΒ Πάρκο 1 και (β) ΦΒ Πάρκο 2. ....                                                                                                                                                                                                                                             | 143 |

## **Ακρωνύμια και Συντομογραφίες**

### **Ελληνικά Ακρωνύμια και Συντομογραφίες**

|     |                             |
|-----|-----------------------------|
| ΑΠΕ | Ανανεώσιμες Πηγές Ενέργειας |
| ΝΔ  | Νευρωνικό Δίκτυο            |
| TN  | Τεχνητή Νοημοσύνη           |
| TNΔ | Τεχνητά Νευρωνικά Δίκτυα    |
| ΦΒ  | Φωτοβολταϊκό                |

### **Αγγλικά Ακρωνύμια και Συντομογραφίες**

|       |                                                       |
|-------|-------------------------------------------------------|
| BELM  | Bootstrap Extreme Learning Machine                    |
| CRPS  | Continuous Ranked Probability Score                   |
| CSO   | Chicken Swarm Optimization                            |
| CWC   | Coverage Width Criterion                              |
| ICSO  | Improved Chicken Swarm Optimization                   |
| LSTM  | Long Short-Term Memory                                |
| LUBE  | Lower Upper Bound Estimation                          |
| MAE   | Mean Absolute Error                                   |
| MAPE  | Mean Absolute Percentage Error                        |
| MSE   | Mean Squared Error                                    |
| NWP   | Numerical Weather Predictions                         |
| PICP  | Prediction Interval Coverage Probability              |
| PINAW | Prediction Interval Normalized Average Width          |
| PINC  | Prediction Interval Nominal Coverage                  |
| PINRW | Prediction Interval Normalized Root mean square Width |
| PP    | Prey-Predator                                         |
| PSO   | Particle Swarm Optimization                           |
| RMSE  | Root Mean Square Error                                |
| WT    | Wavelet Transform                                     |



## Περιεχόμενα

|                                                                                                     |           |
|-----------------------------------------------------------------------------------------------------|-----------|
| Περίληψη .....                                                                                      | 7         |
| Abstract.....                                                                                       | 9         |
| Πρόλογος.....                                                                                       | 11        |
| Κατάλογος Πινάκων.....                                                                              | 13        |
| Κατάλογος Σχημάτων .....                                                                            | 17        |
| Ακρωνύμια και Συντομογραφίες .....                                                                  | 19        |
| ΕΙΣΑΓΩΓΗ.....                                                                                       | 25        |
| 1.1 Η σημασία της αξιοποίησης των Ανανεώσιμων Πηγών Ενέργειας στο ενεργειακό δίκτυο.....            | 25        |
| 1.2 Αντικείμενο της διδακτορικής διατριβής.....                                                     | 26        |
| 1.3 Δομή της διδακτορικής διατριβής.....                                                            | 27        |
| <b>ΠΡΟΒΛΕΨΗ ΠΑΡΑΓΩΓΗΣ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ ΑΠΟ ΑΠΕ.....</b>                                         | <b>31</b> |
| 2.1 Εισαγωγή .....                                                                                  | 31        |
| 2.2 Ο ρόλος της πρόβλεψης ισχύος από ΑΠΕ στα σύγχρονα συστήματα ηλεκτρικής ενέργειας.....           | 33        |
| 2.3 Συμβολή στη διδακτορική διατριβή .....                                                          | 34        |
| 2.4 Πρόβλεψη παραγωγής ηλιακής και αιολικής ισχύος.....                                             | 35        |
| 2.4.1 Παραγωγή ΦΒ ισχύος .....                                                                      | 36        |
| 2.4.2 Παραγωγή αιολικής ισχύος .....                                                                | 38        |
| 2.4.3 Μετεωρολογικοί παράγοντες και η επίδρασή τους στην παραγωγή ΦΒ και αιολικής ισχύος.....       | 39        |
| 2.5 Μέθοδοι πρόβλεψης παραγωγής από ΑΠΕ .....                                                       | 40        |
| 2.5.1 Αιτιοκρατική πρόβλεψη .....                                                                   | 40        |
| 2.5.2 Πιθανοτική πρόβλεψη .....                                                                     | 45        |
| 2.6 Εξέλιξη μελλοντικής έρευνας και εστίαση της πρόβλεψης αιολικής και φωτοβολταϊκής ενέργειας..... | 49        |
| 2.6.1 Βελτιστοποίηση της ακρίβειας υπαρχόντων μοντέλων προόβλεψης.....                              | 49        |
| 2.6.2 Πιθανοτική πρόβλεψη και αξιοποίηση της σε προβλήματα λήψης αποφάσεων..                        | 50        |
| 2.6.3 Χωροχρονικά μοντέλα πρόβλεψης.....                                                            | 50        |
| 2.6.4 Αποδοτική χρήση και αξιοποίηση των μεθόδων βαθιάς μάθησης .....                               | 50        |
| 2.6.5 Βελτίωση της επιλογής και ανάλυσης των δεδομένων εισόδου.....                                 | 51        |
| 2.6.6 Μοντέλα εκτίμησης νεφοκάλυψης στη φωτοβολταϊκή παραγωγή. ....                                 | 51        |
| 2.6.7 Ευελιξία και προσαρμοστικότητα των μοντέλων πρόβλεψης.....                                    | 51        |

|                                                                                                     |           |
|-----------------------------------------------------------------------------------------------------|-----------|
| 2.6.8 Προστασία δεδομένων.....                                                                      | 52        |
| <b>ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ.....</b>                                                                | <b>53</b> |
| 3.1 Εισαγωγή.....                                                                                   | 53        |
| 3.2 Αρχιτεκτονική τεχνητών νευρωνικών δικτύων.....                                                  | 54        |
| 3.2.1 Τεχνητά νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης ενός επιπέδου (Single-Layer Perceptron)..... | 56        |
| 3.2.2 Πολυεπίπεδα τεχνητά νευρωνικά δίκτυα (Multi-Layer Perceptron).....                            | 56        |
| 3.2.3 Αναδρομικά νευρωνικά δίκτυα.....                                                              | 57        |
| 3.3 Συναρτήσεις ενεργοποίησης.....                                                                  | 57        |
| 3.4 Εκπαίδευση τεχνητών νευρωνικών δικτύων.....                                                     | 59        |
| 3.4.1 Επιτηρούμενη εκπαίδευση.....                                                                  | 59        |
| 3.4.2 Μη επιτηρούμενη εκπαίδευση.....                                                               | 59        |
| 3.5 Αντικειμενική συνάρτηση.....                                                                    | 60        |
| 3.6 Μετρητικά αξιολόγησης μοντέλων πρόβλεψης.....                                                   | 60        |
| 3.6.1 Αιτιοκρατικά μετρητικά αξιολόγησης.....                                                       | 61        |
| 3.6.2 Πιθανοτικά μετρητικά αξιολόγησης.....                                                         | 64        |
| 3.7 Παράδειγμα μελέτης αποτελεσμάτων υβριδικών μοντέλων με βάση ΤΝΔ.....                            | 68        |
| 3.7.1 Υβριδική προσέγγιση (1).....                                                                  | 68        |
| 3.7.2 Υβριδική προσέγγιση (2).....                                                                  | 69        |
| 3.7.3 Αποτελέσματα.....                                                                             | 70        |
| <b>ΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ ΑΙΟΛΙΚΗΣ ΚΑΙ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ. 79</b>                              |           |
| 4.1 Εισαγωγή.....                                                                                   | 79        |
| 4.2 Συμβολή στη διδακτορική διατριβή.....                                                           | 79        |
| 4.3 Ορίζοντας πρόβλεψης.....                                                                        | 81        |
| Υπερβραχυπρόθεσμη πρόβλεψη.....                                                                     | 81        |
| Βραχυπρόθεσμη πρόβλεψη.....                                                                         | 81        |
| Μεσοπρόθεσμη πρόβλεψη.....                                                                          | 82        |
| Μακροπρόθεσμη πρόβλεψη.....                                                                         | 82        |
| 4.4 Θεωρητικό υπόβαθρο.....                                                                         | 82        |
| 4.4.1 Βραχυπρόθεσμη πρόβλεψη συστημάτων αιολικής παραγωγής.....                                     | 82        |
| 4.4.2 Βραχυπρόθεσμη πρόβλεψη συστημάτων φωτοβολταϊκής παραγωγής.....                                | 83        |
| 4.4.3 Συσχέτιση δυναμικού παραγωγής ενέργειας και μετεωρολογικών συνθηκών. ...                      | 86        |
| 4.5 Βελτιστοποίηση τεχνικών μηχανικής μάθησης.....                                                  | 88        |
| 4.5.1 Αλγόριθμος προς τα πίσω διάδοσης του σφάλματος.....                                           | 89        |
| 4.5.2 Μεταερευρητικοί αλγόριθμοι.....                                                               | 91        |

|                                                                                                                                         |            |
|-----------------------------------------------------------------------------------------------------------------------------------------|------------|
| <b>ΠΙΘΑΝΟΤΙΚΗ ΠΡΟΒΛΕΨΗ ΑΙΟΛΙΚΗΣ ΙΣΧΥΟΣ ΜΕ ΥΒΡΙΔΙΚΗ ΜΕΘΟΔΟ<br/>ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ .....</b>                                               | <b>97</b>  |
| 5.1 Εισαγωγή .....                                                                                                                      | 97         |
| 5.2 Ανάλυση και επεξεργασία αιολικών δεδομένων .....                                                                                    | 98         |
| 5.3 Εκτίμηση κάτω και άνω ορίου του διαστήματος πρόβλεψης με βελτιστοποίηση σμήνους<br>σωματιδίων του κριτηρίου του εύρους κάλυψης..... | 101        |
| 5.3.1 Μέθοδος εκτίμησης κάτω και άνω ορίου (Lower Upper Bound Estimation –<br>LUBE) .....                                               | 102        |
| 5.3.2 Αλγόριθμος σμήνους σωματιδίων (PSO).....                                                                                          | 102        |
| 5.4 Τελικό προτεινόμενο μοντέλο πιθανοτικής πρόβλεψης αιολικής παραγωγής .....                                                          | 103        |
| 5.5 Βελτιστοποίηση υπερπαραμέτρων μοντέλου πρόβλεψης.....                                                                               | 108        |
| 5.6 Εποχική ανάλυση και σύγκριση αποδοτικότητας σφαλμάτων πρόβλεψης .....                                                               | 109        |
| <b>ΠΙΘΑΝΟΤΙΚΗ ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΙΣΧΥΟΣ ΜΕ ΥΒΡΙΔΙΚΗ ΜΕΘΟΔΟ<br/>ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ .....</b>                                          | <b>121</b> |
| 6.1 Εισαγωγή .....                                                                                                                      | 121        |
| 6.2 Ανάλυση και επεξεργασία μετεωρολογικών δεδομένων και δεδομένων φωτοβολταϊκής<br>ισχύος.....                                         | 123        |
| 6.3 Πρώιμο προτεινόμενο μοντέλο μηχανικής μάθησης.....                                                                                  | 124        |
| 6.3.1 Νευρωνικά δίκτυα μακράς βραχυπρόθεσμης μνήμης (LSTM).....                                                                         | 124        |
| 6.3.2 Μέθοδος επαναδειγματοληψίας Bootstrap.....                                                                                        | 126        |
| 6.3.3 Αλγόριθμος σμήνους κοτόπουλων (CSO).....                                                                                          | 126        |
| 6.4 Εισαγωγή μηχανισμού θηράματος-θηρευτή.....                                                                                          | 128        |
| 6.5 Τελικό προτεινόμενο μοντέλο πιθανοτικής πρόβλεψης φωτοβολταϊκής ισχύος.....                                                         | 128        |
| 6.5.1 Μοντέλο Bootstrap-LSTM.....                                                                                                       | 128        |
| 6.5.2 Βελτιωμένος αλγόριθμος σμήνους κοτόπουλων (ICSO) .....                                                                            | 129        |
| 6.5.3 Αρχιτεκτονική προτεινόμενου μοντέλου Boot-LSTM-ICSO-PP.....                                                                       | 130        |
| 6.6 Βελτιστοποίηση υπερπαραμέτρων μοντέλου πρόβλεψης.....                                                                               | 133        |
| 6.7 Εποχική ανάλυση και σύγκριση αποδοτικότητας σφαλμάτων πρόβλεψης .....                                                               | 135        |
| <b>ΣΥΜΠΕΡΑΣΜΑΤΑ.....</b>                                                                                                                | <b>145</b> |
| 7.1 Σύνοψη της διδακτορικής διατριβής.....                                                                                              | 145        |
| 7.2 Συμβολή της διδακτορικής διατριβής.....                                                                                             | 146        |
| 7.3 Μελλοντικές επεκτάσεις.....                                                                                                         | 147        |
| <b>Δημοσιεύσεις του Συγγραφέα.....</b>                                                                                                  | <b>149</b> |
| <b>Βιβλιογραφία .....</b>                                                                                                               | <b>151</b> |



# Κεφάλαιο 1

## ΕΙΣΑΓΩΓΗ

### 1.1 Η σημασία της αξιοποίησης των Ανανεώσιμων Πηγών Ενέργειας στο ενεργειακό δίκτυο

Δύο από τα σημαντικότερα προβλήματα του σύγχρονου κόσμου είναι η συνεχής αλλαγή των κλιματικών συνθηκών που οδηγεί στην υπερθέρμανση του πλανήτη και η ικανοποίηση των συνεχώς αυξανόμενων παγκόσμιων ενεργειακών αναγκών. Η αποτελεσματική χρήση των Ανανεώσιμων Πηγών Ενέργειας (ΑΠΕ) έχει αποδειχθεί ότι είναι μία από τις λύσεις σε αυτά τα προβλήματα. Επειδή οι ΑΠΕ παρέχουν μια «πράσινη» εναλλακτική λύση στην παραγωγή ηλεκτρικής ενέργειας για συμβατικές πηγές ενέργειας (άνθρακας, πετρέλαιο), υπήρξε ο κύριος στόχος των ερευνητών τα τελευταία χρόνια να αναπτύξουν μεθοδολογίες για την αποτελεσματική αξιοποίηση των ΑΠΕ.

Επειδή ο ήλιος είναι μια ανεξάντλητη πηγή ενέργειας, η ηλιακή ενέργεια είναι μία από τις πιο εκμεταλλεύσιμες και σημαντικότερες ανανεώσιμες πηγές ενέργειας. Αντίστοιχα, η αιολική ενέργεια, χάρη στον ευρέως κατανοημένο χαρακτήρα της, είναι μία από τις ευκολότερα εκμεταλλεύσιμες και σημαντικότερες ανανεώσιμες πηγές ενέργειας. Λόγω της συνεχούς έρευνας και της προόδου της τεχνολογίας, τόσο η αιολική ενέργεια, ως ανανεώσιμη πηγή ενέργειας, όσο και η ηλιακή ενέργεια, μέσω ηλιακών φωτοβολταϊκών συστημάτων, διαδραματίζουν κρίσιμο ρόλο στα παγκόσμια ενεργειακά συστήματα καθώς και στις παγκόσμιες αγορές ενέργειας.

Εστιάζοντας στην ηλιακή ενέργεια ως σημαντικό μέρος των σημερινών συστημάτων παραγωγής ενέργειας, ενδέχεται να προκύψουν διάφορα προβλήματα σχετικά με τον τρόπο σωστής ενσωμάτωσης της στα ενεργειακά συστήματα. Η φωτοβολταϊκή παραγωγή συνδέεται άμεσα με την ποσότητα της προσπίπτουσας ηλιακής ακτινοβολίας στους φωτοβολταϊκούς συλλέκτες. Ωστόσο, η ηλιακή ακτινοβολία περιορίζεται από διάφορους παράγοντες. Ο πρώτος παράγοντας είναι ο ίδιος ο χρόνος, δεδομένου ότι η ηλιακή ενέργεια μπορεί να ληφθεί μόνο κατά τη διάρκεια της ημέρας. Επιπλέον, η κατανομή της ηλιακής ακτινοβολίας δεν μπορεί να είναι ομοιόμορφη, όχι μόνο σε παγκόσμιο αλλά και σε τοπικό επίπεδο. Επιπλέον, η φωτοβολταϊκή παραγωγή εξαρτάται από διάφορους μετεωρολογικούς παράγοντες, όπως η θερμοκρασία στην ατμόσφαιρα και στους φωτοβολταϊκούς συλλέκτες, η ταχύτητα και η διεύθυνση του ανέμου, η υγρασία και η νεφοκάλυψη.

Εστιάζοντας στην αιολική ενέργεια ως σημαντικό μέρος των σημερινών συστημάτων παραγωγής ηλεκτρικής ενέργειας, λόγω της στοχαστικής και της διαλείπουσας φύσης του

ανέμου προκύπτουν πολυάριθμα προβλήματα στη λειτουργία και τον προγραμματισμό τους αλλά και στη διαδικασία λήψης αποφάσεων.

Για την αντιμετώπιση αυτών των προβλημάτων, έχουν αναπτυχθεί διάφορα μοντέλα πρόβλεψης παραγωγής ενέργειας τόσο από αιολικά όσο και από φωτοβολταϊκά συστήματα. Τις τελευταίες δεκαετίες, έχουν ερευνηθεί πολυάριθμες μεθοδολογίες πρόβλεψης, προκειμένου να διευκολυνθεί ο έλεγχος της συνεχούς αύξησης της διείσδυσης της αιολικής και ηλιακής ενέργειας στα παγκόσμια ενεργειακά συστήματα. Επιπλέον, τέτοια μοντέλα πρόβλεψης βοηθούν στον προγραμματισμό των συστημάτων ηλεκτρικής ενέργειας και στη διατήρηση της ευστάθειας και της αξιοπιστίας τους, και της αποδοτικότερης αξιοποίησης των ΑΠΕ στις αγορές ηλεκτρικής ενέργειας. Τα βραχυπρόθεσμα μοντέλα πρόβλεψης βρίσκονται στο επίκεντρο της προσοχής για τους περισσότερους ερευνητές, λαμβάνοντας υπόψη τη σημασία τους στον σχεδιασμό και τη λειτουργία των ημερήσιων αγορών ηλεκτρικής ενέργειας και στη διαχείριση των ενεργειακών συστημάτων. Τα ακριβή μοντέλα πρόβλεψης μπορούν να μειώσουν την ανάγκη για εφεδρική παραγωγή, να μειώσουν το κόστος ηλεκτρικής ενέργειας και να διασφαλίσουν ότι το ηλεκτρικό δίκτυο λειτουργεί με αξιόπιστο και αποτελεσματικό τρόπο. Με την ενσωμάτωση βραχυπρόθεσμων προβλέψεων αιολικής και ηλιακής ενέργειας σε εφαρμογές σε πραγματικό χρόνο για την παραγωγή ηλεκτρικής ενέργειας και τη διαχείριση του δικτύου, οι διαχειριστές συστημάτων μπορούν να προγραμματίσουν με βέλτιστο τρόπο την διείσδυση των ανανεώσιμων πηγών ενέργειας, να μειώσουν την ανάγκη για σταθμούς ηλεκτροπαραγωγής με βάση τα ορυκτά καύσιμα για να καλύψουν την αιχμή της ζήτησης και να βελτιώσουν την αξιοπιστία και την ευστάθεια του συστήματος ηλεκτρικής ενέργειας.

## 1.2 Αντικείμενο της διδακτορικής διατριβής

Η συνεχής ανάπτυξη και εξέλιξη των αλγορίθμων πρόβλεψης παραγόμενης ισχύος αποτελεί μονόδρομο στην ανάγκη κάλυψης της αυξανόμενης διείσδυσης των ΑΠΕ στο δίκτυο.

Τα συμβατικά μοντέλα πρόβλεψης που χρησιμοποιούνται σε πραγματικές συνθήκες, είναι αιτιοκρατικά μοντέλα πρόβλεψης, τα οποία προτείνουν σημειακές εκτιμήσεις της εξέλιξης της καμπύλης παραγωγής ενέργειας. Παρόλα αυτά, τέτοια μοντέλα πρόβλεψης δεν παρέχουν πλήρη πληροφορία της αβεβαιότητας που εμπεριέχεται στη διαδικασία πρόβλεψης. Για να καλυφθεί η παραπάνω ανάγκη, τα τελευταία χρόνια αναπτύσσονται πιθανοτικά μοντέλα πρόβλεψης, τα οποία έχουν τη δυνατότητα να προσφέρουν μια ευρύτερη εικόνα της εξέλιξης των προβλέψεων παραγόμενης ισχύος υπό μορφή διαστημάτων πρόβλεψης, ή και, συνδυαζόμενα με αιτιοκρατικά μοντέλα, να προσφέρουν μια πλήρη οπτική της εκτιμώμενης πορείας της καμπύλης πρόβλεψης.

Στο πλαίσιο της παρούσας διδακτορικής διατριβής προτείνονται καινοτόμες μέθοδοι βραχυπρόθεσμης, πιθανοτικής πρόβλεψης παραγωγής από αιολικά και φωτοβολταϊκά συστήματα βασισμένες σε τεχνικές μηχανικής μάθησης. Επιπλέον, αξιοποιούνται μεταερευνητικοί αλγόριθμοι βελτιστοποίησης προκειμένου να βελτιωθεί περαιτέρω η ακρίβεια πρόβλεψης των προτεινόμενων μοντέλων. Ουσιαστικός στόχος της παρούσας διδακτορικής διατριβής είναι η ανάπτυξη μοντέλων πρόβλεψης ικανών να συνδυάζουν υψηλής ποιότητας προβλέψεις παραγόμενης ισχύος, διατηρώντας παράλληλα χαμηλά το υπολογιστικό κόστος του μοντέλου.

Πιο συγκεκριμένα, στην παρούσα διδακτορική διατριβή αναπτύσσεται ένα καινοτόμο μοντέλο βραχυπρόθεσμης πρόβλεψης αιολικής παραγωγής βασισμένο στη μέθοδο LUBE προκειμένου να παρέχει αποτελεσματικά και ακριβή διαστήματα πρόβλεψης αιολικής ενέργειας. Ο αλγόριθμος PSO προτάθηκε για τη διαδικασία βελτιστοποίησης, ενώ ο μετασχηματισμός κυματιδίων υιοθετήθηκε για την εκτέλεση της προεπεξεργασίας των δεδομένων εισόδου.

Επίσης, στην παρούσα διδακτορική διατριβή αναπτύσσεται ένα καινοτόμο, υβριδικό, πιθανοτικό μοντέλο πρόβλεψης φωτοβολταϊκής παραγωγής βασισμένο στο μοντέλο LSTM προκειμένου να κατασκευαστούν αποτελεσματικά, ακριβή διαστήματα πρόβλεψης. Η ικανότητα αναδειγματοληψίας του μηχανισμού Bootstrap αλλά και το πλεονέκτημα του LSTM να συλλαμβάνει τις διαδοχικές εξαρτήσεις αξιοποιήθηκαν για την κατασκευή διαστημάτων πρόβλεψης υψηλής ακρίβειας. Το μοντέλο εκπαιδεύτηκε και βελτιστοποιήθηκε περαιτέρω μέσω μιας βελτιωμένης έκδοσης (ICSO) του αλγορίθμου CSO. Η συμπερίληψη του ICSO επέτρεψε την ταχύτερη και ακριβέστερη σύγκλιση του μοντέλου και, ως εκ τούτου, την υψηλότερη ακρίβεια συνολικά. Επιπλέον, ένας μηχανισμός θηράματος-θηρευτή συμπεριλήφθηκε και προσαρμόστηκε στην αρχιτεκτονική του μοντέλου, προκειμένου να διευκολυνθεί η ικανότητα αναζήτησης των σωματιδίων ICSO, να βελτιωθεί η προγνωστική ακρίβεια και να μειωθεί το υπολογιστικό κόστος.

### 1.3 Δομή της διδακτορικής διατριβής

Στο Κεφάλαιο 2, αρχικά, περιγράφονται τα βασικά χαρακτηριστικά και ο ρόλος της πρόβλεψης παραγωγής ηλεκτρικής ενέργειας από ΑΠΕ. Στη συνέχεια αναλύονται οι βασικές μεθοδολογίες πρόβλεψης από ΑΠΕ και τα βασικά τους χαρακτηριστικά, ενώ παρουσιάζονται και οι βασικοί παράγοντες που επηρεάζουν την ποιότητα και την αξιοπιστία της πρόβλεψης. Παράλληλα διενεργείται μια εκτεταμένη βιβλιογραφική ανασκόπηση εργασιών τόσο στα πλαίσια της αιτιοκρατικής όσο και της πιθανοτικής πρόβλεψης παραγωγής ενέργειας τόσο από αιολικά όσο και από φωτοβολταϊκά συστήματα.

Στο Κεφάλαιο 3, αρχικά, αναλύονται σε μεγαλύτερο βάθος τα χαρακτηριστικά των τεχνητών νευρωνικών δικτύων καθώς αποτελούν κατά πλειοψηφία τη βάση για τα μοντέλα μηχανικής μάθησης. Ακόμη, αναλύεται η σημασία των συναρτήσεων ενεργοποίησης αλλά και της επιλογής κατάλληλης αντικειμενικής συνάρτησης ανάλογα με το εκάστοτε πρόβλημα πρόβλεψης παραγωγής που μελετάται. Τέλος, γίνεται μια εκτενής αναφορά στα μετρητικά αξιολόγησης τόσο αιτιοκρατικών όσο και πιθανοτικών μοντέλων πρόβλεψης, καθώς διαδραματίζουν καθοριστικό ρόλο στην κατανόηση της ποιότητας και της αξιοπιστίας των αποτελεσμάτων των μοντέλων πρόβλεψης.

Στο Κεφάλαιο 4 εξετάζονται οι βασικές παράμετροι που επιδρούν στην απόδοση και την επίδοση των μοντέλων πρόβλεψης. Αναλύεται η σημασία του ορίζοντα πρόβλεψης τόσο στην κατανόηση του εκάστοτε προβλήματος πρόβλεψης παραγωγής ενέργειας όσο και στην αξιοποίηση της κατάλληλης μεθοδολογίας. Επιπλέον, αξιοποιώντας τη βιβλιογραφική ανασκόπηση που πραγματοποιήθηκε στο Κεφάλαιο 2, εξετάζεται η σημασία των κλιματικών συνθηκών αλλά και του τύπου των δεδομένων που εισάγονται στα μοντέλα πρόβλεψης, στην τελική ποιότητα του σφάλματος πρόβλεψης. Τέλος, παρουσιάζονται οι τεχνικές

|                                                                                                        |
|--------------------------------------------------------------------------------------------------------|
| <b>Κεφάλαιο 1:</b><br>ΕΙΣΑΓΩΓΗ                                                                         |
| <b>Κεφάλαιο 2:</b><br>ΠΡΟΒΛΕΨΗ ΠΑΡΑΓΩΓΗΣ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ<br>ΑΠΟ ΑΠΕ                               |
| <b>Κεφάλαιο 3:</b><br>ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ                                                         |
| <b>Κεφάλαιο 4:</b><br>ΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ ΑΙΟΛΙΚΗΣ ΚΑΙ<br>ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ                   |
| <b>Κεφάλαιο 5:</b><br>ΠΙΘΑΝΟΤΙΚΗ ΠΡΟΒΛΕΨΗ ΑΙΟΛΙΚΗΣ ΙΣΧΥΟΣ ΜΕ<br>ΥΒΡΙΔΙΚΗ ΜΕΘΟΔΟ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ      |
| <b>Κεφάλαιο 6:</b><br>ΠΙΘΑΝΟΤΙΚΗ ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΙΣΧΥΟΣ<br>ΜΕ ΥΒΡΙΔΙΚΗ ΜΕΘΟΔΟ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ |
| <b>Κεφάλαιο 7:</b><br>ΣΥΜΠΕΡΑΣΜΑΤΑ                                                                     |
| ΒΙΒΛΙΟΓΡΑΦΙΑ                                                                                           |

**Σχήμα 1.1** Δομή παρούσας διδακτορικής διατριβής.

βελτιστοποίησης που αξιοποιούνται για τη βέλτιστη προσαρμογή των παραμέτρων των μοντέλων μηχανικής μάθησης.

Στο Κεφάλαιο 5, αρχικά, αναπτύσσεται ένα καινοτόμο, βραχυπρόθεσμο, πιθανοτικό μοντέλο πρόβλεψης αιολικής παραγωγής, το οποίο βασίζεται στη μεθοδολογία LUBE, αξιοποιώντας τη δυνατότητά του να κατασκευάζει αξιόπιστα διαστήματα πρόβλεψης άμεσα με την εκτέλεση του νευρωνικού δικτύου. Στο πλαίσιο αυτό, ενσωματώνεται ένας βελτιωμένος αλγόριθμος βελτιστοποίησης σμήνους σωματιδίων, στοχεύοντας στη βελτιστοποίηση των τιμών των υπερπαραμέτρων του μοντέλου για την αναζήτηση των βέλτιστων λύσεων. Η αρχικοποίηση Yam-Chow προσαρμόζεται ανάλογα για να εφαρμοστεί στην αρχιτεκτονική του νευρωνικού δικτύου, ώστε να επιταχύνει τη βελτιστοποίηση των βαρών και των πολώσεων του νευρωνικού δικτύου. Για την αξιολόγηση του προτεινόμενου μοντέλου πρόβλεψης, τα αποτελέσματα που προκύπτουν συγκρίνονται με το υπερσύγχρονο BELM μοντέλο, αποδεικνύοντας την υπεροχή του προτεινόμενου μοντέλου αλλά και τη δυνατότητα εφαρμογής του σε πραγματικά προβλήματα πρόβλεψης αιολικής παραγωγής.

Στο Κεφάλαιο 6, αρχικά, αναπτύσσεται ένα πρωτότυπο, βραχυπρόθεσμο, υβριδικό, πιθανοτικό μοντέλο πρόβλεψης φωτοβολταϊκής παραγωγής, το οποίο βασίζεται στη μεθοδολογία του νευρωνικού δικτύου LSTM. Στο πλαίσιο αυτό, ενσωματώνεται ένας βελτιωμένος αλγόριθμος βελτιστοποίησης σμήνους κοτόπουλων, στοχεύοντας στη βελτιστοποίηση των τιμών των παραμέτρων του μοντέλου για την αναζήτηση των βέλτιστων λύσεων. Ένας επιπλέον μηχανισμός θηράματος-θηρευτή ενσωματώνεται με στόχο τη διευκόλυνση του μοντέλου να μην παγιδεύεται σε τοπικά βέλτιστα. Για την αξιολόγηση του προτεινόμενου μοντέλου πρόβλεψης, τα αποτελέσματα που προκύπτουν συγκρίνονται με μοντέλα πρόβλεψης τελευταίας τεχνολογίας, αποδεικνύοντας την υπεροχή του προτεινόμενου μοντέλου αλλά και τη δυνατότητα εφαρμογής του σε πραγματικά προβλήματα πρόβλεψης φωτοβολταϊκής παραγωγής.

Στο Κεφάλαιο 7, αρχικά, γίνεται μία ανακεφαλαίωση της διδακτορικής διατριβής. Στη συνέχεια, παρουσιάζονται τα συμπεράσματα και η συμβολή της διδακτορικής διατριβής στον τομέα της ανάπτυξης μοντέλων πρόβλεψης μηχανικής μάθησης με σύνολα δεδομένων αιολικής και φωτοβολταϊκής παραγωγής τα οποία με τη σειρά τους είναι ικανά να συμβάλλουν πρακτικά και ενεργά στη διατήρηση της ευστάθειας του δικτύου ηλεκτρικής ενέργειας και τη βέλτιστη αξιοποίηση της αιολικής και φωτοβολταϊκής παραγωγής στις αγορές ηλεκτρικής ενέργειας.

Τέλος, παρουσιάζονται οι δημοσιεύσεις του συγγραφέα κ. Ι. Μπαζιώνη, καθώς και η βιβλιογραφία της διδακτορικής διατριβής. Η δομή της παρούσας διδακτορικής διατριβής παρουσιάζεται στο Σχήμα 1.1.



# Κεφάλαιο 2


## ΠΡΟΒΛΕΨΗ ΠΑΡΑΓΩΓΗΣ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ ΑΠΟ ΑΠΕ

### 2.1 Εισαγωγή

Η κλιματική αλλαγή, ταυτιζόμενη με την παγκόσμια αύξηση της θερμοκρασίας, αποτελεί ένα από τα σημαντικότερα προβλήματα της σύγχρονης εποχής. Η απομάκρυνση από τις συμβατές πηγές ενέργειας, που κατά βάση χρησιμοποιούν αποθέματα ορυκτών καυσίμων, αποτελεί βασική πρόκληση των σύγχρονων συστημάτων ενέργειας. Τις τελευταίες δεκαετίες, η ανάπτυξη και ενσωμάτωση Ανανεώσιμων Πηγών Ενέργειας (ΑΠΕ) στο ενεργειακό δίκτυο έχει παίξει καίριο ρόλο στην αντιμετώπιση των προβλημάτων της κλιματικής αλλαγής και στην υιοθέτηση βιώσιμων και φιλικών προς το περιβάλλον μεθόδων για την κάλυψη των ενεργειακών αναγκών. Σε αντίθεση με τη χρήση ορυκτών πόρων, η εκμετάλλευση των οποίων απαιτεί καύση και συνεπώς μεγάλη περιβαλλοντική επιβάρυνση, οι ΑΠΕ αξιοποιούν φυσικές πηγές ενέργειας, όπως τον άνεμο, το ηλιακό φως ή την κίνηση του νερού, ώστε να παράγουν ενέργεια.

Η στροφή στις ΑΠΕ τα τελευταία χρόνια, έχει συμβάλει σημαντικά τόσο σε περιβαλλοντικό όσο και σε λειτουργικό επίπεδο. Χάρη στην τεχνολογία εκμετάλλευσής τους, οι εκπομπές αερίων του θερμοκηπίου είναι σημαντικά χαμηλότερες σε σύγκριση με τα συμβατικά ορυκτά καύσιμα, με αποτέλεσμα η χρήση των ΑΠΕ να επεμβαίνει θετικά στην αντιμετώπιση του φαινομένου του θερμοκηπίου με ταυτόχρονη μείωση του αποτυπώματος άνθρακα κατά την παραγωγή ενέργειας. Επιπλέον, προσφέρει τη δυνατότητα συνεχούς εκμετάλλευσης καθώς βασίζεται σε πρακτικά ανεξάντλητες πηγές ενέργειας, σε αντίθεση με τα ορυκτά καύσιμα, τα οποία μειώνονται όλο και περισσότερο κατά τη χρήση τους. Η εκμετάλλευση των ΑΠΕ έχει το πλεονέκτημα ότι μπορεί να γίνει τόσο μέσω δομών μεγάλων παραγωγών ενέργειας όσο και μικρότερων δομών έως και οικιακού επιπέδου. Αυτή η δυνατότητα δίνει έναν απομακρυσμένο και ταυτόχρονα αποκεντρωμένο χαρακτήρα στην παραγωγή ενέργειας από ΑΠΕ, κάνοντάς την πιο προσιτή στον καταναλωτή/παραγωγό αλλά και ταυτόχρονα πιο ελεγχόμενη από το ενεργειακό δίκτυο.

Η εκμετάλλευση και η ενσωμάτωση των ΑΠΕ στα ενεργειακά δίκτυα σε κρατικό και ευρωπαϊκό επίπεδο, έχει δρομολογηθεί και ελέγχεται από την Ευρωπαϊκή Ένωση (ΕΕ). Η τότε ισχύουσα ευρωπαϊκή οδηγία (RED I), η οποία εγκρίθηκε στις 23 Απριλίου 2009, όριζε ότι μέχρι το 2020 ήταν υποχρεωτικό το 20% της κατανάλωσης ενέργειας στην ΕΕ να καλύπτεται από ΑΠΕ [1]. Με βάση το RED I, κάθε κράτος μέλος της ΕΕ, με βάση τις υποδομές και τις δυνατότητές του, σε συνεργασία με την ΕΕ, κλήθηκε να βρει μηχανισμούς επίτευξης των



προσωπικών του ενεργειακών στόχων. Το RED I επιβεβαίωσε τους εθνικούς στόχους των κρατών μελών θέτοντας

**Σχήμα 2.1** Καθαρές προσθήκες παραγόμενης ηλεκτρικής ενέργειας από ΑΠΕ [2].

παράλληλα τις βάσεις και τις υποδομές για την περαιτέρω ανάπτυξη της εκμετάλλευσης των ΑΠΕ για τη δεκαετία 2020-2030. Στις 11 Δεκεμβρίου του 2018, τέθηκε σε ισχύ η αναθεωρημένη οδηγία ΕΕ 2018/2001 του ευρωπαϊκού κοινοβουλίου για την προώθηση της χρήσης ενέργειας από ΑΠΕ, κατά το οποίο, το 32% της κατανάλωσης ενέργειας της ΕΕ θα πρέπει να καλύπτεται από ΑΠΕ μέχρι το 2030 [3]. Στις 14 Ιουλίου 2021, η ευρωπαϊκή επιτροπή προτείνει την τροποποιημένη οδηγία RED II, βάσει της οποίας ο προηγούμενος στόχος του 32% σε κάλυψη ενεργειακών αναγκών από ΑΠΕ ανήλθε πλέον σε 40% έως το 2030 [4]. Στις 18 Μαΐου 2022, μετά την έναρξη της πολεμικής σύρραξης μεταξύ Ρωσίας και Ουκρανίας νωρίτερα τον ίδιο χρόνο, η άμεση εξάρτηση της ΕΕ από το ρωσικό φυσικό αέριο, είχε ως αποτέλεσμα, η ΕΕ να προτείνει την οδηγία RED III στα πλαίσια του ευρωπαϊκού ενεργειακού σχεδίου REPowerEU. Το RED III, προέβλεπε αύξηση του στόχου του 40% σε 45% μέχρι το 2030, με προβλεπόμενη δυναμικότητα παραγωγής ενέργειας από ΑΠΕ στα 1236 GW. Επιπλέον, δείχνοντας μια σαφή τάση προς την ΦΒ παραγωγή, τέθηκε ο στόχος εγκατάστασης νέων ΦΒ ισχύος άνω των 320 GW μέχρι το 2025 και περίπου 600 GW μέχρι το 2030, ενώ χάρη στην ευελιξία της χρήσης της τεχνολογίας των ΦΒ σε στέγες κτιρίων, προτάθηκε η ενίσχυση χρήσης τους, η οποία σε μερικές περιπτώσεις κτιρίων κρίθηκε και υποχρεωτική [5].

Όπως φαίνεται και στο Σχήμα 2.1, τα τελευταία χρόνια παρουσιάζεται ραγδαία αύξηση της ενσωμάτωσης παραγόμενης ηλεκτρικής ενέργειας από ΑΠΕ, κυρίως λόγω της αύξησης αιολικών και φωτοβολταϊκών (ΦΒ) εγκαταστάσεων [2]. Εκτιμάται ότι οι νέες προσθήκες δυνατότητας παραγωγής ενέργειας από ΑΠΕ σε παγκόσμιο επίπεδο θα αυξηθούν κατά περίπου 440 GW το 2023 με το αισιόδοξο σενάριο να προβλέπει ότι μπορεί να αγγίξουν και τα 500 GW. Το 2022, το παγκόσμιο δυναμικό παραγωγής ισχύος από ΑΠΕ έφτασε τα 3382 GW [6], ενώ εκτιμάται ότι μέχρι το 2024 θα ξεπεράσει τα 4500 GW [2].

Είναι εμφανές ότι η παγκόσμια ενεργειακή κοινότητα έχει στραφεί στην όλο και πιο φιλική προς το περιβάλλον αξιοποίηση των φυσικών ενεργειακών πόρων, δίνοντας ιδιαίτερη έμφαση στην αιολική και την ηλιακή ενέργεια. Τα τελευταία χρόνια, τόσο η τεχνολογική βελτίωση των υποδομών απομάστευσης ηλεκτρικής ενέργειας από ΑΠΕ, όσο και η διαχείριση της συνεχώς αυξανόμενης έγχυσής της στα ενεργειακά δίκτυα, έχουν αποτελέσει σημαντικό πόλο μελέτης της ερευνητικής κοινότητας.

## **2.2 Ο ρόλος της πρόβλεψης ισχύος από ΑΠΕ στα σύγχρονα συστήματα ηλεκτρικής ενέργειας**

Ένας από τους βασικότερους προβληματισμούς της χρήσης παραγόμενης ηλεκτρικής ενέργειας από ΑΠΕ είναι η ομαλή ένταξή της στα συστήματα ηλεκτρικής ενέργειας (ΣΗΕ) καθώς και η ελεγχόμενη αξιοποίησή της τόσο κατά την παραγωγή όσο και τη διανομή της. Επιπλέον, με τη ραγδαία ανάπτυξη που έχει γνωρίσει η παραγόμενη ενέργεια από ΑΠΕ, σήμερα αποτελεί μια αναπόσπαστη συνιστώσα των ενεργειακών αγορών.

Είναι λοιπόν αυτονόητο ότι η συνεχώς αυξανόμενη παραγωγή ηλεκτρικής ενέργειας από ΑΠΕ και η έγχυσή της στο ενεργειακό δίκτυο, απαιτεί συνεχή τεχνική εξέλιξη αλλά και μεθόδους διασφάλισης της ευστάθειας και της ομαλής λειτουργίας του ηλεκτρικού δικτύου. Εστιάζοντας στην ηλιακή και αιολική ενέργεια, οι οποίες αποτελούν τις βασικότερες πηγές “πράσινης” ηλεκτρικής ενέργειας, είναι κατανοητό γιατί είναι τόσο δημοφιλείς μεταξύ των ΑΠΕ [7]. Η ηλιακή ακτινοβολία και ο άνεμος αποτελούν ανεξάντλητες πηγές ενέργειας ενώ η εκμετάλλευσή τους είναι ευκολότερη και οικονομικότερη συγκριτικά με τις υπόλοιπες ΑΠΕ [8]. Παρόλα αυτά, γίνεται εύκολα κατανοητό, ότι παρά την ανεξάντλητη φύση τους, δεν μπορούν να είναι και συνεχώς διαθέσιμες. Τόσο οι περίοδοι παροδικής ή μεγαλύτερης άπνοιας στην περίπτωση της αιολικής παραγωγής, όσο και οι νυχτερινές ώρες ή οι περίοδοι ελαφριάς ή βαριάς συννεφιάς στην περίπτωση της ΦΒ παραγωγής, αποτελούν περιπτώσεις που μπορούν να επηρεάσουν την απόδοση των συστημάτων παραγωγής αιολικής ή ηλιακής ενέργειας και συνεπώς την απόδοση των ηλεκτρικών δικτύων αλλά και τις καθημερινές αποφάσεις στα πλαίσια των ενεργειακών αγορών.

Επιθυμώντας να εκτιμηθούν τα αποτελέσματα αλλά και οι επιπτώσεις της έγχυσης ενέργειας παραγόμενης από ΑΠΕ στο δίκτυο, ο ερευνητικός κόσμος έχει εστιάσει το ενδιαφέρον του τα τελευταία χρόνια στον σχεδιασμό και την ανάπτυξη μεθοδολογιών ικανές να προβλέψουν και να εκτιμήσουν την παραγόμενη ενέργεια από ΑΠΕ κάτω από διάφορες συνθήκες και σε πλαίσια διαφορετικών ενεργειακών αναγκών. Είναι άξιο να σημειωθεί ότι χάρη στην ταχύτατη τεχνολογική ανάπτυξη, τόσο σε τεχνικό επίπεδο όσο και σε επίπεδο ανάπτυξης λογισμικού, τα μοντέλα πρόβλεψης συνεχώς βελτιώνονται. Σήμερα, η χρήση μεθοδολογιών πρόβλεψης κρίνεται απαραίτητη για τη βέλτιστη ένταξη μονάδων παραγωγής ενέργειας από ΑΠΕ στο ηλεκτρικό δίκτυο αφού έχει αποδειχθεί τα τελευταία χρόνια ότι συμβάλει σημαντικά στην οργάνωση και την ευστάθεια του δικτύου ηλεκτρικής ενέργειας και των ενεργειακών αγορών.

## 2.3 Συμβολή της διδακτορικής διατριβής

Στα πλαίσια της παρούσας διδακτορικής διατριβής μελετήθηκαν οι σύγχρονες και οι τελευταίες τεχνολογίας μέθοδοι πρόβλεψης αιολικής και φωτοβολταϊκής ενέργειας τόσο σε αιτιοκρατικό όσο και σε πιθανοτικό πλαίσιο, και τα αποτελέσματα της αξιολόγησης των μοντέλων της βιβλιογραφικής έρευνας δημοσιεύθηκαν σε δύο διεθνή επιστημονικά περιοδικά, στις εργασίες [9] και [10]. Παράλληλα, μελετήθηκε σύνολο εργασιών στα πλαίσια της κατανόησης της αρχιτεκτονικής των διαφορετικών μεθόδων πρόβλεψης παραγωγής ενέργειας από ΑΠΕ αλλά και στα πλαίσια της διερεύνησης των δυνατοτήτων εξέλιξης και βελτίωσης του κλάδου της πρόβλεψης στο μέλλον.

Πιο αναλυτικά, η εργασία [11] επικεντρώθηκε στους ευφείς προγνωστικούς παράγοντες για αιτιοκρατική πρόβλεψη αιολικής ενέργειας. Στην μελέτη [12], εξετάστηκαν οι αιτιοκρατικές μεθοδολογίες πρόβλεψης και παρουσιάστηκαν οι παράγοντες που διακρίνουν αυτές τις μεθοδολογίες. Επιχειρήθηκε περαιτέρω σύγκριση μεταξύ αυτών των μοντέλων με βάση τα χαρακτηριστικά εισόδου, το μέγεθος των συνόλων δεδομένων και τις προδιαγραφές τους καθώς και το ποσοστό δειγματοληψίας τους, την αντικειμενική συνάρτηση που χρησιμοποιείται σε κάθε μοντέλο και τα κριτήρια αξιολόγησης. Η εργασία [13] επικεντρώθηκε στην ποσοτικοποίηση της αβεβαιότητας με βάση την υπολογιστική νοημοσύνη και στις διαφορετικές τεχνικές λήψης αποφάσεων, καθώς και στην εφαρμογή τους σε έξυπνα δίκτυα από την άποψη των διαστημάτων πρόβλεψης. Εξετάστηκαν επίσης διάφορες μεθοδολογίες κατασκευής διαστημάτων πρόβλεψης και η ενσωμάτωσή τους σε εφαρμογές έξυπνων δικτύων μέσω τεχνικών λήψης αποφάσεων. Η εργασία [14] εξέτασε μεσοπρόθεσμα και μακροπρόθεσμα μοντέλα πρόβλεψης ανέμου με στόχο τον συνολικό σχεδιασμό. Η εργασία [15] εξέτασε το πρόβλημα των συμβάντων ράμπας στην πρόβλεψη αιολικής ενέργειας. Στη μελέτη [16], ο ρόλος της επεξεργασίας δεδομένων στην πρόβλεψη αιολικής ενέργειας καθώς και οι εφαρμογές της στις προβλέψεις ανέμου ήταν ο κύριος στόχος. Στην εργασία [17], διερευνήθηκε η ακρίβεια πρόβλεψης ανέμου σύμφωνα με διαφορετικούς μεταβλητούς παράγοντες. Η εργασία [18] επικεντρώθηκε στην ταξινόμηση νέων υβριδικών αλγορίθμων και μεθοδολογιών που χρησιμοποιούν διαφορετικά μοντέλα πρόβλεψης για να αυξήσουν το αποτέλεσμα πρόβλεψης σε αποδοτικό υπολογιστικό χρόνο. Η μελέτη [19] εξέτασε μοντέλα πρόβλεψης φωτοβολταϊκής παραγωγής, εστιάζοντας στη μηχανική μάθηση και στις μεταερευνητικές μεθόδους, όπου διαπιστώθηκε ότι τα υβριδικά μοντέλα παρείχαν τα πιο ακριβή προγνωστικά αποτελέσματα. Στην εργασία [20], η κύρια εστίαση ήταν η ανασκόπηση των βραχυπρόθεσμων μοντέλων πρόβλεψης φωτοβολταϊκής παραγωγής που βασίζονται σε ιστορικά δεδομένα και πώς η ακρίβεια της πρόβλεψης εξαρτάται από τέτοια δεδομένα. Η μελέτη [21] συνοψίζει τις προδιαγραφές που απαιτούνται για την εκτέλεση μιας ακριβούς πρόβλεψης. Περαιτέρω σύγκρινε τον ορισμό των οριζόντων πρόβλεψης μεταξύ προβλέψεων ηλιακής και αιολικής ενέργειας και τις επιδόσεις τους. Η εργασία [22] εξέτασε διάφορες τεχνικές που χρησιμοποιούνται για την πρόβλεψη ηλιακής ενέργειας και παρουσίασε σημαντικές πληροφορίες που απαιτούνται για μια ακριβή πρόβλεψη. Η τεράστια εστίαση στην πρόβλεψη της επόμενης ημέρας μαζί με την αυξανόμενη χρήση του NWP τονίστηκε περαιτέρω. Η μελέτη [23] εξέτασε διαφορετικές τεχνικές φωτοβολταϊκής πρόβλεψης και προσδιόρισε δεδομένα εισόδου που θα μπορούσαν ενδεχομένως να βελτιώσουν την ακρίβεια της πρόβλεψης, προσδιορίζοντας την ηλιακή ακτινοβολία, τη θερμοκρασία, την ταχύτητα και κατεύθυνση ανέμου, την υγρασία, την κάλυψη νεφών και τον δείκτη αερολύματος ως τις πιο σημαντικές

μεταβλητές για την πρόβλεψη φωτοβολταϊκής παραγωγής. Στην εργασία [24], μια ανασκόπηση των πιθανοτικών μοντέλων πρόβλεψης ηλιακής ενέργειας και φορτίου ήταν ο κύριος στόχος, ενώ επικεντρώθηκε ακόμα περισσότερο στον εντοπισμό ομοιοτήτων μεταξύ των μοντέλων πρόβλεψης ηλιακής ενέργειας και φορτίου. Η εργασία [25] επικεντρώθηκε στην ανάδειξη της χρήσης του πιθανοτικών μοντέλων πρόβλεψης φωτοβολταϊκής παραγωγής σε συστήματα ισχύος, επισημαίνοντας την ανάγκη για περαιτέρω αξιολόγηση και ενσωμάτωση των πιθανοτικών μοντέλων σε πραγματικά προβλήματα πρόβλεψης. Η εργασία [26] παρουσίασε μια ανασκόπηση των μαθηματικών φωτοβολταϊκών μοντέλων και μια μελέτη περίπτωσης που προέβλεπε την απόδοση ενός συγκεκριμένου ΦΒ συστήματος. Η μελέτη [27] παρουσίασε μια σε βάθος ανασκόπηση σε μεθοδολογίες αιχμής όσον αφορά τις τεχνικές και τη βελτιστοποίηση. Η μελέτη υπογράμμισε περαιτέρω τη σημασία της προεπεξεργασίας της διαδικασίας πρόβλεψης προκειμένου να κατασκευαστεί το κατάλληλο μοντέλο πρόβλεψης ανάλογα με την περίπτωση, καθώς και την ανάγκη της διαδικασίας αξιολόγησης και σύγκρισης των διαφορετικών μοντέλων πρόβλεψης.

Η συγκεντρωτική μελέτη που πραγματοποιήθηκε στα πλαίσια της παρούσας διδακτορικής διατριβής, επικεντρώθηκε σε σύγχρονες μεθόδους πρόβλεψης ενέργειας από ΑΠΕ. Πιο συγκεκριμένα μελετήθηκε η αρχιτεκτονική των μεθοδολογιών καθώς και τα βασικά τους πλεονεκτήματα και μειονεκτήματα. Συγκρίνοντας διαφορετικές μεθόδους, αξιοποιώντας αποτελέσματα κοινών μετρητικών αξιολόγησης, διερευνήθηκε η αποτελεσματικότητα των διαφορετικών προσεγγίσεων τόσο σε ερευνητικό επίπεδο όσο και σε πρακτικό.

Δίνοντας έμφαση στους τύπους δεδομένων εισόδου που χρησιμοποιούνται σε μοντέλα τελευταίας τεχνολογίας, προτάθηκαν σαφείς και αξιόπιστες ταξινομήσεις οι οποίες αναλύουν και καθοδηγούν με βάση πραγματικές προκλήσεις πρόβλεψης που θα πρέπει να αντιμετωπίσει η μελλοντική έρευνα.

## 2.4 Πρόβλεψη παραγωγής ηλιακής και αιολικής ισχύος

Η χρήση μεθοδολογιών πρόβλεψης αποτελεί ένα ισχυρό εργαλείο για την ομαλή ενσωμάτωση των ΑΠΕ στο ενεργειακό δίκτυο. Η ομαλή και σταθερή λειτουργία του δικτύου ηλεκτρικής ενέργειας αλλά και ο έλεγχος των ενεργειακών αγορών αποτελούν σημαντικά προβλήματα τα οποία η χρήση των μοντέλων πρόβλεψης παραγωγής έρχεται να αντιμετωπίσει και να επιλύσει.

Τα σύγχρονα μοντέλα πρόβλεψης ΦΒ και αιολικής παραγωγής, βασιζόμενα στην συνεχώς αναπτυσσόμενη τεχνολογία αλλά και την εξέλιξη των λογισμικών, μπορούν με εξαιρετική ακρίβεια να εκτιμούν τις δυνατότητες παραγωγής από ΑΠΕ. Κατά κύριο λόγο, η λειτουργία των μοντέλων πρόβλεψης βασίζεται στη χρήση ιστορικών δεδομένων παραγωγής ενέργειας από την ζητούμενη ΑΠΕ, αλλά και χρήση ιστορικών μετεωρολογικών δεδομένων. Λόγω της άμεσης εξάρτησης της παραγωγής από ΑΠΕ από καθημερινά φυσικά φαινόμενα, η εξέταση των μετεωρολογικών δεδομένων τόσο σε τοπικό όσο και σε ευρύτερα γεωγραφικό επίπεδο συμβάλλει σημαντικά στη βελτίωση της ακρίβειας των μοντέλων πρόβλεψης.

### 2.4.1 Παραγωγή ΦΒ ισχύος

Η παραγωγή ενέργειας από την ηλιακή ακτινοβολία αποτελεί σήμερα την πιο διαδεδομένη μορφή ΑΠΕ, ενώ σε παγκόσμιο επίπεδο αποτελεί περίπου το 1/3 του συνολικού δυναμικού παραγωγής ισχύος από ΑΠΕ [6]. Τόσο οι γνώσεις πάνω στην αξιοποίηση της ηλιακής ενέργειας, όσο και η συνεχής ανάπτυξη των ΦΒ συλλεκτών έχουν συμβάλει σημαντικά στο να χρησιμοποιείται όλο και περισσότερο για την παραγωγή ηλεκτρικής ενέργειας, ακόμα και σε οικιακό επίπεδο.

Η παραγωγή ηλιακής ισχύος είναι άμεσα εξαρτώμενη από τη διαθεσιμότητα ηλιακού φωτός. Η αποδοτική δέσμευση της ηλιακής ακτινοβολίας από τους ΦΒ συλλέκτες επηρεάζει και την τελική παραγόμενη ΦΒ ισχύ. Η απόδοση των ΦΒ συστημάτων εξαρτάται από πολλούς παράγοντες, τόσο τεχνικούς όσο και μετεωρολογικούς.

Τα υψηλής ποιότητας ημιαγώγιμα υλικά που χρησιμοποιούνται ενισχύουν τη μετατροπή ενέργειας και ενισχύουν την απόδοση του ΦΒ συστήματος. Επιπλέον, η γωνία πρόσπτωσης της ηλιακής ακτινοβολίας παίζει σημαντικό ρόλο, καθώς η κάθετη πρόσπτωσή της στους ΦΒ συλλέκτες μπορεί να αυξήσει την παραγωγή ενέργειας σε σύγκριση με την κεκλιμένη πρόσπτωση. Πολλές σύγχρονες ΦΒ εγκαταστάσεις διαθέτουν μηχανισμούς εντοπισμού οι οποίοι παρακολουθούν την ηλιακή κίνηση και προσαρμόζουν τη γωνία των ηλιακών συλλεκτών ώστε να ακολουθεί την πορεία του ήλιου σε όλη τη διάρκεια της ημέρας με τη βέλτιστη δυνατή γωνία πρόσπτωσης, και έτσι βελτιστοποιείται η δυνατότητα παραγωγής ενέργειας. Αξίζει να σημειωθεί ότι η συνεχής βελτίωση της απόδοσης των ΦΒ συστημάτων καθώς και η άμεση ανάγκη για διεύρυνση της χρήσης τους σε παγκόσμιο επίπεδο, έχει οδηγήσει στη βελτίωση της βιωσιμότητάς τους σε οικονομικό επίπεδο, καθώς γίνονται όλο και πιο προσιτά στον καταναλωτή, τόσο κατά την αγορά τους όσο και κατά τη συντήρησή τους.

Κάποιοι από τους βασικούς μετεωρολογικούς παράγοντες που επηρεάζουν την απόδοση των συστημάτων ΦΒ παραγωγής είναι [28]:

- Παγκόσμια οριζόντια ακτινοβολία (GHI)

Αποτελεί τη συνολική ηλιακή ακτινοβολία που προσπίπτει σε μια οριζόντια επιφάνεια. Η ανάλυσή της μπορεί να δώσει σημαντικές πληροφορίες τόσο σε εποχικό όσο και σε ημερήσιο επίπεδο για το ΦΒ δυναμικό μιας περιοχής και επομένως αποτελεί σημαντικό παράγοντα για τον σχεδιασμό των ΦΒ συστημάτων.

- Άμεση κανονική ακτινοβολία (DNI)

Αποτελεί το ποσό της ηλιακής ακτινοβολίας που προσπίπτει απευθείας σε μια επιφάνεια κάθετα στις ακτίνες του ήλιου. Η κατανόηση και εκτίμηση της συμπεριφοράς της DNI είναι σημαντική για τη βελτιστοποίηση της λειτουργίας των ΦΒ εγκαταστάσεων.

- Διάχυτη οριζόντια ακτινοβολία (DHI)

Πρόκειται για το ποσοστό της ακτινοβολίας που διαχέεται στην ατμόσφαιρα και φτάνει σε μια οριζόντια επιφάνεια από κάθε κατεύθυνση. Η εκτίμησή της είναι καθοριστική, τόσο για τον σχεδιασμό όσο και για τη διερεύνηση της δυνατότητας βέλτιστης παραγωγής των ΦΒ συστημάτων.

- Θερμοκρασία ηλιακού συλλέκτη

Η θερμοκρασία πάνω στους ΦΒ συλλέκτες μπορεί να επηρεάσει σε σημαντικό βαθμό την απόδοσή τους. Εάν και συνεχώς επιδιώκεται να υπάρχει πρόσπτωση ηλιακής ακτινοβολίας πάνω στους ηλιακούς συλλέκτες αυτό δεν σημαίνει ότι η μεγάλη θερμοκρασία των συλλεκτών είναι επιθυμητή. Παρότι μοιάζει αντιφατικό, εάν και σε μεγαλύτερες θερμοκρασίες παράγεται περισσότερο ρεύμα λόγω της αυξημένης παραγωγής στον φορέα, ταυτόχρονα υπάρχει μείωση της κινητικότητάς του, ενώ παρατηρείται και αύξηση της αντίστασης των ημιαγωγικών υλικών που χρησιμοποιούνται. Το τελικό αποτέλεσμα είναι η τελική τάση εξόδου να μειώνεται όταν αυξάνεται η θερμοκρασία.

- Νεφοκάλυψη

Η κάλυψη της ηλιακής ακτινοβολίας από σύννεφα αποτελεί ίσως τον σημαντικότερο παράγοντα που μπορεί να επηρεάσει την παραγωγή ενέργειας μέσω ΦΒ συστημάτων. Γνωρίζοντας την καθημερινή αναμενόμενη κίνηση του ήλιου, η τοποθέτηση των ΦΒ συλλεκτών είναι εύκολο να γίνει κατά τέτοιο τρόπο ώστε να βελτιστοποιείται η πρόσπτωση της ηλιακής ακτινοβολίας. Ωστόσο, η παρουσία συννεφιάς οδηγεί σε σύντομη ή μεγαλύτερης διάρκειας διακοπή της πρόσπτωσης ηλιακής ακτινοβολίας στους ηλιακούς συλλέκτες. Η διακοπτόμενη αυτή πρόσπτωση ακτινοβολίας οδηγεί σε πτώση της συνολικής απόδοσης του ΦΒ συστήματος, αφού κατά τη διάρκεια της νεφοκάλυψης, η τελική παραγόμενη ενέργεια μπορεί να κυμαίνεται μεταξύ του μηδενός και ποσοστού της ονομαστικής ισχύος του ΦΒ πάρκου, χωρίς όμως να είναι εύκολο να εκτιμηθεί. Η συννεφιά ως φαινόμενο δεν μπορεί να προβλεφθεί με ακρίβεια και η εκτίμησή της αποτελεί πρόκληση για τη βελτίωση της απόδοσης των ΦΒ συστημάτων αλλά και την ασφαλή και αποδοτική ενσωμάτωσή τους στις ενεργειακές αγορές.

- Βροχόπτωση

Η βροχόπτωση (ή και η χιονόπτωση σε χαμηλότερες θερμοκρασίες) συνδέεται άμεσα με την ΦΒ παραγωγή. Η βροχή ως φαινόμενο, μπορεί τόσο να απορροφά την ηλιακή ακτινοβολία όσο και να τη σκεδάζει, κάνοντας δύσκολη την ομαλή και κάθετη πρόσπτωσή της στους ΦΒ συλλέκτες. Επιπλέον, η ύπαρξη βροχόπτωσης ταυτίζεται άμεσα με την ύπαρξη συννεφιάς, η οποία σε μεγάλο βαθμό επηρεάζει το ΦΒ δυναμικό.

### 2.4.2 Παραγωγή αιολικής ισχύος

Η παραγωγή αιολικής ισχύος αποτελεί τη δεύτερη μεγαλύτερη παραγωγή από ΑΠΕ σε παγκόσμιο επίπεδο. Βασίζεται στην εκμετάλλευση της κίνησης του ανέμου, η οποία κινεί έναν δρομέα και μέσω της γεννήτριας μετατρέπει τη μηχανική ενέργεια σε ηλεκτρική. Οι σύγχρονες ανεμογεννήτριες, επιτρέπουν την αξιοποίηση υλικών τα οποία μειώνουν τα συνολικά κόστη για την παραγωγή αιολικής ενέργειας ενώ ταυτόχρονα βελτιστοποιούν τη δυνατότητα παραγωγής.

Κάποιοι από τους βασικούς μετεωρολογικούς παράγοντες που επηρεάζουν την απόδοση των συστημάτων αιολικής παραγωγής είναι [29]:

- Ταχύτητα ανέμου

Η ταχύτητα του ανέμου αποτελεί ίσως την κρίσιμότερη παράμετρο που μπορεί να επηρεάσει την απόδοση των συστημάτων αιολικής παραγωγής. Οι ανεμογεννήτριες είναι κατασκευασμένες να έχουν μια τυπική ελάχιστη ταχύτητα ανέμου με την οποία αρχίζουν να παράγουν ισχύ και μια ονομαστική ταχύτητα ανέμου κατά την οποία παράγουν τη μέγιστη ονομαστική τους ισχύ. Επομένως, εάν η ταχύτητα του ανέμου είναι πολύ χαμηλή ή πολύ υψηλή, η ανεμογεννήτρια μπορεί να μην λειτουργεί αποτελεσματικά ή να απενεργοποιείται για να αποφευχθεί πιθανή ζημιά.

- Διεύθυνση ανέμου

Η διεύθυνση του ανέμου είναι καθοριστική για τη γωνία με την οποία τα πτερύγια του δρομέα του στροβίλου της ανεμογεννήτριας ευθυγραμμίζονται με τον άνεμο. Οι ανεμογεννήτριες είναι σχεδιασμένες να παράγουν ενέργεια αποτελεσματικότερα όταν ο άνεμος προσπίπτει κάθετα στα πτερύγια του δρομέα.

- Ένταση τύρβης

Οι τυρβωειδείς κινήσεις του ανέμου αφορούν σε ακανόνιστη και έντονη συμπεριφορά του ανέμου, τόσο σε επίπεδο ταχύτητας όσο και σε επίπεδο διεύθυνσης. Οι τυρβώδεις συνθήκες μπορούν να αυξήσουν την πίεση στα εξαρτήματα του στροβίλου και να μειώσουν την απόδοση του συστήματος. Η κατανόηση και εκτίμηση των τυρβωειδών κινήσεων, αποτελεί σημαντικό παράγοντα για τον σχεδιασμό και την αξιοπιστία των συστημάτων αιολικής παραγωγής.

- Τοπογραφία εδάφους

Η τοπογραφία του εδάφους μπορεί να επηρεάσει σημαντικά τα τοπικά μοτίβα ανέμων. Σε πολλές περιπτώσεις, η μορφολογία του εδάφους, για παράδειγμα σε κοιλάδες και παράκτιες περιοχές, μπορεί να δημιουργήσει φαινόμενα διοχέτευσης που συγκεντρώνουν σημαντικές ριπές ανέμου και επιταχύνουν τον άνεμο, με αποτέλεσμα να αποτελούν ιδανικές τοποθεσίες για αιολικά πάρκα.

- Ατμοσφαιρική πίεση

Η ατμοσφαιρική πίεση μπορεί να επηρεάσει τα μοτίβα του ανέμου σε τοπικό επίπεδο. Τα συστήματα χαμηλής πίεσης συχνά οδηγούν σε ισχυρότερους ανέμους, ενώ τα συστήματα υψηλής πίεσης μπορούν να οδηγήσουν σε πιο ήρεμες συνθήκες. Επομένως, η γνώση των συνθηκών ατμοσφαιρικής πίεσης σε τοπικό επίπεδο μπορεί να δώσει σημαντικές πληροφορίες για τη συμπεριφορά των ανέμων και συνεπώς του αιολικού δυναμικού της περιοχής.

- Πυκνότητα ανέμου

Η πυκνότητα του ανέμου, η οποία επηρεάζεται άμεσα από την αλλαγή της θερμοκρασίας, επιδρά σημαντικά στην ταχύτητα του ανέμου. Όσο μεγαλύτερη η πυκνότητα του ανέμου, τόσο αυξάνεται και το αιολικό δυναμικό αφού αυξάνεται η ταχύτητα του ανέμου.

### 2.4.3 Μετεωρολογικοί παράγοντες και η επίδρασή τους στην παραγωγή ΦΒ και αιολικής ισχύος

Οι μετεωρολογικές συνθήκες παίζουν βασικό ρόλο στην απόδοση των συστημάτων παραγωγής ενέργειας από ΑΠΕ. Πέραν των επιμέρους μετεωρολογικών συνθηκών που αναλύθηκαν παραπάνω, υπάρχουν και μετεωρολογικοί παράγοντες που παίζουν εξίσου σημαντικό ρόλο τόσο στην ΦΒ όσο και στην αιολική παραγωγή. Οι βασικότεροι από αυτούς παρουσιάζονται στη συνέχεια:

- Θερμοκρασία περιβάλλοντος

Η θερμοκρασία περιβάλλοντος αποτελεί ένας κρίσιμο παράγοντα που επηρεάζει την παραγωγή τόσο αιολικής όσο και ΦΒ παραγωγής. Η αυξημένη θερμοκρασία περιβάλλοντος μπορεί να συμβάλει στην αύξηση της θερμοκρασίας πάνω στους ΦΒ συλλέκτες, ειδικά σε συνδυασμό με έντονους ανέμους και να οδηγήσει σε πτώση της απόδοσης των ΦΒ συλλεκτών. Αντίστοιχα, στις περιπτώσεις αιολικής παραγωγής, η θερμοκρασία περιβάλλοντος μπορεί να επηρεάσει την πυκνότητα του ανέμου. Οι χαμηλές θερμοκρασίες περιβάλλοντος αυξάνουν την πυκνότητα του ανέμου με αποτέλεσμα να υπάρχουν μεγαλύτερες ταχύτητες και άρα καλύτερο δυναμικό αιολικής παραγωγής.

- Υγρασία

Η υγρασία αφορά το ποσό των υδρατμών στον αέρα και ύπαρξή της μπορεί να επιδράσει στον τρόπο μετάδοσης της ηλιακής ακτινοβολίας. Επιπλέον, οι συνθήκες αυξημένης υγρασίας έχουν ως αποτέλεσμα να μειώνεται η πυκνότητα του αέρα και συνεπώς το αιολικό δυναμικό.

- Γεωγραφική τοποθεσία και εποχικές αλλαγές

Περιοχές πλησιέστερα στον Ισημερινό δέχονται περισσότερη κάθετη ηλιακή ακτινοβολία συγκριτικά με τις περιοχές κοντά στους πόλους, με αποτέλεσμα να

έχουν μεγαλύτερο ηλιακό δυναμικό σε όλη τη διάρκεια του έτους. Αντίστοιχα, σε περιοχές κοντά στον Ισημερινό, συναντώνται ασθενέστεροι και λιγότερο σταθεροί άνεμοι, λόγω της πιο ομοιόμορφης κατανομής της θερμοκρασίας. Πλησιάζοντας στους πόλους, οι διακυμάνσεις της θερμοκρασίας γίνονται όλο και μεγαλύτερες, με αποτέλεσμα ισχυρότερους και πιο σταθερούς ανέμους. Σε ότι αφορά στις εποχικές διακυμάνσεις, μπορούν να επιδράσουν στην απόδοση των ΦΒ συστημάτων. Για παράδειγμα, σε περιοχές που βρίσκονται στο βόρειο ημισφαίριο, κατά τους καλοκαιρινούς μήνες η κάθετη ακτινοβολία είναι μεγαλύτερη με αποτέλεσμα να βελτιώνει τη δυνατότητα παραγόμενης ενέργειας σε αντίθεση με τους χειμερινούς μήνες που η πρόσπτωση της ηλιακής ακτινοβολίας γίνεται υπό μεγαλύτερη γωνία. Σε ότι αφορά στην αιολική παραγωγή, η συμπεριφορά του ανέμου κατά τις εποχικές αλλαγές είναι σημαντικό να αναλύεται, καθώς ανάλογα τη γεωγραφική θέση αλλά και την τοπογραφία του εδάφους, μπορεί οι άνεμοι να εμφανίζουν σημαντική διακύμανση. Ως αποτέλεσμα, μπορεί να εκτιμάται το αιολικό δυναμικό μιας περιοχής σε ετήσιο επίπεδο και έτσι να γίνεται κατάλληλος σχεδιασμός για τη βελτιστοποίηση της αιολικής παραγωγής.

## 2.5 Μέθοδοι πρόβλεψης παραγωγής από ΑΠΕ

Η ενσωμάτωση της παραγωγής από ΑΠΕ στο ηλεκτρικό δίκτυο προχωράει με ραγδαίους ρυθμούς. Οι μεθοδολογίες πρόβλεψης του δυναμικού παραγωγής από ΑΠΕ έχει γίνει ένα απαραίτητο εργαλείο στην αντιμετώπιση των προβλημάτων ευστάθειας του δικτύου, οργάνωσης των διαδικασιών και ελέγχου των ενεργειακών αγορών.

Τα σύγχρονα μοντέλα πρόβλεψης έχουν βασιστεί κατά κύριο λόγο σε μοντέλα που εξελίσσονται εδώ και δεκαετίες. Η απόδοση διαφορετικών μοντέλων πρόβλεψης παραγωγής από ΑΠΕ έχουν δοκιμαστεί σε διαφορετικά προβλήματα παραγωγής από ΑΠΕ. Τόσο η γεωγραφική τοποθεσία και οι κλιματικές συνθήκες, όσο και οι ανάγκες κάλυψης του δικτύου αποτελούν παραμέτρους που διαφέρουν από περιοχή σε περιοχή και από περίπτωση σε περίπτωση. Τα μοντέλα πρόβλεψης εκμεταλλευόμενα κατά κύριο λόγο ιστορικά δεδομένα, τόσο παραγόμενης ισχύος όσο και μετεωρολογικών συνθηκών, μπορούν πλέον με μεγάλη ακρίβεια να εκτιμήσουν την παραγόμενη ισχύ από ΑΠΕ, τόσο βραχυχρόνια όσο και μακροχρόνια.

### 2.5.1 Αιτιοκρατική πρόβλεψη

Τα αιτιοκρατικά μοντέλα αποτελούν τα πιο ευρέως χρησιμοποιημένα μοντέλα πρόβλεψης παραγωγής, τόσο σε ότι αφορά τη ΦΒ παραγωγή όσο και την αιολική παραγωγή ισχύος. Πρόκειται για μοντέλα τα οποία δίνουν ως τελικό αποτέλεσμα την προβλεπόμενη παραγόμενη ισχύ σε μορφή μιας χρονοσειράς. Πρακτικά, αυτό σημαίνει ότι για κάθε προβλεπόμενη χρονική στιγμή, το μοντέλο πρόβλεψης δίνει μια μοναδική εκτίμηση της παραγόμενης ισχύος. Το χρονικό βήμα της χρονοσειράς μπορεί να ποικίλει ανάλογα το εκάστοτε πρόβλημα το οποίο μελετάται.

Σήμερα, με τη συνεχή ενσωμάτωση των ΑΠΕ στο ενεργειακό δίκτυο, η χρήση αιτιοκρατικών μοντέλων πρόβλεψης παραγωγής κρίνεται απαραίτητη. Ανά τα χρόνια, έχει γίνει

μεγάλη προσπάθεια βελτίωσης της απόδοσης και της ακρίβειας των αιτιοκρατικών μοντέλων πρόβλεψης. Η συνεχής βελτίωση των λογισμικών αλλά και των τεχνικών ικανοτήτων των υπολογιστικών συστημάτων, έχει επιτρέψει τον συνυπολογισμό σημαντικού αριθμού παραγόντων που μπορεί να επηρεάζουν την ακρίβεια των μοντέλων πρόβλεψης. Ωστόσο, με τον τρόπο αυτό, τα μοντέλα πρόβλεψης τείνουν να γίνονται όλο και πιο πολύπλοκα κυρίως σε ότι αφορά στην αρχιτεκτονική τους και στην υλοποίησή τους, ενώ μπορεί να απαιτούν αρκετά μεγάλο χρόνο τρεξίματος. Συχνά, επιπλέον χρήση αλγορίθμων βελτιστοποίησης είναι απαραίτητη ώστε τα αποτελέσματα να γίνονται όσο το δυνατόν πιο ρεαλιστικά. Η προσαρμογή των σύγχρονων αιτιοκρατικών μοντέλων πρόβλεψης με τέτοιο τρόπο ώστε η ανάγκη για ακρίβεια να μην υπερκαλύπτεται από την πολυπλοκότητα και τους μεγάλους χρόνους τρεξίματος, αποτελεί βασική πρόκληση στην περαιτέρω εξέλιξή τους.

#### 2.5.1.1 Φυσικά μοντέλα

Τα φυσικά μοντέλα παίζουν σημαντικό ρόλο, τόσο στην κατανόηση της ίδιας της πρόβλεψης όσο και της αλληλεπίδρασής της με τις φυσικές διαδικασίες. Τα μοντέλα αυτά βασίζονται σε συγκεκριμένες μαθηματικές εξισώσεις που απεικονίζουν σε κάποιο βαθμό τις υπάρχουσες φυσικές συνθήκες σε μια περιοχή έτσι ώστε να καταλήγουν στην εκτίμηση της παραγόμενης ισχύος.

Τα φυσικά μοντέλα αξιολογούν τις ατμοσφαιρικές συνθήκες και χρησιμοποιούν πραγματικά μετεωρολογικά δεδομένα για να δημιουργήσουν ένα μοντέλο πρόβλεψης. Τέτοια μοντέλα χρησιμοποιούν τοπογραφικά δεδομένα, όπως το υψόμετρο, την τραχύτητα της επιφάνειας, τα εμπόδια, καθώς και μετεωρολογικά δεδομένα. Το μοντέλο Αριθμητικής Πρόβλεψης Καιρού (Numerical Weather Prediction – NWP) είναι τα πλέον τυπικά φυσικά μοντέλα και χρησιμοποιούν τέτοια δεδομένα προκειμένου να εκτιμήσουν, για παράδειγμα, την ακριβή τιμή της ταχύτητας ανέμου για κάθε ανεμογεννήτρια ενός αιολικού πάρκου προκειμένου να προβλεφθεί η παραγωγή αιολικής ενέργειας όσο το δυνατόν ακριβέστερα.

Τα μοντέλα NWP χρησιμοποιούν υδροδυναμικά και θερμοδυναμικά μοντέλα της ατμόσφαιρας προκειμένου να κάνουν προβλέψεις με βάση τις καιρικές συνθήκες για συγκεκριμένες συνθήκες αρχικής τιμής και οριακών συνθηκών. Διάφορα παγκόσμια και περιφερειακά μοντέλα πρόβλεψης NWP έχουν αναπτυχθεί τα τελευταία χρόνια [30]. Βασικά, αυτά τα μοντέλα πρόβλεψης NWP λειτουργούν με την επίλυση πολύπλοκων μαθηματικών μοντέλων, τα οποία βασίζονται σε δεδομένα καιρού (δηλαδή θερμοκρασία, υγρασία, κ.λπ.). Τέτοια μοντέλα απαιτούν πολλούς υπολογισμούς και είναι πιο αξιόπιστα για μακροπρόθεσμες προβλέψεις [31].

Ένα από τα κύρια μειονεκτήματα των φυσικών μοντέλων είναι η συλλογή τοπικών δεδομένων εδάφους καθώς πολλές φορές το έδαφος μπορεί να είναι πραγματικά πολύπλοκο. Επιπλέον, η προγνωστική ακρίβεια των φυσικών μοντέλων συνδέεται άμεσα με τη σταθερότητα των καιρικών συνθηκών της περιοχής που ερευνάται. Κατά κύριο λόγο τα φυσικά μοντέλα βασίζονται στην, όσο το δυνατόν, γραμμική απεικόνιση των φυσικών φαινομένων. Ως αποτέλεσμα, δεν είναι εύκολο να αποτυπωθούν οι μη γραμμικές σχέσεις των φυσικών φαινομένων, ή απρόβλεπτα γεγονότα, όπως συννεφιά ή βροχόπτωση στην περίπτωση ΦΒ παραγωγής, ή μεγάλη διάρκεια άπνοιας ή πολύ δυνατοί άνεμοι στην περίπτωση της αιολικής παραγωγής.

### 2.5.1.2 Στατιστικά μοντέλα

Τα στατιστικά μοντέλα βασίζονται στις στατιστικές συσχετίσεις μεταξύ των επεξηγηματικών μεταβλητών που χρησιμοποιούνται και των ιστορικών δεδομένων παραγωγής και περιβαλλοντικών συνθηκών, αλλά και των στόχων του μοντέλου προκειμένου να γίνουν ακριβείς προβλέψεις. Οι στατιστικές μέθοδοι βασίζονται είτε σε μοντέλα χρονοσειρών είτε σε μοντέλα τεχνητής νοημοσύνης (TN), ενώ η αξιοποίηση των πλεονεκτημάτων διαφορετικών μεθοδολογιών καταλήγει σε υβριδικά μοντέλα.

#### Στατιστικά μοντέλα βασισμένα σε χρονοσειρές

Το αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (*ARMA*) αποτελεί ένα από τα πιο διαδεδομένα στατιστικά μοντέλα πρόβλεψης [32], [33]. Το *ARMA* συνδυάζει δυο συνιστώσες, το αυτοπαλινδρομικό μοντέλο (*AR*) και το μοντέλο κινητού μέσου όρου (*MA*).

Το *AR* προβλέπει μελλοντικές τιμές με βάση έναν γραμμικό συνδυασμό προηγούμενων παρατηρήσεων  $p$  της ίδιας μεταβλητής. Ο όρος "αυτοπαλινδρομικό" υποδηλώνει ότι το μοντέλο παλινδρομεί την τρέχουσα τιμή της μεταβλητής έναντι των προηγούμενων τιμών της. Το  $AR(p)$  εκφράζεται ως εξής:

$$X_t = c + \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + \varepsilon_t \quad (2.1)$$

όπου,  $X_t$  είναι η παρατηρούμενη τιμή που είναι επιθυμητό να προβλεφθεί κατά τη χρονική στιγμή  $t$ , το  $c$  είναι σταθερά του μοντέλου, το  $\varepsilon_t$  αποτελεί τον θόρυβο ή το σφάλμα στο μοντέλο και τα  $\varphi_1, \varphi_2, \dots, \varphi_p$  αποτελούν τις αυτοπαλινδρομες συνιστώσες.

Το *MA* προβλέπει μελλοντικές τιμές με βάση έναν σταθμισμένο μέσο όρο των προηγούμενων όρων σφάλματος  $q$ . Το  $MA(q)$  εκφράζεται ως εξής:

$$X_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.2)$$

όπου,  $X_t$  είναι η παρατηρούμενη τιμή που είναι επιθυμητό να προβλεφθεί κατά τη χρονική στιγμή  $t$ , το  $\mu$  αποτελεί τον μέσο όρο της σειράς, το  $\varepsilon_t$  αποτελεί τον θόρυβο ή το σφάλμα στο μοντέλο την κάθε χρονική στιγμή  $t$ , και τα  $\theta_1, \theta_2, \dots, \theta_q$  αποτελούν τις συνιστώσες κινητού μέσου όρου.

Το *ARMA* συνδυάζει τις δυνατότητες του *AR* και του *MA*. Ουσιαστικά, το *ARMA* συνδυάζει την ιδέα ότι η τρέχουσα τιμή της χρονοσειράς επηρεάζεται από τις δικές της προηγούμενες τιμές (το αυτοπαλινδρομικό μέρος) και την επιρροή των προηγούμενων όρων σφάλματος (το τμήμα του κινούμενου μέσου όρου) [34]. Το αυτοπαλινδρομικό στοιχείο έχει τη δυνατότητα να καταγράφει τις μακροπρόθεσμες τάσεις και εξαρτήσεις στα δεδομένα, ενώ το στοιχείο κινούμενου μέσου όρου λαμβάνει υπόψη του τις βραχυπρόθεσμες διακυμάνσεις και τον θόρυβο/σφάλμα. Το  $ARMA(p, q)$  εκφράζεται ως εξής:

$$X_t = \mu + \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.3)$$

Εάν στο *ARMA* ενταχθεί και η συνιστώσα της διαφορίσης ώστε να γίνει στάσιμη η σειρά, τότε εισάγεται το ολοκληρωμένο αυτοπαλινδρομικό μοντέλο κινητού μέσου όρου (*ARIMA*) [35]-[38]. Το  $ARIMA(p, d, q)$  εκφράζεται ως εξής:

$$\Delta^d X_t = \mu + \varphi_1 \Delta^d X_{t-1} + \varphi_2 \Delta^d X_{t-2} + \dots + \varphi_p \Delta^d X_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.4)$$

όπου,  $\Delta^d X_t$  είναι η διαφορισμένη χρονοσειρά τάξης  $d$ .

Ενσωματώνοντας και άλλες συνιστώσες στο αυτοπαλινδρομικό μοντέλο, για παράδειγμα τις εποχικές συνιστώσες ( $S$ ) ή συνιστώσες εξωγενών μεταβλητών ( $X$ ), μπορούν να προκύψουν περαιτέρω επεκτάσεις του *ARIMA*, όπως το *SARIMA* ή το *ARIMAX* ή συνδυασμός, ανάλογα με τις υπολογισμένες συνιστώσες.

### Στατιστικά μοντέλα βασισμένα σε TN και μηχανική μάθηση

Η χρήση TN γίνεται όλο και πιο απαραίτητη τα τελευταία χρόνια για τα μοντέλα πρόβλεψης. Η ικανότητα των μοντέλων που βασίζονται σε TN να διαχειρίζονται μεγάλους αριθμούς δεδομένων, να εντοπίζουν σύνθετες σχέσεις και αλληλοεξαρτήσεις μεταξύ των μεταβλητών αλλά και τα παράγουν προβλέψεις υψηλής ακρίβειας, τα καθιστά απαραίτητα για την πρόβλεψη παραγωγής τόσο από ηλιακή όσο και από αιολική ενέργεια.

- **Μοντέλα μηχανικής μάθησης**

Η μηχανική μάθηση αξιοποιείται και χρησιμοποιείται στην πρόβλεψη παραγωγής από ΑΠΕ μέσα από μια σειρά απαραίτητων διαδικασιών. Η κατάλληλη επιλογή του μοντέλου μηχανικής μάθησης για το εκάστοτε πρόβλημα παίζει καθοριστικό ρόλο. Κάθε μοντέλο λειτουργεί διαφορετικά, ανάλογα με τον διαθέσιμο τύπο και όγκο δεδομένων αλλά και την επιθυμητή πρόβλεψη. Κάθε μοντέλο πρόβλεψης μηχανικής μάθησης έχει διαφορετικά πλεονεκτήματα και αδυναμίες, τα οποία ο χρήστης καλείται να γνωρίζει και να αξιοποιεί σε κάθε περίπτωση. Στη συνέχεια, η προεπεξεργασία των δεδομένων τα οποία θα χρησιμοποιηθούν για τη διαδικασία εκπαίδευσης του μοντέλου είναι απαραίτητη, καθώς σε πολλές περιπτώσεις τα διαθέσιμα δεδομένα έχουν μεγάλο όγκο ενώ συχνά απαιτείται καθαρισμός και κανονικοποίησή τους.

Με την ολοκλήρωση της επεξεργασίας των δεδομένων εισόδου, ακολουθεί η διαδικασία παραμετροποίησης του επιλεγμένου μοντέλου σε ότι αφορά τα κρυφά στρώματα, τα βάρη και τις πολώσεις. Στη συνέχεια, το μοντέλο εκπαιδεύεται και καταλήγει στην έξοδο της προβλεπόμενης παραγόμενης ισχύος. Η απόκλιση της προβλεπόμενης από την πραγματική ισχύ αξιολογείται. Σε περιπτώσεις που τα σφάλματα πρόβλεψης είναι μεγαλύτερα από το επιθυμητό, συνήθίζεται να εφαρμόζονται αλγόριθμοι βελτιστοποίησης στο μοντέλο πρόβλεψης ώστε να ρυθμίζονται εκ νέου οι υπερπαραμέτροι του μοντέλου ώστε να βελτιώνεται η απόδοσή του.

Υπάρχουν διάφοροι τύποι μοντέλων μηχανικής μάθησης:

Τα δέντρα αποφάσεων (decision trees) αποτελούν μοντέλα μηχανικής μάθησης που χρησιμοποιούνται συχνά στην πρόβλεψη ισχύος λόγω της ερμηνευτικότητάς τους και της ευκολίας χρήσης τους [39]. Διαχωρίζουν αναδρομικά τα δεδομένα με βάση τα πιο σημαντικά χαρακτηριστικά τους για να δημιουργήσουν μια δομή

κανόνων απόφασης που έχει μορφή δέντρου. Τα δέντρα αποφάσεων μπορούν να συλλάβουν πολύπλοκες σχέσεις και μη γραμμικότητες στα δεδομένα.

Τα τυχαία δάση (random forests) είναι μια μέθοδος που δημιουργεί πολλαπλά δέντρα αποφάσεων και συνδυάζει τις προβλέψεις τους για να βελτιώσει την ακρίβεια και να μειώσει την υπερπροσαρμογή [40]. Αξιοποιώντας την ποικιλομορφία των μεμονωμένων δέντρων αποφάσεων, τα τυχαία δάση μπορούν να συλλάβουν τη μεταβλητότητα και την αβεβαιότητα που σχετίζεται με πηγές ενέργειας που εξαρτώνται από τις καιρικές συνθήκες, όπως η ηλιακή και ο άνεμος [41], [42]. Μπορούν να παρέχουν πιο ισχυρές και ακριβείς προβλέψεις συνδυάζοντας τη γνώση πολλών δέντρων.

Οι μηχανές διανυσμάτων υποστήριξης (Support Vector Machines – SVM) είναι εποπτευόμενα μοντέλα εκμάθησης που χρησιμοποιούνται για εργασίες ταξινόμησης και παλινδρόμησης στην πρόβλεψη ισχύος [43]. Τα SVM στοχεύουν να βρουν ένα υπερεπίπεδο που διαχωρίζει καλύτερα τα σημεία δεδομένων σε διαφορετικές κλάσεις ή προβλέπει μια συνεχή έξοδο [44]-[46]. Μπορούν να χαρτογραφήσουν ένα σύνολο δεδομένων σε ένα χώρο χαρακτηριστικών υψηλών διαστάσεων μέσω μιας διαδικασίας μη γραμμικής χαρτογράφησης προκειμένου να προχωρήσουν στη γραμμική παλινδρόμηση, απλοποιώντας έτσι μια πραγματικά πολύπλοκη διαδικασία. Τα SVM είναι αποτελεσματικά όταν χρησιμοποιούνται σε δεδομένα υψηλών διαστάσεων ενώ μπορούν να χειριστούν μη γραμμικές σχέσεις μέσω της χρήσης συναρτήσεων πυρήνα.

- **Μοντέλα βαθιάς μηχανικής μάθησης**

Τα πιο γνωστά μοντέλα βαθιάς μηχανικής μάθησης που χρησιμοποιούνται σε στατιστικές προσεγγίσεις είναι τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ). Η όλη ιδέα των ΤΝΔ εμπνεύστηκε από τους βιολογικούς νευρώνες ενός ανθρώπινου εγκεφάλου. Η λειτουργία των νευρωνικών δικτύων (ΝΔ) βασίζεται στην αξιολόγηση των δεδομένων εισόδου που είναι διαθέσιμα και στη συνεχή επαναξιολόγησή τους, αλλά και των νέων εκπαιδευμένων δεδομένων, προκειμένου να επιτευχθεί ένα ακριβές προγνωστικό αποτέλεσμα, όπως ακριβώς αξιολογεί ο ανθρώπινος εγκέφαλος τα δεδομένα που λαμβάνει. Ανάλογα με την αρχιτεκτονική τους, υπάρχουν διάφοροι τύποι νευρωνικών δικτύων, όπως για παράδειγμα τα νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης (Feed-forward Neural Networks – FNN) [47], [48], τα συνελκτικά νευρωνικά δίκτυα (Convolutional Neural Networks – CNN) [49]-[52] και τα αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Networks – RNN) [53]-[57].

Ένα τυπικό ΤΝΔ αποτελείται από ένα επίπεδο εισόδου, όπου ενσωματώνονται τα ιστορικά δεδομένα, ένα επίπεδο εξόδου, όπου προκύπτουν οι προβλεπόμενες τιμές της ζητούμενης μεταβλητής και ένα ή περισσότερα κρυφά επίπεδα, όπου γίνεται η αξιολόγηση των δεδομένων από το επίπεδο εισόδου και το επίπεδο εξόδου. Κάθε στρώμα αποτελείται από νευρώνες που συνδέονται με αυτούς του

προηγούμενου στρώματος. Κάθε σύνδεση μεταξύ νευρώνων έχει ένα συγκεκριμένο βάρος που υπογραμμίζει τη σημασία αυτής της σύνδεσης και είναι το κλειδί για την επίτευξη της καλύτερης δυνατής ακρίβειας πρόβλεψης. Το ΝΔ εκπαιδεύεται τελικά προκειμένου να πάρει τις βέλτιστες τιμές βάρους κάθε σύνδεσης και να δώσει τις καλύτερες δυνατές τιμές εξόδου, δηλαδή την καλύτερη πρόβλεψη.

### **Υβριδικά μοντέλα**

Χάρη στην εξέλιξη των τεχνολογιών που χρησιμοποιούνται στην πρόβλεψη παραγωγής ηλεκτρικής ενέργειας από ΑΠΕ, οι υβριδικές μέθοδοι χρησιμοποιούνται όλο και περισσότερο προκειμένου να επιτευχθούν ακριβέστερα αποτελέσματα πρόβλεψης. Οι υβριδικές προσεγγίσεις στοχεύουν στη χρήση των πλεονεκτημάτων των συνδυασμένων μοντέλων που χρησιμοποιούνται για την επίτευξη βέλτιστης απόδοσης [58]-[61].

Τα συνδυασμένα μοντέλα μπορεί να είναι φυσικά και στατιστικά μοντέλα, μοντέλα για διαφορετικές χρονικές κλίμακες (για παράδειγμα, βραχυπρόθεσμα και μεσοπρόθεσμα μοντέλα) ή διαφορετικά στατιστικά μοντέλα. Συνδυάζοντας αυτές τις διαφορετικές μεθόδους, τα υβριδικά μοντέλα στοχεύουν να καλύψουν ένα ευρύτερο φάσμα πληροφοριών και να λάβουν υπόψη τους διάφορους παράγοντες που επηρεάζουν τα συστήματα ισχύος.

#### **2.5.2 Πιθανοτική πρόβλεψη**

Τα αιτιοκρατικά μοντέλα χρησιμοποιούνται κατά κόρον στην προσπάθεια της ομαλής ένταξης των ΑΠΕ στο ενεργειακό δίκτυο. Τα αιτιοκρατικά μοντέλα, προσφέρουν μια αποτύπωση της προβλεπόμενης παραγωγής σε μορφή χρονοσειράς για το ζητούμενο χρονικό διάστημα.

Παρόλα αυτά, είναι εύκολα κατανοητό ότι τα αιτιοκρατικά μοντέλα δεν μπορούν να έχουν απόλυτη ακρίβεια. Η προβλεπόμενη παραγόμενη ισχύς δεν παύει παρά να είναι μια εκτίμηση. Σε αντίθεση με τις σημειακές προβλέψεις που παρέχονται από τις αιτιοκρατικές μεθόδους, η πιθανοτική πρόβλεψη δίνει ένα διάστημα πρόβλεψης όπου αναμένεται να βρίσκεται η εκτιμώμενη παραγόμενη ισχύς. Πρακτικά, η πιθανοτική πρόβλεψη, προσφέρει για κάθε χρονική στιγμή ένα μεγαλύτερο εύρος πιθανών τιμών παραγόμενης ενέργειας.

Η εκτίμηση της αβεβαιότητας στην πρόβλεψη της παραγόμενης ισχύος, είναι αυτή που κάνει τα πιθανοτικά μοντέλα μοναδικά σε σύγκριση με τα αιτιοκρατικά μοντέλα [62]. Εάν και η χρήση των αιτιοκρατικών μοντέλων είναι σήμερα απαραίτητη και φαίνεται ότι θα είναι και για τα επόμενα χρόνια, τα πιθανοτικά μοντέλα κερδίζουν όλο και περισσότερο το ενδιαφέρον σε ερευνητικό επίπεδο και είναι πολύ πιθανό τα επόμενα χρόνια να συμβάλλουν σε ίδιο βαθμό στην ομαλή ένταξη των ΑΠΕ στο ηλεκτρικό δίκτυο αλλά και στον έλεγχο των ενεργειακών αγορών.

Τα πιθανοτικά μοντέλα αναπτύσσονται υπό δυο διαφορετικές προσεγγίσεις, την παραμετρική και την μη-παραμετρική.

### 2.5.2.1 Παραμετρικά μοντέλα

Το βασικό χαρακτηριστικό των παραμετρικών μοντέλων είναι ότι βασίζονται σε προκαθορισμένες υποθέσεις σχετικά με την κατανομή της παραγόμενης ισχύος [62]. Η πιο κοινή κατανομή είναι η Γκαουσιανή κατανομή, η οποία μπορεί να περιγραφεί ως εξής:

$$\hat{f}_{t+k|t} = f(p_{t+k}, \mu, \sigma^2) \quad (2.5)$$

όπου  $\mu$  είναι η παράμετρος μέσης τιμής,  $\sigma^2$  είναι η διασπορά, και  $\sigma$  είναι η τυπική απόκλιση. Ένα τυπικό πλεονέκτημα αυτών των μεθόδων είναι ότι είναι αρκετά απλές στην εκτέλεσή τους όχι μόνο όσον αφορά την επεξεργασία δεδομένων αλλά και την αξιολόγηση πρόβλεψης. Μια άλλη ευρέως χρησιμοποιούμενη κατανομή είναι η κατανομή beta, η οποία μπορεί να προσφέρει μεγαλύτερη ευελιξία σε περιπτώσεις που η κανονική κατανομή δεν μπορεί να αποτυπώσει επαρκώς τα χαρακτηριστικά της παραγόμενης ισχύος.

Ωστόσο, υπάρχουν διάφορες περιπτώσεις όπου η χρήση μιας προκαθορισμένης κατανομής της παραγωγής είναι υπερβολική ή δεν μπορούν να εφαρμοστούν συγκεκριμένες κατανομές. Επιπλέον, υπάρχουν περιπτώσεις όπου η κατανομή του σφάλματος πρόβλεψης μπορεί να αλλάζει ανάλογα με τη χρονική κλίμακα του ορίζοντα πρόβλεψης (πολύ βραχυπρόθεσμη, βραχυπρόθεσμη, μεσοπρόθεσμη και μακροπρόθεσμη). Τα παραπάνω καθιστούν τη χρήση παραμετρικών μοντέλων μη κατάλληλη για πολλές περιπτώσεις προβλημάτων πρόβλεψης παραγωγής ηλεκτρικής ενέργειας από ΦΒ ή αιολική ενέργεια.

### 2.5.2.2 Μη-παραμετρικά μοντέλα

Στα μη-παραμετρικά μοντέλα, δεν γίνεται εκ των προτέρων υπόθεση συγκεκριμένης κατανομής [63]. Το κύριο πλεονέκτημα των μη-παραμετρικών μοντέλων πρόβλεψης είναι η ευελιξία που προσφέρουν στον χρήστη. Η κατανομή των τιμών εξόδου υπολογίζεται απευθείας από τα δεδομένα που χρησιμοποιούνται. Ως αποτέλεσμα, τα σφάλματα πρόβλεψης που προκύπτουν από λανθασμένες υποθέσεις συγκεκριμένων κατανομών μειώνονται σημαντικά. Παρόλα αυτά, τέτοιες μέθοδοι είναι πιο περίπλοκες καθώς απαιτούν μεγαλύτερο αριθμό δεδομένων, καθιστώντας πιο δύσκολη όχι μόνο την επεξεργασία αλλά και την αξιολόγησή τους.

### Παλινδρόμηση ποσοστημορίων (Quantile Regression – QR)

Η παλινδρόμηση ποσοστημορίων αποτελεί μια πολύτιμη τεχνική στο πλαίσιο της πρόβλεψης ισχύος. Σε αντίθεση με τις παραδοσιακές μεθόδους πρόβλεψης που βασίζονται στη μέση τιμή, τα QR μοντέλα μπορούν να συλλάβουν τη μεταβλητότητα των δεδομένων υπολογίζοντας διαφορετικά ποσοστά της παραγωγής ισχύος [64]-[68]. Η βασική ιδέα της QR είναι η χρήση ποσοστημορίων για να προσεγγιστεί η υπό όρους κατανομή πιθανότητας μιας τυχαίας μεταβλητής [69]. Οι υπό όρους συναρτήσεις ποσοστού μοντελοποιούνται ως συναρτήσεις επεξηγηματικών μεταβλητών, οι οποίες είναι ανεξάρτητες μεταβλητές που χρησιμοποιούνται ως είσοδος για το μοντέλο πρόβλεψης.

Επιπλέον, η παλινδρόμηση ποσοστημορίων είναι ένα πολύτιμο εργαλείο για την ανθεκτικότητα και την αξιολόγηση κινδύνου στα συστήματα ισχύος. Εκτιμώντας τα ποσοστά, γίνεται εφικτή η αξιολόγηση του κινδύνου που σχετίζεται με ακραία γεγονότα, όπως διακοπές ρεύματος ή εξαιρετικά υψηλή ζήτηση, με αποτέλεσμα την καλύτερη οργάνωση και βελτίωση

των υποδομών και της κατανομής πόρων για να διασφαλιστεί η αξιοπιστία και η ευστάθεια του ηλεκτρικού δικτύου.

Έχουν αναπτυχθεί διάφορα μοντέλα βασισμένα στην QR όπως, όπως η τοπική παλινδρόμηση ποσοστημορίων (LQR), η άμεση παλινδρόμηση ποσοστημορίων (DQR), το δάσος παλινδρόμησης ποσοστημορίων (QRF) και η παλινδρόμηση ποσοστημορίων spline (SQR).

### Εκτίμηση πυκνότητας πυρήνα (KDE)

Η εκτίμηση της πυκνότητας πυρήνα είναι μια κοινή μέθοδος σε μη παραμετρικές προσεγγίσεις που βοηθά στην εκτίμηση της συνάρτησης πυκνότητας πιθανότητας (Probability Density Function – PDF) μιας τυχαίας μεταβλητής. Ως μη-παραμετρική προσέγγιση, μπορεί να εκτιμήσει άμεσα την πυκνότητα μιας τυχαίας μεταβλητής χωρίς να χρειάζεται να υποθέσει εκ των προτέρων μια συγκεκριμένη κατανομή. Η βασική λειτουργία της μεθόδου KDE είναι ότι, σε κάθε σημείο δεδομένων μιας μεταβλητής, τοποθετείται μια συνάρτηση πυρήνα προκειμένου να αναδειχθεί η συμβολή και η σημασία της στην πιθανολογική πυκνότητα [70]. Στη συνέχεια, το άθροισμα των συναρτήσεων του πυρήνα σε μια ομαλή καμπύλη επιτρέπει την τελική εκτίμηση της πυκνότητας του πυρήνα.

Ο εκτιμητής πυκνότητας πυρήνα περιγράφεται ως:

$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) \quad (2.6)$$

όπου,  $K$  είναι η συνάρτηση πυρήνα,  $h$  είναι η παράμετρος εξομάλυνσης (παράμετρος εύρους ζώνης),  $n$  είναι ο αριθμός των σημείων του δείγματος και το  $x_i$  αντιπροσωπεύει το σημείο του δείγματος στο οποίο τοποθετείται η συνάρτηση πυρήνα.

Η κατάλληλη επιλογή της κάθε συνάρτησης πυρήνα αλλά και των παραμέτρων εξομάλυνσης παίζουν καθοριστικό ρόλο στη βέλτιστη μοντελοποίηση του KDE αλλά και στην τελική αξιοπιστία του [71], [72].

### Μέθοδοι συνόλου (Ensemble)

Οι μέθοδοι συνόλου, συνδυάζουν πολλαπλά μοντέλα και χρησιμοποιούνται ευρέως στην πιθανοτική πρόβλεψη, τόσο της αιολικής όσο και της ΦΒ παραγωγής. Αυτές οι μέθοδοι αξιοποιούν τον συνδυασμό πολλαπλών μοντέλων πρόβλεψης για να μετριάσουν τις εγγενείς αβεβαιότητες και πολυπλοκότητες που σχετίζονται με τις ζητούμενες μεταβλητές [73].

Οι μέθοδοι συνόλου λειτουργούν εκπαιδύοντας και συνδυάζοντας πολλαπλά μεμονωμένα μοντέλα πρόβλεψης, τα οποία μπορεί να είναι διαφορετικού τύπου ή να χρησιμοποιούν διαφορετικούς αλγόριθμους και δυνατότητες εισαγωγής. Συνδυάζοντας αυτά τα διαφορετικά μοντέλα, οι μέθοδοι συνόλου στοχεύουν στην καταγραφή διαφορετικών πτυχών της υποκείμενης διανομής δεδομένων, μειώνοντας τον κίνδυνο μεροληψίας και υπερπροσαρμογής του μοντέλου [74], [75].

### Μέθοδος εκτίμησης κάτω και άνω ορίου (Lower Upper Bound Estimation – LUBE)

Η μέθοδος LUBE βασίζεται στη χρήση τεχνητής νοημοσύνης, για παράδειγμα ένα νευρωνικό δίκτυο, το οποίο δίνει δύο διαφορετικές εξόδους. Αυτές οι εξοδοί μπορούν να χρησιμοποιηθούν απευθείας για την κατασκευή διαστημάτων πρόβλεψης υπολογίζοντας το κάτω και το άνω όριο του διαστήματος πρόβλεψης [76]. Ένα από τα κύρια πλεονεκτήματα αυτής της μεθόδου είναι η άμεση κατασκευή του διαστήματος πρόβλεψης. Ενώ άλλες μέθοδοι υπολογίζουν συνήθως το διάστημα πρόβλεψης (Prediction Interval – PI) μετά την εκτίμηση των προβλέψεων σημείων, η μέθοδος LUBE απλοποιεί αυτή τη διαδικασία κατασκευάζοντας απευθείας το PI σε ένα βήμα [77]. Ως αποτέλεσμα, η όλη διαδικασία γίνεται απλούστερη και ταχύτερη, μειώνοντας έτσι το υπολογιστικό κόστος.

### Μέθοδος Bootstrap

Η λειτουργία της μεθόδου bootstrap βασίζεται στη δημιουργία μιας δειγματοληπτικής κατανομής των μεταβλητών μέσω της επαναδειγματοληψίας των αρχικών δεδομένων [78]. Είναι ιδιαίτερα χρήσιμη σε περιπτώσεις περιορισμένων δεδομένων ή «μη καθαρών» δεδομένων. Υπάρχουν διάφορες παραλλαγές της μεθόδου bootstrap, όπως η Bootstrap τυπικών καταλοίπων, η bootstrap άγριων καταλοίπων και η Bootstrap ζευγών.

Η μέθοδος Bootstrap περιλαμβάνει τη δημιουργία πολλαπλών συνόλων δεδομένων επαναδειγματοληψίας (δείγματα εκκίνησης) από τα αρχικά δεδομένα με αντικατάσταση. Κάθε δείγμα εκκίνησης έχει το ίδιο μέγεθος με το αρχικό σύνολο δεδομένων, αλλά μπορεί να περιέχει διπλές παρατηρήσεις. Αυτά τα δείγματα χρησιμοποιούνται στη συνέχεια για επανειλημμένη εκπαίδευση και δοκιμή μοντέλων πρόβλεψης, επιτρέποντας την εκτίμηση των διαστημάτων πρόβλεψης και την αξιολόγηση της αβεβαιότητας των προβλέψεων.

Το ουσιαστικότερο πλεονέκτημα της μεθόδου bootstrap είναι η ακρίβεια κατασκευής των διαστημάτων πρόβλεψης. Παρόλα αυτά, αυτή η ακρίβεια έχει υψηλό υπολογιστικό κόστος, καθώς τα παραδοσιακά χρησιμοποιούμενα NN δεν μπορούν να υπερβούν τους υπάρχοντες τεχνολογικούς περιορισμούς προκειμένου να γίνει η διαδικασία ταχύτερη.

### Ιεραρχική πρόβλεψη

Λόγω της αυξημένης ανάγκης για συνοχή και συνέπεια των μοντέλων πρόβλεψης, τα τελευταία χρόνια έχουν αναπτυχθεί ιεραρχικά μοντέλα πρόβλεψης. Οι προβλέψεις όλων των επιπέδων μιας ιεραρχίας συνοψίζονται μαζί. Επιπλέον, οι περιορισμοί συνοχής που χρησιμοποιούνται στα προγνωστικά μοντέλα, βελτιώνουν περαιτέρω την απόδοση όλων των επιπέδων της ιεραρχίας [79].

### Μηχανική μάθηση

Οι μεθοδολογίες μηχανικής μάθησης αποτελούν ισχυρούς αλγόριθμους εκπαίδευσης που βασίζονται στην τεχνητή νοημοσύνη, όπως στη χρήση νευρωνικών δικτύων. Αν και τείνουν να είναι εξαιρετικά πολύπλοκες, τέτοιες μεθοδολογίες έχουν χρησιμοποιηθεί ευρέως τα τελευταία χρόνια προκειμένου να βελτιωθεί η απόδοση των συμβατικών μοντέλων, δεδομένης της υψηλής ακρίβειας και του συνήθως χαμηλού υπολογιστικού κόστους [80]-[85].

## 2.6 Εξέλιξη μελλοντικής έρευνας και εστίαση της πρόβλεψης αιολικής και φωτοβολταϊκής ενέργειας

Κατά τη βιβλιογραφική ανασκόπηση των σύγχρονων μεθόδων πρόβλεψης, μελετήθηκε η δυνατότητα ανάπτυξης και εξέλιξής τους αλλά και οι τρόποι μείωσης των σφαλμάτων πρόβλεψης.

### 2.6.1 Βελτιστοποίηση της ακρίβειας υπαρχόντων μοντέλων πρόβλεψης

Χάρη στην εξέλιξη της τεχνολογίας, τα σύγχρονα μοντέλα πρόβλεψης έχουν αναπτυχθεί περαιτέρω τα τελευταία χρόνια και έχουν καταφέρει να μειώσουν σημαντικά το προγνωστικό σφάλμα της διαδικασίας πρόβλεψης. Ωστόσο, απαιτούνται πολλές πτυχές για τον προσδιορισμό ενός καλά κατασκευασμένου μοντέλου πρόβλεψης. Πιο συγκεκριμένα, η ακρίβεια, η αποτελεσματικότητα, η ευελιξία και το υπολογιστικό κόστος είναι βασικά χαρακτηριστικά που καθορίζουν ένα κατάλληλο μοντέλο πρόβλεψης. Πολλές φορές, απαιτείται μια αντιστάθμιση μεταξύ της ακρίβειας και των άλλων πτυχών προκειμένου να παραχθούν ακριβή μοντέλα. Χάρη στην τεχνητή νοημοσύνη και τα μοντέλα βαθιάς μάθησης, τέτοιου είδους συμβιβασμοί μπορούν να αποφευχθούν σε μεγάλο βαθμό.

Η περαιτέρω βελτίωση της ακρίβειας των υπαρχόντων μοντέλων είναι ζωτικής σημασίας [86]-[88]. Χάρη στα μετρητικά αξιολόγησης, είναι δυνατή μια μετρήσιμη σύγκριση διαφορετικών μοντέλων πρόβλεψης και έτσι η περαιτέρω μείωση του σφάλματος πρόβλεψης των μοντέλων που δίνουν χειρότερα αποτελέσματα μπορεί να επιτευχθεί ευκολότερα εστιάζοντας περισσότερο σε συγκεκριμένες λύσεις.

Τα μοντέλα που βασίζονται σε νευρωνικά δίκτυα έχουν προταθεί, όλο και περισσότερο, με τα χρόνια, βελτιώνοντας το σφάλμα πρόβλεψης των συμβατικών μοντέλων. Επιπλέον, τα σύγχρονα υβριδικά μοντέλα θα μπορούσαν να αποδειχθούν πιο αποτελεσματικά στην αντιμετώπιση των διακυμάνσεων των δεδομένων καθώς και να βελτιώσουν περαιτέρω την απόδοση των μεμονωμένων μοντέλων [89]. Επιπλέον, η ενσωμάτωση νέων αλγορίθμων βελτιστοποίησης καθώς και περαιτέρω ανάλυση δεδομένων και η προεπεξεργασία τους θα μπορούσαν να βελτιώσουν ακόμα περισσότερο την ακρίβεια πρόβλεψης των μοντέλων πρόβλεψης [90], [91].

Θα πρέπει επίσης να σημειωθεί ότι η ακρίβεια της πρόβλεψης θα μπορούσε να βελτιωθεί και να επικυρωθεί επιπλέον, όχι μόνο μέσω της ανάλυσης δεδομένων και της ανάπτυξης λογισμικού, αλλά και μέσω της βελτίωσης των υλικών της παραγωγής ενέργειας από ΑΠΕ. Τα τελευταία χρόνια, καινοτόμα εξαρτήματα έχουν συμπεριληφθεί στις φωτοβολταϊκές μονάδες αλλά και στις ανεμογεννήτριες, προκειμένου να βελτιωθεί η διαδικασία καταγραφής δεδομένων. Τέτοια εξαρτήματα περιλαμβάνουν φθηνά κατανεμημένα όργανα παρακολούθησης θερμοκρασίας και ταχύτητας ανέμου που επιτρέπουν την επί τόπου «σύλληψη» τοπικών δεδομένων. Συνοδευόμενες από ανταγωνιστικό κόστος, τέτοιες καινοτομίες θα πρέπει να συμπεριληφθούν και να αναπτυχθούν μελλοντικά, καθώς θα μπορούσαν να διευκολύνουν τη φάση προεπεξεργασίας των δεδομένων και έτσι να καταστήσουν τη διαδικασία πρόβλεψης λιγότερο περίπλοκη.

### 2.6.2 Πιθανοτική πρόβλεψη και αξιοποίησή της σε προβλήματα λήψης αποφάσεων

Τα πιο πρόσφατα χρόνια, η ανάπτυξη πιθανοτικών μεθοδολογιών πρόβλεψης βρίσκεται στο επίκεντρο της προσοχής πολλών ερευνητών, προκειμένου να κατανοήσουν και να αναλύσουν την αβεβαιότητα που υπάρχει στη διαδικασία της πρόβλεψης. Σε αντίθεση με τις σημειακές προβλέψεις, οι πιθανοτικές προβλέψεις προσφέρουν μια ευρύτερη άποψη του πιθανού αποτελέσματος μιας πρόβλεψης με τη μορφή ενός διαστήματος. Η πρόσφατη ανάπτυξη πιθανοτικών μοντέλων πρόβλεψης έχει δείξει ότι στο μέλλον, θα μπορούσαν να διαδραματίσουν σημαντικό ρόλο σε προβλήματα λήψης αποφάσεων στις αγορές ηλεκτρικής ενέργειας καθώς και στη λειτουργία των συστημάτων ηλεκτρικής ενέργειας. Ωστόσο, τρόποι αποτελεσματικής χρήσης πληροφοριών αβεβαιότητας σε προβλήματα λήψης αποφάσεων και σχεδιασμού, καθώς και τρόπος προσαρμογής των προβλημάτων λήψης αποφάσεων για την αποτελεσματική χρήση των πλεονεκτημάτων των πιθανοτικών προβλέψεων θα πρέπει να διερευνηθούν περαιτέρω στο μέλλον.

### 2.6.3 Χωροχρονικά μοντέλα πρόβλεψης

Τα χωροχρονικά μοντέλα πρόβλεψης έχουν αναπτυχθεί τα τελευταία χρόνια και εστιάζουν στην αξιοποίηση διαφορετικών μη τοπικών πληροφοριών και δεδομένων. Η ανάπτυξη της πλειονότητας των μοντέλων πρόβλεψης τα προηγούμενα χρόνια στηριζόταν κυρίως σε δεδομένα από μεμονωμένα αιολικά ή φωτοβολταϊκά πάρκα, προκειμένου να αποδειχθεί η ακρίβειά τους. Λαμβάνοντας υπόψη ότι διαφορετικές αιολικές ή φωτοβολταϊκές μονάδες κατασκευάζονται σε διαφορετικές γεωγραφικές περιοχές, πιο κοντά ή πιο μακριά το ένα από το άλλο, δεδομένα από διαφορετικές μονάδες έχει αποδειχθεί ότι βελτιώνουν περαιτέρω την ακρίβεια των μοντέλων πρόβλεψης. Δεδομένου ότι ένα μοντέλο πρόβλεψης θα μπορούσε να αναπτυχθεί για να ικανοποιήσει τις ανάγκες ενός σημαντικού συνόλου δεδομένων, χρησιμοποιώντας σύνολα δεδομένων που εκφράζουν διαφορετικά ιστορικά ή μετεωρολογικά δεδομένα, θα μπορούσε όχι μόνο να βελτιώσει την ακρίβεια και την αποτελεσματικότητα του εν λόγω μοντέλου, αλλά και να παρέχει πιο ρεαλιστικά προγνωστικά αποτελέσματα.

### 2.6.4 Αποδοτική χρήση και αξιοποίηση των μεθόδων βαθιάς μάθησης

Η πλειοψηφία των μοντέλων πρόβλεψης περιλαμβάνει την τεχνητή νοημοσύνη ως μέρος της επεξεργασίας των δεδομένων εισόδου. Τα απλά νευρωνικά δίκτυα έχουν χρησιμοποιηθεί σε πολλές περιπτώσεις ως μέρος της επεξεργασίας και της προεπεξεργασίας των δεδομένων προκειμένου να παρέχουν πιο ακριβή αποτελέσματα. Πρόσφατα, έχουν προταθεί πιο σύνθετες μεθοδολογίες βαθιάς μάθησης προκειμένου να βελτιωθεί η ακρίβεια των ήδη υπαρχουσών μεθοδολογιών καθώς και τα παρόντα νέα μοντέλα βαθιάς μάθησης για πιθανοτικές προβλέψεις ενέργειας. Κυρίως για τον τομέα της πιθανοτικής πρόβλεψης ενέργειας που πρόσφατα διερευνάται όλο και περισσότερο, υπάρχει ακόμα η δυνατότητα περαιτέρω ανάπτυξης της ακρίβειας τέτοιων μοντέλων μέσω της βελτίωσης του επιπέδου ευκρίνειας και εμπιστοσύνης.

Επιπλέον, η απλοποίηση των εν λόγω μοντέλων, καθώς και η βελτίωση του υπολογιστικού τους κόστους θα πρέπει επίσης να είναι το επίκεντρο για μελλοντική έρευνα. Δεδομένου ότι η πρόβλεψη αβεβαιότητας θα μπορούσε να αποδειχθεί εξαιρετικά χρήσιμη όσον αφορά τα προβλήματα λήψης αποφάσεων, η αντιμετώπιση προβλημάτων υψηλού υπολογιστικού κόστους σε πραγματικό χρόνο και οι καθημερινές εφαρμογές θα πρέπει επίσης

να αναπτυχθούν περαιτέρω. Παρά την πολυπλοκότητά της, η βαθιά μάθηση φαίνεται να γίνεται όλο και πιο αποτελεσματική καθώς οι προτεινόμενες μεθοδολογίες προχωρούν και εξελίσσονται συνεχώς. Πιθανά υβριδικά μοντέλα και μεθοδολογίες θα μπορούσαν να αποδειχθούν ότι βελτιώνουν την αποτελεσματική χρήση της βαθιάς μάθησης, μέσω της κοινής χρήσης των υψηλών δυνατοτήτων επεξεργασίας της ενώ ταυτόχρονα αντιμετωπίζουν πιθανά υψηλά υπολογιστικά κόστη.

### **2.6.5 Βελτίωση της επιλογής και ανάλυσης των δεδομένων εισόδου**

Με τη συνεχή ανάπτυξη των μεθοδολογιών πρόβλεψης παραγωγής από ΑΠΕ, γίνεται όλο και πιο εφικτό τα μοντέλα αυτά να χρησιμοποιούνται για προβλήματα λήψης αποφάσεων. Πιο ακριβή μοντέλα θα μπορούσαν να διαδραματίσουν σημαντικό ρόλο στην αποτελεσματική χρήση τους στις αγορές ηλεκτρικής ενέργειας. Η επιλογή δεδομένων εισόδου και η καινοτόμος ανάπτυξη μεθοδολογιών προεπεξεργασίας θα μπορούσαν να βελτιώσουν την ακρίβεια των υπαρχόντων μοντέλων. Η απλοποίηση της διαδικασίας ανάλυσης και ενσωμάτωσης των δεδομένων εισόδου καθώς και η αξιολόγηση του θορύβου και των σφαλμάτων που παράγονται από διαφορετικές μεταβλητές εισόδου, θα μπορούσε να προσφέρει καλύτερα προγνωστικά αποτελέσματα. Ως αποτέλεσμα, εκτός από την ανάπτυξη μοντέλων πρόβλεψης, θα πρέπει να διερευνηθεί περαιτέρω η σημασία της έγκυρης επιλογής δεδομένων, της αποτελεσματικής ανάλυσης και επεξεργασίας τους.

### **2.6.6 Μοντέλα εκτίμησης νεφοκάλυψης στη φωτοβολταϊκή παραγωγή**

Πρόσφατα, χάρη στην ανάπτυξη της τεχνολογίας και των μοντέλων πρόβλεψης, η νεφοκάλυψη εξετάζεται και εφαρμόζεται ως δεδομένο εισόδου σε μοντέλα πρόβλεψης ΦΒ παραγωγής. Διάφοροι αλγόριθμοι έχουν προταθεί για την ταξινόμηση της νεφοκάλυψης και έχουν χρησιμοποιηθεί αποτελεσματικά προκειμένου να βελτιωθεί η ακρίβεια της πρόβλεψης. Επιπλέον, χάρη στην εφαρμογή συσκευών απεικόνισης ουρανού, έχει σημειωθεί σημαντική πρόοδος στην εκτίμηση της διακύμανσης της ηλιακής ακτινοβολίας στην επιφάνεια κατά τη διάρκεια συννεφιασμένων καιρικών συνθηκών. Ωστόσο, νέοι αλγόριθμοι, κατασκευασμένοι για τον υπολογισμό και την ποσοτικοποίηση της συννεφιάς θα μπορούσαν να αναπτυχθούν στο μέλλον [92], [93]. Επιπλέον, ο τρόπος με τον οποίο κάθε τύπος μορφής σύννεφων επηρεάζει τα μοντέλα πρόβλεψης θα πρέπει επίσης να ενδιαφέρει μελλοντική έρευνα. Λαμβάνοντας υπόψη την τεράστια τυχαιότητα των σύννεφων, παράγοντες όπως η ταχύτητα κίνησής τους, η μορφή και το πάχος τους έχουν σημαντικό αντίκτυπο στην ακρίβεια της πρόβλεψης.

### **2.6.7 Ευελιξία και προσαρμοστικότητα των μοντέλων πρόβλεψης**

Η πλειοψηφία των μοντέλων πρόβλεψης, πέραν της διαδικασίας ανάπτυξης και εκπαίδευσής τους, επικεντρώνεται στην εκτίμηση του σφάλματος πρόβλεψης με βάση ένα συγκεκριμένο σύνολο δεδομένων που αφορά ένα συγκεκριμένο πρόβλημα [94]. Δεν είναι λίγες οι περιπτώσεις που τα μοντέλα πρόβλεψης που αναπτύσσονται είναι διαμορφωμένα για να παρέχουν προγνωστικά αποτελέσματα για συγκεκριμένες περιοχές στις οποίες έχουν καλή απόδοση, ύστερα και από την βελτιστοποίηση των υπερπαραμέτρων τους. Ωστόσο, σπάνια δοκιμάζονται σε άλλες περιοχές, είτε με παρόμοιες είτε διαφορετικές κλιματικές συνθήκες. Επιπλέον, λόγω περιορισμένης πρόσβασης σε δεδομένα, σε διάφορες περιπτώσεις χρησιμοποιούνται επανειλημμένα συγκεκριμένα δεδομένα ανοιχτής πρόσβασης. Τέτοιοι περιορισμοί πρέπει να ξεπεραστούν και η ανάγκη ανάπτυξης μοντέλων πρόβλεψης που να είναι

αποτελεσματικά παρά τα δεδομένα εισόδου και τις κλιματικές συνθήκες, καθώς και την αξιολόγησή τους σε διαφορετικές περιοχές πρέπει να ερευνηθεί περαιτέρω. Επιπλέον, πρέπει να σημειωθεί ότι η μεταβλητότητα της παραγωγής ενέργειας είναι μείζονος σημασίας για την εκτίμηση της ικανότητας πρόβλεψης. Η καλύτερη ερμηνεία των πληροφοριών που παρέχονται από τέτοια δεδομένα μεταβλητότητας θα μπορούσε να βελτιώσει ακόμα περισσότερο την προσαρμοστικότητα και την ευελιξία των μοντέλων πρόβλεψης σε διαφορετικές συνθήκες.

#### **2.6.8 Προστασία δεδομένων**

Λόγω της ταχείας και συνεχούς βελτίωσης και ανάπτυξης των μεθοδολογιών πρόβλεψης, η απόκτηση δεδομένων και πιο συγκεκριμένα δεδομένων υψηλής ακρίβειας έχει γίνει μια μεγάλη πρόκληση. Ωστόσο, ενώ η απόκτηση δεδομένων ήταν το κύριο πρόβλημα και η κύρια εστίαση τα τελευταία χρόνια, το απόρρητο των δεδομένων έχει παραμεληθεί αρκετά. Ο όρος «απόρρητο δεδομένων» αναφέρεται στην προστασία ευαίσθητων και εμπιστευτικών πληροφοριών της διαδικασίας πρόβλεψης. Αυτές οι πληροφορίες μπορεί να περιλαμβάνουν προσωπικά ή οικονομικά δεδομένα που μπορεί να επηρεάσουν τη διαδικασία πρόβλεψης. Ως αποτέλεσμα, στα σύγχρονα ενεργειακά συστήματα, η ενίσχυση της ασφάλειας και η επίτευξη του απορρήτου των δεδομένων γίνεται μια σημαντική πρόκληση [95]. Τα κοινά προβλήματα προστασίας απορρήτου δεδομένων μπορεί να περιλαμβάνουν την κοινή χρήση δεδομένων μεταξύ οργανισμών, τη διατήρηση δεδομένων στα μοντέλα πρόβλεψης, τις παραβιάσεις δεδομένων και τις επιθέσεις στον κυβερνοχώρο [96] καθώς και τη μη συμμόρφωση με τους υφιστάμενους νόμους περί προστασίας δεδομένων. Ως εκ τούτου, η προστασία του απορρήτου των δεδομένων θα πρέπει να λαμβάνεται υπόψη κατά την ανάπτυξη και την κατασκευή νέων μοντέλων πρόβλεψης στο μέλλον.

# Κεφάλαιο 3

## ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

### 3.1 Εισαγωγή


Τα τεχνητά νευρωνικά δίκτυα αποτελούν σήμερα τη δημοφιλέστερη βάση των μοντέλων πρόβλεψης, τόσο γενικά, όσο και ειδικά στην πρόβλεψη παραγωγής από ΑΠΕ. Η λογική πίσω από τη δομή των τεχνητών νευρωνικών δικτύων βρίσκεται στη βιολογία [97].

Τα ΤΝΔ αρχικά ορίστηκαν ως μια προσπάθεια μαθηματικής μοντελοποίησης και προσομοίωσης της πολύπλοκης λειτουργίας του ανθρώπινου εγκεφάλου. Η φυσική δομή του εγκεφάλου επιτρέπει αφενός την παράλληλη επεξεργασία ποικίλων και μεγάλου όγκου δεδομένων και αφετέρου τη δυνατότητα συνεχούς εκπαίδευσης και μάθησης αλληλεπιδρώντας με το περιβάλλον, λαμβάνοντας υπόψη πολυάριθμα ερεθίσματα. Τα παραπάνω χαρακτηριστικά, δίνουν τη δυνατότητα συνεχούς προσαρμογής και εξέλιξης της λειτουργίας του εγκεφάλου, επιτρέποντας ταχύτατες διεργασίες και συνεχή βελτίωση των δυνατοτήτων του.

Αντίστοιχα, τα τεχνητά νευρωνικά δίκτυα αναπτύχθηκαν με τέτοιο τρόπο ώστε να μιμούνται τις παραπάνω ιδιότητες του βιολογικού δικτύου νευρώνων του εγκεφάλου [98]. Βασικό δομικό στοιχείο των ΤΝΔ αποτελεί ο νευρώνας, ο οποίος λαμβάνει το πλήθος των ερεθισμάτων από άλλους κόμβους και στη συνέχεια υπολογίζει μια έξοδο, συναρτήσει των δεδομένων εισόδου που προσλαμβάνει [99]. Το μαθηματικό μοντέλο ενός τυπικού νευρώνα ενός ΤΝΔ φαίνεται στο Σχήμα 3.1.

Κάθε νευρώνας δέχεται δεδομένα εισόδου, είτε από άλλους νευρώνες ( $x_1, x_2, \dots, x_m$ ), είτε από εξωτερικούς παράγοντες (πόλωση  $b$ ) και παράγει την έξοδο  $y$ . Το σύνολο των νευρώνων του ΤΝΔ αλληλεπιδρούν μεταξύ τους συνδεόμενοι με τις συνάψεις. Ο βαθμός και η σημασία της αλληλεπίδρασης μεταξύ ενός ζεύγους νευρώνων διαφέρει και καθορίζεται από τα συναπτικά βάρη ( $w_1, w_2, \dots, w_n$ ).

Καθώς το νευρωνικό δίκτυο εκπαιδεύεται και γίνεται όλο και “εξυπνότερο”, τα συναπτικά βάρη μεταβάλλονται συνεχώς, κάνοντας τους δεσμούς μεταξύ των νευρώνων ισχυρότερους ή πιο αδύναμους [100]. Η παραπάνω διαδικασία, αναδεικνύει πόσο ισχυρός είναι ο δεσμός μεταξύ ενός ζεύγους νευρώνων και συνεπώς τη σημασία των δεδομένων εισόδου στην εκπαίδευση του ΤΝΔ. Τα συναπτικά βάρη επί της ουσίας μεταφράζουν τη γνώση που λαμβάνει το ΤΝΔ από το περιβάλλον, δηλαδή από τα εισαγόμενα σε αυτό δεδομένα και τονίζουν τη δυνατότητα των ΤΝΔ να προσαρμόζονται στο εκάστοτε πρόβλημα.



**Σχήμα 3.1** Αποτύπωση τυπικού νευρώνα τεχνητού νευρωνικού δικτύου

Η συνολική είσοδος του νευρώνα του Σχήματος 3.1 είναι:

$$z = w_1 x_1 + w_2 x_2 + \dots + w_m x_m + b \quad (3.1)$$

Η έξοδος του νευρώνα του Σχήματος 3.1 υπολογίζεται ως εξής:


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

Η έξοδος  $y$  παράγεται εφαρμόζοντας το άθροισμα της συνολικής εισόδου στη συνάρτηση ενεργοποίησης  $f$ . Θεωρώντας την πόλωση ως σταθερά, η οποία αποδίδει στον νευρώνα την ευελιξία για να βρεθεί η βέλτιστη δυνατή προσέγγιση, η τελική έξοδος του νευρώνα απεικονίζεται καλύτερα με την παρακάτω σχέση [101]:

$$y = f\left(\sum_{i=1}^m (w_i x_i + b)\right) \quad (3.3)$$

### 3.2 Αρχιτεκτονική τεχνητών νευρωνικών δικτύων

Η αρχιτεκτονική των ΤΝΔ μπορεί να ποικίλει από πολύ απλή μέχρι πολύ σύνθετη. Οι νευρώνες των ΤΝΔ είναι οργανωμένοι σε επίπεδα ή στρώματα [102]. Το στρώμα εισόδου και το στρώμα εξόδου αποτελούν δομικά στοιχεία της αρχιτεκτονικής των ΤΝΔ, ενώ το ενδιάμεσο κρυφό ή κρυφά στρώματα καθορίζουν την πολυπλοκότητα του νευρωνικού δικτύου.



**Σχήμα 3.2** Τυπικό πολυεπίπεδο Perceptron.

- **Στρώμα εισόδου (Input Layer)**


Το στρώμα εισόδου αποτελείται από όλες τις μεταβλητές οι οποίες εισάγονται στο ΤΝΔ. Κάθε μεταβλητή εισόδου αντιστοιχεί σε έναν νευρώνα. Οι νευρώνες του στρώματος εισόδου συνδέονται απευθείας είτε με τους νευρώνες του επόμενου κρυφού στρώματος, είτε (σπανιότερα) απευθείας με τους νευρώνες του στρώματος εξόδου.

- **Κρυφά στρώματα (Hidden Layers)**

Ο αριθμός των κρυφών στρωμάτων μπορεί να ποικίλει, ανάλογα με τις απαιτήσεις του προβλήματος και την επεξεργαστική πολυπλοκότητα των δεδομένων εισόδου. Οι νευρώνες ενός κρυφού στρώματος συνδέονται με διάφορους τρόπους με τους νευρώνες του επόμενου κρυφού στρώματος, ή με τους νευρώνες του στρώματος εξόδου [103]. Η εισαγόμενη πληροφορία στους νευρώνες ενός κρυφού στρώματος μπορεί να προέρχεται απευθείας από το στρώμα εισόδου είτε από την εξαγόμενη πληροφορία του προηγούμενου κρυφού στρώματος.

- **Στρώμα εξόδου (Output Layer)**

Από το στρώμα εξόδου διέρχεται το διάνυσμα εξόδου του συνολικού ΤΝΔ. Ο αριθμός των νευρώνων του στρώματος εξόδου ισούται με τις ζητούμενες μεταβλητές εξόδου από το ΤΝΔ. Η εισαγόμενη πληροφορία στο στρώμα εξόδου μπορεί να προέρχεται είτε απευθείας από το στρώμα εισόδου, είτε από την τελική επεξεργαζόμενη έξοδο από το τελευταίο κρυφό στρώμα.



**Σχήμα 3.3** Απλοποιημένη σχηματική απεικόνιση αναδρομικού νευρωνικού δικτύου.

Τα ΤΝΔ, βάσει της αρχιτεκτονικής τους, μπορούν να διακριθούν σε δυο βασικές κατηγορίες, τα δίκτυα εμπρόσθιας τροφοδότησης και τα αναδρομικά δίκτυα [28].

### 3.2.1 Τεχνητά νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης ενός επιπέδου (Single-Layer Perceptron)

Αποτελούν την πιο απλή μορφή ΤΝΔ. Τα δίκτυα εμπρόσθιας τροφοδότησης χαρακτηρίζονται από τη μονόδρομη πορεία της πληροφορίας, από το στρώμα εισόδου προς τα κρυφά στρώματα καταλήγοντας στο στρώμα εξόδου.

Πιο συγκεκριμένα, αυτό το είδος νευρωνικών δικτύων είναι η πιο απλή μορφή ΤΝΔ. Αποτελείται μόνο από το στρώμα εισόδου και το επίπεδο εξόδου, με την πληροφορία να εισάγεται από το στρώμα εισόδου και μεταφέρεται προς το στρώμα εξόδου [104]. Στο στρώμα εισόδου επιτελείται μόνο η μεταφορά της πληροφορίας προς το στρώμα εξόδου, χωρίς να γίνεται οποιουδήποτε είδους επεξεργασία.

### 3.2.2 Πολυεπίπεδα τεχνητά νευρωνικά δίκτυα (Multi-Layer Perceptron)

Τα πολυεπίπεδα ΤΝΔ εμπρόσθιας τροφοδότησης είναι τα πιο συχνά χρησιμοποιούμενα ΤΝΔ εμπρόσθιας τροφοδότησης. Όπως αποτυπώνεται και στο Σχήμα 3.2, η ουσιαστική διαφορά με τα αντίστοιχα δίκτυα εμπρόσθιας τροφοδότησης ενός επιπέδου είναι η χρήση κρυφών στρωμάτων. Η χρήση όλο και περισσότερων κρυφών στρωμάτων αυξάνει την πολυπλοκότητα του ΤΝΔ, βελτιώνοντας ωστόσο την δυναμική και την υπολογιστική του ισχύ [105]. Η χρήση κρυφών στρωμάτων επιτρέπει στα ΤΝΔ να ανταποκρίνονται στις ανάγκες σύνθετων προβλημάτων του πραγματικού κόσμου.

Η παραμετροποίηση αυτών των νευρωνικών δικτύων ουσιαστικά αφορά στην επιλογή του αριθμού των κρυφών στρωμάτων αλλά και του αριθμού των νευρώνων που έχει κάθε

στρώμα. Στο στρώμα εξόδου εφαρμόζεται συνήθως διαφορετική συνάρτηση ενεργοποίησης από αυτή που χρησιμοποιείται στα κρυφά στρώματα, ανάλογα το πρόβλημα που χρειάζεται να αντιμετωπίσει ο χρήστης. Οι νευρώνες ενός στρώματος συνδέονται με όλους τους νευρώνες του επόμενου στρώματος, χωρίς όμως να συνδέονται με τους νευρώνες εντός του ίδιου στρώματος.

### 3.2.3 Αναδρομικά νευρωνικά δίκτυα

Η όλο και πιο συχνή χρήση των ΤΝΔ σε πιο πολύπλοκα προβλήματα, έχει οδηγήσει στην επιπλέον αξιολόγηση των απαιτήσεων των ΤΝΔ από τον χρήστη και τον εντοπισμό των περιθωρίων εξέλιξής τους από τους χρήστες. Στα δίκτυα εμπρόσθιας τροφοδότησης, οι εισόδοι των νευρώνων είναι ανεξάρτητες μεταξύ τους και η πληροφορία μεταφέρεται μονόδρομα από στο στρώμα εισόδου μέχρι και το στρώμα εξόδου.

Η πολυπλοκότητα των προβλημάτων του πραγματικού κόσμου ωστόσο δεν λειτουργεί πάντα μονόδρομα. Τα αναδρομικά νευρωνικά δίκτυα επιτρέπουν τη μεταφορά της πληροφορίας τόσο μεταξύ των νευρώνων του ίδιου στρώματος, όσο και προς προηγούμενα στρώματα [106]. Στην ουσία, ο όρος “αναδρομικό νευρωνικό δίκτυο”, προκύπτει από τη δυνατότητα που προσφέρει η αρχιτεκτονική αυτών των δικτύων να εκτελούν την ίδια εργασία, για κάθε στοιχείο μίας αλληλουχίας, με το αποτέλεσμα να εξαρτάται από τους προηγούμενους υπολογισμούς που έχουν πραγματοποιηθεί. Δημιουργείται δηλαδή, η έννοια της ύπαρξης “μνήμης” πληροφοριών σε αυτού του τύπου τα δίκτυα. Μια απλοποιημένη απεικόνιση της λειτουργίας του αναδρομικού ΤΝΔ φαίνεται στο Σχήμα 3.3.

### 3.3 Συναρτήσεις ενεργοποίησης

Οι συναρτήσεις ενεργοποίησης αποτελούν βασικά δομικά στοιχεία των ΤΝΔ, προσδίδοντάς τους την απαραίτητη μη γραμμικότητα ώστε να γίνεται εφικτή η υλοποίηση και αντιμετώπιση πολύπλοκων προβλημάτων του πραγματικού κόσμου [107]. Οι νευρώνες του ΤΝΔ λαμβάνουν συνεχώς ερεθίσματα και πληροφορίες τις οποίες καλούνται να επεξεργαστούν και να μεταφέρουν τα αποτελέσματα της επεξεργασίας στους επόμενους νευρώνες.

Κάθε νευρώνας σε ένα ΤΝΔ εφαρμόζει μια συνάρτηση ενεργοποίησης στο σταθμισμένο άθροισμα των εισόδων του για να εισαγάγει μη γραμμικότητα και να συλλάβει πολύπλοκα μοτίβα στα δεδομένα. Στη συνέχεια, η συνάρτηση ενεργοποίησης πρακτικά επιλέγει τον βαθμό της πληροφορίας που θα περάσει στον επόμενο νευρώνα, ρυθμίζοντας την πολυπλοκότητα της πληροφορίας αλλά και το εύρος της.

Η επιλογή της συνάρτησης ενεργοποίησης παίζει ουσιαστικό ρόλο στη λειτουργία του δικτύου, αφού ανάλογα το πρόβλημα, η κατάλληλη συνάρτηση μπορεί να συμβάλλει σημαντικά στη βελτίωση της απόδοσης του δικτύου. Υπάρχουν διάφορες συναρτήσεις ενεργοποίησης που χρησιμοποιούνται στα νευρωνικά δίκτυα με τις πιο ευρέως γνωστές να είναι η συνάρτηση διορθωμένης γραμμικής μονάδας (Rectified Linear Unit – ReLU), η σιγμοειδής και η συνάρτηση υπερβολικής εφαπτομένης (tanh). Οι παραπάνω συναρτήσεις αποτυπώνονται στο Σχήμα 3.4, και ορίζονται ως εξής:


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

$$f_{ReLU}(z) = \max(0, z) \quad (3.5)$$

$$f_{tanh}(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (3.6)$$

Η σιγμοειδής συνάρτηση συμπίπτει τις τιμές εισόδου στην περιοχή  $[0, 1]$  και χρησιμοποιείται συχνά στο επίπεδο εξόδου για προβλήματα δυαδικής ταξινόμησης [108]. Η συνάρτηση υπερβολικής εφαπτομένης ( $\tanh$ ) είναι παρόμοια με τη σιγμοειδή, αλλά αντιστοιχίζει τις τιμές στην περιοχή  $[-1, 1]$ , καθιστώντας την μηδενική στο κέντρο και κατάλληλη για κρυφά επίπεδα [109]. Η ReLU υιοθετείται ευρέως, θέτοντας αρνητικές τιμές στο 0, το οποίο βοηθά στην καταπολέμηση του προβλήματος της εξαφάνισης της κλίσης και προσφέρει υπολογιστική απόδοση [110].

Η επιλογή της κατάλληλης συνάρτησης ενεργοποίησης εξαρτάται από το εκάστοτε πρόβλημα αλλά και τα χαρακτηριστικά των δεδομένων. Για τα βαθιά νευρωνικά δίκτυα, η ReLU και οι παραλλαγές της συχνά προτιμώνται λόγω της αποτελεσματικότητάς τους κατά την διαδικασία εκπαίδευσης του δικτύου. Οι sigmoid και tanh συναρτήσεις βρίσκουν χρησιμότητα στο στρώμα εξόδου για εργασίες ταξινόμησης δυαδικών ή και πολλαπλών κλάσεων. Η επιλογή μπορεί επίσης να εξετάσει προκλήσεις όπως εξαφανιζόμενες κλίσεις ή νεκρούς νευρώνες.



**Σχήμα 3.4** Συναρτήσεις ενεργοποίησης, (α) σιγμοειδής συνάρτηση, (β) συνάρτηση υπερβολικής εφαπτομένης, (γ) συνάρτηση ReLU.

### 3.4 Εκπαίδευση τεχνητών νευρωνικών δικτύων

Η διαδικασία εκπαίδευσης ενός ΤΝΔ είναι αυτή που του επιτρέπει να αναπτύσσει την ικανότητα να εντοπίζει σχέσεις και μοτίβα μεταξύ των δεδομένων που του τροφοδοτούνται ώστε να μπορεί στη συνέχεια να εκτελεί πολύπλοκες λειτουργίες, όπως η πρόβλεψη ή η ταξινόμηση. Ως εκπαίδευση του νευρωνικού δικτύου μπορεί να θεωρηθεί η διαδικασία συνεχούς και επαναλαμβανόμενης τροφοδότησής του με ένα σύνολο δεδομένων εισόδου και η παραμετροποίηση των βαρών και των πολώσεων ώστε κάθε νευρώνας να δίνει τη βέλτιστη τιμή εξόδου. Τα δεδομένα που χρησιμοποιούνται για τη διαδικασία εκπαίδευσης αποτελούν το σύνολο εκπαίδευσης και αποτελούν ποσοστό του συνολικού όγκου των δεδομένων. Υπάρχουν δύο μέθοδοι εκπαίδευσης των τεχνητών νευρωνικών δικτύων, η επιτηρούμενη εκπαίδευση και η μη επιτηρούμενη εκπαίδευση [111].

#### 3.4.1 Επιτηρούμενη εκπαίδευση

Η επιτηρούμενη εκπαίδευση προκύπτει από την εισαγωγή από τον χρήστη ενός συνόλου δεδομένων εισόδου αλλά και των επιθυμητών τιμών εξόδου. Οι τιμές εξόδου που προ-εισάγονται αποτελούν τους “στόχους” του νευρωνικού δικτύου τις οποίες πρέπει να προσεγγίζουν οι προβλέψεις του ΤΝΔ ώστε να είναι αποδοτικό.

Αρχικά, τα βάρη και οι πολώσεις αρχικοποιούνται είτε με τυχαίο τρόπο είτε με κάποια μέθοδο αρχικοποίησης που ορίζεται από τον χρήστη. Στη συνέχεια, το ΤΝΔ τροφοδοτείται συνεχώς και κατά επανάληψη με το σύνολο των δεδομένων εκπαίδευσης, παραμετροποιώντας σε κάθε επανάληψη τα βάρη και τις πολώσεις κατά τέτοιο τρόπο ώστε, για κάθε δεδομένο εισόδου να προσεγγίζεται επαρκώς η επιθυμητή έξοδος. Στόχος της αναπροσαρμογής των βαρών και των πολώσεων είναι η όσο το δυνατόν βέλτιστη μείωση της απόκλισης μεταξύ των πραγματικών και των προβλεπόμενων εξόδων. Όταν η απόκλιση αυτή έχει φτάσει σε μια επιθυμητή διαφορά, οι τιμές των βαρών και των πολώσεων σταθεροποιούνται και ολοκληρώνεται η διαδικασία της εκπαίδευσης.

Μετά τη βέλτιστη σύγκλιση των βαρών και των πολώσεων, τροφοδοτούνται στο ΤΝΔ επιπλέον δεδομένα ώστε να εξεταστεί και να αξιολογηθεί η απόδοση του και σε δεδομένα πέραν αυτών που χρησιμοποιήθηκαν για την εκπαίδευσή του. Το νέο σύνολο των δεδομένων αποτελεί το σύνολο αξιολόγησης [98]. Συχνά, η διαδικασία εκπαίδευσης συνεχίζει να τρέχει παράλληλα με το στάδιο της αξιολόγησης, επιτρέποντας στο ΤΝΔ να προχωράει σε επιπλέον παραμετροποίηση, βελτιώνοντας την προσαρμοστικότητα και την απόδοση του μοντέλου, αλλά αυξάνοντας ταυτόχρονα τον χρόνο τρεξίματος του μοντέλου πρόβλεψης.

Η πλειοψηφία των ΤΝΔ βασίζονται στην επιτηρούμενη εκπαίδευση, τόσο χάρη στην αποτελεσματικότητα και την ακρίβειά της, όσο και στον έλεγχο που προσφέρουν στον χρήστη.

#### 3.4.2 Μη επιτηρούμενη εκπαίδευση

Στη μη επιτηρούμενη εκπαίδευση, στο ΤΝΔ τροφοδοτείται αποκλειστικά με τα δεδομένα εισόδου, παραλείποντας τις επιθυμητές τιμές εξόδου. Στην περίπτωση αυτή, το νευρωνικό δίκτυο καλείται μέσα από τη διαδικασία της εκπαίδευσής του να οδηγηθεί σε δικά του συμπεράσματα για την ιδανική έξοδο. Αξιολογώντας τα δεδομένα εισόδου, το ΤΝΔ εντοπίζει μοτίβα ή στατιστικές συσχετίσεις μεταξύ των δεδομένων ώστε να οδηγηθεί στη βέλτιστη, για

εκείνο, πρόβλεψη. Η μόνη ουσιαστική παρέμβαση που μπορεί να έχει ο χρήστης, είναι στην αρχιτεκτονική του νευρωνικού δικτύου, ή μέσω κάποιων κανόνων μάθησης, τα οποία μπορούν να καθοδηγήσουν σε ένα βαθμό τον τρόπο λειτουργίας και εκμάθησης του ΤΝΔ [98].

Η μη επιτηρούμενη εκπαίδευση, υστερεί σε απόδοση και ακρίβεια της επιτηρούμενης εκπαίδευσης, ωστόσο είναι ταχύτερη από εκείνη. Κατά κύριο λόγο χρησιμοποιείται για να γίνει κάποια αρχική κατηγοριοποίηση των δεδομένων εισόδου [112].

### **3.5 Αντικειμενική συνάρτηση**

Η αντικειμενική συνάρτηση, συχνά αναφερόμενη και ως συνάρτηση απώλειας ή συνάρτηση κόστους, παίζει θεμελιώδη ρόλο στην εκπαίδευση και τη βελτιστοποίηση των νευρωνικών δικτύων. Χρησιμεύει ως κρίσιμο συστατικό της διαδικασίας μάθησης του νευρωνικού δικτύου, ποσοτικοποιώντας την επίδοση του μοντέλου πρόβλεψης όσον αφορά τις προβλέψεις του σε σύγκριση με τις πραγματικές τιμές της ζητούμενης μεταβλητής. Η αντικειμενική συνάρτηση ουσιαστικά ποσοτικοποιεί το "κόστος" που σχετίζεται με το τρέχον σύνολο παραμέτρων του ΤΝΔ. Στόχος του δικτύου κατά τη διάρκεια της εκπαίδευσης είναι να ελαχιστοποιήσει αυτό το κόστος, βελτιώνοντας έτσι την ικανότητά του να κάνει ακριβείς προβλέψεις.

Η αντικειμενική συνάρτηση είναι συνήθως μια μαθηματική έκφραση που λαμβάνει ως είσοδο τις προβλέψεις του μοντέλου και τις αντίστοιχες πραγματικές τιμές. Υπολογίζει την ασυμφωνία μεταξύ αυτών των προβλέψεων και των πραγματικών τιμών, παρέχοντας μια ενιαία κλιμακωτή τιμή που αντιπροσωπεύει τον βαθμό σφάλματος της πρόβλεψης.

Κατά τη διάρκεια της εκπαιδευτικής διαδικασίας, το ΤΝΔ χρησιμοποιεί τεχνικές βελτιστοποίησης, ώστε να προσαρμόσει τις εσωτερικές του παραμέτρους (συναπτικά βάρη και πολώσεις) για να ελαχιστοποιήσει την τιμή της αντικειμενικής συνάρτησης. Αυτή η επαναληπτική διαδικασία περιλαμβάνει τον υπολογισμό της κλίσης της αντικειμενικής συνάρτησης σε σχέση με τις παραμέτρους του μοντέλου, η οποία υποδεικνύει την κατεύθυνση και το μέγεθος της απαιτούμενης παραμετροποίησης για τη μείωση του σφάλματος. Στη συνέχεια, το μοντέλο ενημερώνει τις παραμέτρους του προς αυτή την κατεύθυνση, προχωρώντας σταδιακά προς μια κατάσταση όπου η αντικειμενική συνάρτηση φτάνει μια ελάχιστη δυνατή τιμή. Αυτό είναι το σημείο στο οποίο οι προβλέψεις του δικτύου ευθυγραμμίζονται όσο το δυνατόν περισσότερο με τις πραγματικές τιμές.

### **3.6 Μετρητικά αξιολόγησης μοντέλων πρόβλεψης**

Η αξιολόγηση των μοντέλων πρόβλεψης αποτελεί ένα σημαντικό στάδιο της επιτυχούς εκτίμησης της παραγωγής ηλεκτρικής ενέργειας από ΑΠΕ. Η συνεχής αύξηση της ένταξης τόσο αιολικής, όσο και ΦΒ παραγόμενης ενέργειας στο ηλεκτρικό δίκτυο επιβάλλει την όλο και ακριβέστερη πρόβλεψή τους. Το ουσιαστικό αποτέλεσμα της ακριβούς πρόβλεψης είναι η ομαλότερη δυνατή ενσωμάτωση των ΑΠΕ στο ενεργειακό δίκτυο μέσω του βέλτιστου προγραμματισμού και ελέγχου.

Όπως περιγράφηκε στο Κεφάλαιο 2, υπάρχουν πολυάριθμες μέθοδοι πρόβλεψης παραγωγής ΦΒ και αιολικής ενέργειας. Η αξιολόγηση των μοντέλων και η εκτίμηση του σφάλματος πρόβλεψης είναι απαραίτητη ώστε να εξασφαλιστεί η ικανότητα των μοντέλων πρόβλεψης να εκτιμούν σε επαρκή βαθμό την παραγόμενη ισχύ [28]. Η αξιολόγηση επιτυγχάνεται μέσω της χρήσης διάφορων μετρητικών σύγκρισης που αξιολογούν τις προβλεπόμενες τιμές ισχύος σε σχέση με τις πραγματικές τιμές ισχύος. Μέσω της χρήσης των μετρητικών αξιολόγησης, γίνεται εφικτή η σύγκριση των διαφορετικών μοντέλων πρόβλεψης που μπορούν να εφαρμοστούν σε ένα συγκεκριμένο πρόβλημα και η επιλογή της βέλτιστης μεθοδολογίας. Επιπλέον, επιτρέπει την κατανόηση του τρόπου λειτουργίας των μοντέλων πρόβλεψης σε διαφορετικά προβλήματα, διαφορετικά διαθέσιμα δεδομένα και διαφορετικές μετεωρολογικές συνθήκες. Τέλος, και ίσως και σημαντικότερη, είναι η συμβολή της διαδικασίας αξιολόγησης των μοντέλων πρόβλεψης στον εντοπισμό πιθανών σημείων βελτίωσής τους. Κατά τη σύγκριση των μοντέλων, μπορούν να εκτιμηθούν τα πλεονεκτήματα και τα μειονεκτήματα των διαφορετικών μεθοδολογιών και συνεπώς να εντοπιστούν πιθανές δυνατότητες βελτιστοποίησης των μοντέλων πρόβλεψης.

Όπως γίνεται εύκολα κατανοητό, η συμβολή της αξιολόγησης των μοντέλων πρόβλεψης είναι μείζονος σημασίας για την ομαλή και ελεγχόμενη ενσωμάτωση των ΑΠΕ στο δίκτυο ηλεκτρικής ενέργειας. Η βελτίωση της αξιοπιστίας των μοντέλων πρόβλεψης παραγωγής από ΑΠΕ είναι σημαντική τόσο στην αιτιοκρατική πρόβλεψη όσο και στην πιθανοτική. Όπως είναι αναμενόμενο, η αιτιοκρατική πρόβλεψη χρησιμοποιεί μετρητικά αξιολόγησης τα οποία εκτιμούν τη σύγκλιση (ή απόκλιση) της προβλεπόμενης τιμής από την πραγματική. Παρόλα αυτά, η αβεβαιότητα της πρόβλεψης δεν είναι δυνατόν να αποτυπωθεί με τη χρήση των μετρητικών αιτιοκρατικής πρόβλεψης. Τα μετρητικά πιθανοτικής πρόβλεψης, κατά ένα πιο περίπλοκο τρόπο από τα αιτιοκρατικά μετρητικά, αξιολογούν την πρόβλεψη τόσο βάσει της ποιότητας της πρόβλεψης όσο και από τη σκοπιά της ευκρίνειας και της αξιοπιστίας τους. Κατά αυτό τον τρόπο, η πιθανοτική πρόβλεψη μπορεί να παρέχει μια πιο πλήρη εικόνα για την επίδοση και την απόδοση των μοντέλων πιθανοτικής πρόβλεψης καλύπτοντας και την πλευρά της αβεβαιότητας των προβλεπόμενων τιμών.

### 3.6.1 Αιτιοκρατικά μετρητικά αξιολόγησης

Τα αιτιοκρατικά μετρητικά αξιολόγησης βασίζονται στο να αναδείξουν αριθμητικά ή ποσοστιαία τη διαφορά μεταξύ πραγματικών και προβλεπόμενων τιμών παραγόμενης ισχύος. Κατά τον τρόπο αυτό, ποσοτικοποιείται το σφάλμα πρόβλεψης μεταξύ πραγματικών και προβλεπόμενων τιμών, επιτρέποντας έτσι την εκτίμηση της απόδοσης του εκάστοτε μοντέλου πρόβλεψης αλλά και τη σύγκριση του με άλλα μοντέλα.

- **Μεροληψία (Bias)**

Η μεροληψία αντιπροσωπεύει μια ζωτική πτυχή της αξιολόγησης της απόδοσης του μοντέλου πρόβλεψης. Υποδηλώνει τα συστηματικά σφάλματα ή τις συνεπείς αποκλίσεις μεταξύ των προβλέψεων ενός μοντέλου και των πραγματικών τιμών. Στην ουσία, το σφάλμα μεροληψίας χαρακτηρίζει πόσο καλά ένα νευρωνικό δίκτυο γενικεύεται σε νέα δεδομένα ενώ χειρίζεται συστηματικά σφάλματα στις προβλέψεις του. Ουσιαστικά, η εκτίμηση της

μεροληψίας δείχνει εάν ένα μοντέλο πρόβλεψης εκτελεί υπο-πρόβλεψη ή υπερ-πρόβλεψη των αποτελεσμάτων. Η μεροληψία μπορεί να εκτιμηθεί ως εξής:

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

όπου  $N$  είναι το σύνολο των παρατηρήσεων,  $y_i$  είναι η πραγματική τιμή για την  $i$ -οστή παρατήρηση και  $\hat{y}_i$  είναι η προβλεπόμενη τιμή για την  $i$ -οστή παρατήρηση. Μηδενική τιμή της μεροληψίας, δείχνει ότι το μοντέλο πρόβλεψης είναι κατά μέσο όρο ακριβές. Η θετική μεροληψία δείχνει ότι το μοντέλο πρόβλεψης κάνει υπερεκτίμηση του αποτελέσματος, ενώ η αρνητική μεροληψία δείχνει ότι το μοντέλο υποεκτιμά το αποτέλεσμα.

Η μεροληψία συνδέεται με την υποπροσαρμογή, μια συνθήκη όπου το μοντέλο είναι πολύ απλοϊκό για να καταγράψει τα υποκείμενα μοτίβα στα δεδομένα. Η υψηλή μεροληψία υποδηλώνει ότι το μοντέλο τείνει να κάνει συστηματικά λάθη αποκλίνοντας σταθερά από τις πραγματικές τιμές.

Η αξιολόγηση και ο μετριασμός της μεροληψίας είναι ένα κρίσιμο βήμα για την ανάπτυξη και τη βελτίωση του μοντέλου. Οι τεχνικές για την αξιολόγηση της μεροληψίας περιλαμβάνουν τη σύγκριση του μέσου όρου των προβλέψεων του μοντέλου με τον μέσο όρο των πραγματικών δεδομένων. Η μεροληψία μπορεί να αντιμετωπιστεί με διάφορα μέσα, όπως η προσαρμογή της αρχιτεκτονικής του μοντέλου, η ενίσχυση της ποικιλομορφίας των δεδομένων εκπαίδευσης και η ενσωμάτωση τεχνικών διόρθωσης μεροληψίας.

- **Μέσο απόλυτο σφάλμα**

Το μέσο απόλυτο σφάλμα (Mean Absolute Error – MAE) αποτελεί το πιο συχνό μετρητικό αξιολόγησης στην αιτιοκρατική πρόβλεψη. Υπολογίζει την μέση απόλυτη τιμή της διαφοράς μεταξύ της προβλεπόμενης τιμής από την πραγματική τιμή για το σύνολο των τιμών [113]. Υπολογίζεται από τη σχέση:

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

Όπως είναι προφανές, όσο μικρότερη είναι η τιμή του MAE, τόσο πιο ακριβής είναι και η πρόβλεψη, αφού αυτό σημαίνει ότι οι τιμές πρόβλεψης είναι πιο κοντά στις πραγματικές τιμές. Το MAE αποτελεί ένα ευρέως χρησιμοποιούμενο μετρητικό αξιολόγησης, καθώς προσφέρει ευκολία στην κατανόηση και την ερμηνεία, ενώ ο υπολογισμός του είναι ιδιαίτερα απλός. Αξίζει παρόλα αυτά να σημειωθεί ότι είναι ευαίσθητο σε ακραίες τιμές, εξαιτίας των οποίων συχνά μπορεί να μην δίνει “αντικειμενικά” αποτελέσματα.

- **Μέσο απόλυτο ποσοστιαίο σφάλμα**

Βασισμένο στο μέσο απόλυτο σφάλμα, το μέσο απόλυτο ποσοστιαίο σφάλμα (Mean Absolute Percentage Error – MAPE) είναι ένα εξίσου ευρέως χρησιμοποιούμενο μετρικό αξιολόγησης το οποίο υπολογίζει την μέση απόλυτη ποσοστιαία διαφορά μεταξύ της προβλεπόμενης τιμής από την πραγματική τιμή για το σύνολο των τιμών [113]. Το MAPE υπολογίζεται από τη σχέση:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|\hat{y}_i - y_i|}{y_i} \times 100\% \quad (3.9)$$

Όπως και στην περίπτωση του MAE, η όσο χαμηλότερη τιμή του MAPE υποδηλώνει και μεγαλύτερη ακρίβεια του μοντέλου πρόβλεψης. Παρόλα αυτά, η χρήση του MAPE μπορεί να έχει σημαντικούς περιορισμούς, κυρίως σε περιπτώσεις που οι πραγματικές τιμές είναι μηδενικές, όπως για παράδειγμα η μηδενική παραγωγή από την ηλιακή ενέργεια τις νυχτερινές ώρες. Το MAPE είναι ιδιαίτερα χρήσιμο στην αξιολόγηση περιπτώσεων που η κλίμακα των δεδομένων ποικίλει.

- **Μέσο τετραγωνικό σφάλμα**

Άλλο ένα ευρέως χρησιμοποιούμενο μετρικό αξιολόγησης αιτιοκρατικής πρόβλεψης είναι το μέσο τετραγωνικό σφάλμα (Mean Squared Error – MSE). Το MSE υπολογίζει τη μέση τετραγωνική διαφορά μεταξύ των προβλεπόμενων τιμών και των πραγματικών τιμών [114].

$$MSE = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (3.10)$$

Η χρήση του MSE είναι πολύ σημαντική αφού τιμωρεί τα μεγαλύτερα σφάλματα πιο βαριά, αφού οι τετραγωνικές διαφορές αυξάνονται μη γραμμικά με το μέγεθος του σφάλματος. Παρόλα αυτά, ακραίες τιμές στο σύνολο δεδομένων μπορεί να επηρεάσουν δυσανάλογα το MSE, καθιστώντας το ενδεχομένως υψηλότερο από το αναμενόμενο. Συνεπώς, ο υπολογισμός του μπορεί να μην είναι ακριβής και η συνολική αξιολόγηση να απαιτεί χρήση επιπλέον μετρητικών.

- **Μέσο τετραγωνικό σφάλμα ρίζας**

Το μέσο τετραγωνικό σφάλμα ρίζας (Root Mean Squared Error – RMSE) είναι μια θεμελιώδης μέτρηση της στατιστικής και της μηχανικής μάθησης, που χρησιμοποιείται συχνά για τη μέτρηση της απόδοσης των μοντέλων πρόβλεψης, ειδικά σε ότι αφορά σε προβλήματα παλινδρόμησης. Το RMSE χρησιμεύει ως ένας ισχυρός δείκτης του πόσο στενά ευθυγραμμίζονται οι προβλεπόμενες τιμές

με τις πραγματικές παρατηρήσεις μετρώντας την τετραγωνική ρίζα του μέσου όρου των τετραγωνικών διαφορών μεταξύ των δύο [114]. Αυτό αποτελεί και ουσιαστικό χαρακτηριστικό του εν λόγω μετρητικού, αφού επικεντρώνεται στα μεγάλα σφάλματα. Το RMSE υπολογίζεται από τη σχέση:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (3.11)$$

Η σχέση του RMSE είναι σχετικά απλή και εύκολα κατανοητή, καθιστώντας το μια προσιτή μέτρηση για την αξιολόγηση της ακρίβειας της πρόβλεψης. Ένα μικρότερο RMSE συνεπάγεται καλύτερη προσαρμογή του μοντέλου στα δεδομένα. Αυτό συνεπάγεται ότι οι προβλέψεις του μοντέλου είναι πιο κοντά στις πραγματικές παρατηρήσεις. Σε ένα ιδανικό σενάριο, ένα μηδενικό RMSE θα σήμαινε τέλεια εφαρμογή μοντέλου, όπου κάθε πρόβλεψη ταιριάζει ακριβώς με τα παρατηρούμενα δεδομένα. Αξίζει ωστόσο να σημειωθεί ότι το RMSE μπορεί να είναι ευαίσθητο σε ακραίες τιμές και η αξιολόγησή του ταυτόχρονα με άλλα μετρητικά θα έδινε μια πιο ολοκληρωμένη εικόνα για την αξιοπιστία και την απόδοση του μοντέλου.

### 3.6.2 Πιθανοτικά μετρητικά αξιολόγησης

Τα μετρητικά αξιολόγησης πιθανοτικής πρόβλεψης εστιάζουν στην αξιολόγηση της αξιοπιστίας και της ευκρίνειας των διαστημάτων πρόβλεψης ή των ποσοστιαίων προβλέψεων της πρόβλεψης.

- **Αξιοπιστία**

Η αξιολόγηση της αξιοπιστίας (reliability) εστιάζει στο εάν οι προβλεπόμενες πιθανότητες ή τα διαστήματα πρόβλεψης αντιπροσωπεύουν με ακρίβεια τα πραγματικά αποτελέσματα. Με άλλα λόγια, αξιολογεί εάν η πρόβλεψη είναι καλά βαθμονομημένη και αξιόπιστη [115]. Όσο καλύτερη η βαθμονόμηση της πρόβλεψης, τόσο καλύτερος είναι και ο βαθμός αξιοπιστίας της.

- **Ευκρίνεια**

Η ευκρίνεια (sharpness) αναφέρεται στην ικανότητα του μοντέλου να αποτυπώνει με ακρίβεια την εγγενή αβεβαιότητα στην παραγωγή ενέργειας. Τα πιθανοτικά μοντέλα παράγουν κατανομές πιθανοτήτων και η ευκρίνεια αποτυπώνει πόσο καλά αυτές οι κατανομές ταιριάζουν με τα πραγματικά αποτελέσματα [115]. Όσο μεγαλύτερη η ευκρίνεια των προβλέψεων, τόσο στενότερα είναι τα διαστήματα πρόβλεψης. Αυτό υποδηλώνει ότι οι προβλεπόμενες τιμές δεν εμφανίζουν μεγάλη διασπορά και επομένως οι τιμές αυτές παρουσιάζουν σημαντική ακρίβεια.

- **Πιθανότητα Κάλυψης Διαστήματος Πρόβλεψης**

Η πιθανότητα κάλυψης διαστήματος πρόβλεψης (Prediction Interval Coverage Probability – PICIP) είναι μια κρίσιμη στατιστική μέτρηση στην προγνωστική μοντελοποίηση και πρόβλεψη. Ο πρωταρχικός σκοπός του είναι να μετρήσει την αξιοπιστία και την αβεβαιότητα που σχετίζονται με τα διαστήματα πρόβλεψης. Τα διαστήματα πρόβλεψης είναι απαραίτητα επειδή προσφέρουν μια σειρά τιμών εντός των οποίων είναι πιθανό να εμπίπτουν μελλοντικές παρατηρήσεις ή αποτελέσματα, παρέχοντας μια πιο ολοκληρωμένη προοπτική από τις εκτιμήσεις ενός σημείου [116].

$$PICP = \frac{1}{N_t} \sum_{t=1}^n c_t, \quad \begin{cases} c_t = 1, & y_t \in [L_t, U_t] \\ c_t = 0 & \end{cases} \quad (3.12)$$

όπου  $n$  το πλήθος των δεδομένων,  $y_i$  η πραγματική τιμή εξόδου,  $L_i$  και  $U_i$  το κάτω και άνω όριο του διαστήματος πρόβλεψης για το δεδομένο  $i$ . Το PICIP εκφράζει το ποσοστό των δεδομένων που βρίσκονται εντός του αντίστοιχου διαστήματος πρόβλεψης. Για να είναι αξιόπιστα τα διαστήματα πρόβλεψης, θα πρέπει το PICIP να είναι μεγαλύτερο ή ίσο του ονομαστικού επιπέδου εμπιστοσύνης. Στην ιδανική περίπτωση που όλα τα δεδομένα βρίσκονται εντός των διαστημάτων πρόβλεψής τους, το PICIP ισούται με 1.

- **Κανονικοποιημένη Κάλυψη Διαστήματος Πρόβλεψης**

Η κανονικοποιημένη κάλυψη του διαστήματος πρόβλεψης (Prediction Interval Nominal Coverage – PINC) είναι ένα σημαντικό στατιστικό μέτρο που χρησιμοποιείται για την αξιολόγηση της ακρίβειας και της αξιοπιστίας των διαστημάτων πρόβλεψης στο πλαίσιο της πρόβλεψης. Παρέχει πολύτιμες πληροφορίες σχετικά με την απόδοση ενός μοντέλου πρόβλεψης ποσοτικοποιώντας πόσο καλά ευθυγραμμίζονται τα διαστήματα πρόβλεψης με τα πραγματικά αποτελέσματα.

$$PINC = 100 (1 - \alpha)\% \quad (3.13)$$

όπου  $(1-\alpha)$  εκφράζει την ονομαστική πιθανότητα κάλυψης των διαστημάτων πρόβλεψης. Όσο πιο κοντά είναι το PICIP στο PINC τόσο πιο αξιόπιστο είναι το PI.

Το PINC είναι μια κανονικοποιημένη έκδοση της πιθανότητας κάλυψης του διαστήματος πρόβλεψης (PICP), η οποία είναι μια μέτρηση που χρησιμοποιείται για την αξιολόγηση του ποσοστού των φορών που ένα διάστημα πρόβλεψης περιέχει την πραγματική τιμή μιας μελλοντικής παρατήρησης [117]. Ενώ το PICIP είναι ένα απόλυτο μέτρο, το PINC λαμβάνει υπόψη το πλάτος των διαστημάτων πρόβλεψης και προσαρμόζεται για αυτό. Αυτή η προσαρμογή είναι ιδιαίτερα χρήσιμη κατά τη σύγκριση μοντέλων με διαστήματα πρόβλεψης

διαφορετικού πλάτους ή κατά την αξιολόγηση της επίδρασης της βαθμονόμησης του διαστήματος πρόβλεψης.

- **Κανονικοποιημένο Μέσο Πλάτος Διαστήματος Πρόβλεψης**

Το κανονικοποιημένο μέσο πλάτος του διαστήματος πρόβλεψης (Prediction Interval Normalized Average Width – PINAW) είναι μια σημαντική μέτρηση στην προγνωστική μοντελοποίηση και πρόβλεψη, που προσφέρει μια ολοκληρωμένη αξιολόγηση της αξιοπιστίας και της ακρίβειας των διαστημάτων πρόβλεψης. Τα διαστήματα πρόβλεψης είναι ζωτικής σημασίας επειδή παρέχουν μια σειρά τιμών εντός των οποίων οι μελλοντικές παρατηρήσεις είναι πιθανό να εμπίπτουν, αναγνωρίζοντας την εγγενή αβεβαιότητα στην πρόβλεψη [118]. Το PINAW βελτιώνει την κατανόηση για αυτά τα διαστήματα λαμβάνοντας υπόψη τόσο το μέσο πλάτος τους όσο και το πόσο καλά ευθυγραμμίζονται με την υποκείμενη κατανομή δεδομένων.

$$PINAW = \frac{1}{N_t R} \sum_{t=1}^n (U_t - L_t) \quad (3.14)$$

όπου  $R$  το εύρος των δεδομένων εξόδου. Το PINAW εκφράζει το εύρος των διαστημάτων πρόβλεψης. Όσο αυξάνεται το εύρος, αυξάνεται και το PICP, ωστόσο μειώνεται η σπουδαιότητα της πληροφορίας που φέρουν τα διαστήματα πρόβλεψης.

- **Κανονικοποιημένη Ρίζα Μέσης Τιμής Τετραγώνου του Εύρους Διαστημάτων Πρόβλεψης**

Αν και το PINAW εκφράζει ικανοποιητικά το μέσο εύρος των διαστημάτων πρόβλεψης, υπάρχουν μετρητικά εύρους που αποδίδουν καλύτερα κατά την εκπαίδευση του τεχνητού νευρωνικού δικτύου. Ένα τέτοιο μετρητικό είναι η κανονικοποιημένη ρίζα της μέσης τιμής του τετραγώνου του εύρους των διαστημάτων πρόβλεψης (Prediction Interval Normalized Root mean square Width – PINRW) που ορίζεται ως εξής [118]:

$$PINRW = \frac{1}{R} \sqrt{\frac{\sum_{t=1}^{N_t} (U_t - L_t)^2}{N_t}} \quad (3.15)$$

Το PINRW δεν είναι ευθέως ανάλογο του μέσου εύρους των διαστημάτων πρόβλεψης, όπως είναι το PINAW, αλλά έχει την ιδιότητα να «μεγεθύνει» τα μεγαλύτερα διαστήματα πρόβλεψης κατά τον υπολογισμό του εύρους τους.

- **Συνεχής Βαθμολογημένη Κατάταξη Πιθανότητας**

Η συνεχής βαθμολογημένη κατάταξη πιθανότητας (Continuous Ranked Probability Score – CRPS) είναι μια στατιστική μέτρηση που χρησιμοποιείται για την αξιολόγηση της ακρίβειας των πιθανοτικών προβλέψεων, ιδιαίτερα στον τομέα της μετεωρολογίας και της υδρολογίας, αλλά και σε άλλους τομείς όπως τα οικονομικά και τα αθλητικά. Το CRPS αξιολογεί πόσο καλά ταιριάζει ένα προγνωστικό μοντέλο ή μια προβλεπόμενη κατανομή πιθανοτήτων με τα παρατηρούμενα αποτελέσματα [115]. Είναι ιδιαίτερα χρήσιμο στις πιθανοτικές προβλέψεις, όπου η πρόβλεψη παρέχει όχι μόνο μια σημειακή εκτίμηση αλλά μια πλήρη κατανομή πιθανοτήτων σε πιθανά αποτελέσματα.

Ο υπολογισμός του CRPS περιλαμβάνει τη σύγκριση της συνάρτησης αθροιστικής κατανομής (Cumulative Distribution Function – CDF) της προβλεπόμενης κατανομής πιθανοτήτων με το CDF των παρατηρούμενων αποτελεσμάτων. Το CDF της προβλεπόμενης κατανομής αντιπροσωπεύει τις προβλεπόμενες πιθανότητες του μοντέλου για διαφορετικά αποτελέσματα, ενώ το CDF των παρατηρούμενων δεδομένων αντιπροσωπεύει την πραγματική κατανομή των αποτελεσμάτων. Το CRPS είναι το ολοκλήρωμα της διαφοράς στο τετράγωνο μεταξύ αυτών των δύο CDF, το οποίο ποσοτικοποιεί την απόκλιση μεταξύ της προβλεπόμενης και της παρατηρούμενης κατανομής [115]. Το CRPS υπολογίζεται ως εξής:

$$CRPS = \frac{1}{N_t} \sum_{t=1}^{N_t} \int_{-\infty}^{+\infty} \{F_t(z_t) - l(z_t \geq y_t)\}^2 dz \quad (3.16)$$

όπου η προγνωστική κατανομή πρόβλεψης  $F_t$  συγκρίνεται με την παρατήρηση  $y_t$  και  $l$  είναι η συνάρτηση μοναδιαίου βήματος.

- **Κριτήριο Πλάτους Κάλυψης**

Το κριτήριο πλάτους κάλυψης (Coverage Width Criterion – CWC) αποτελεί ένα μετρητικό πιθανοτικής πρόβλεψης το οποίο συνυπολογίζει την κάλυψη και την ευκρίνεια του διαστήματος πρόβλεψης, αλλά όχι το σχήμα της κατανομής τους [76]. Το CWC υπολογίζεται ως εξής:

$$CWC = \frac{1}{N_t} \sum_{t=1}^{N_t} (U_t - L_t) + \gamma e^{-h\left(\frac{1}{N_t} \sum_{t=1}^{N_t} (c_t) - cl\right)} \quad (3.17)$$

όπου  $\gamma$  ισούται με 1 όταν η μέση κάλυψη του PI είναι μικρότερη από το ονομαστικό επίπεδο εμπιστοσύνης, διαφορετικά το  $\gamma$  ισούται με 0.

### 3.7 Παράδειγμα μελέτης αποτελεσμάτων υβριδικών μοντέλων με βάση ΤΝΔ

Στην ενότητα αυτή παρουσιάζεται η λειτουργία και η απόδοση δύο διαφορετικών υβριδικών μοντέλων βασισμένων σε νευρωνικά δίκτυα και συγκεκριμένα το νευρωνικό δίκτυο LSTM, και στατιστικές μεθόδους και συγκεκριμένα τη μέθοδο ARIMA [119].

Η χρήση και υβριδικών μοντέλων επιτρέπει την αξιοποίηση των πλεονεκτημάτων της κάθε μεθόδου, με στόχο την βελτίωση της απόδοσης του τελικού μοντέλου. Πιο συγκεκριμένα, μια υβριδική προσέγγιση με χρήση των μοντέλων LSTM και ARIMA μπορεί να αξιοποιήσει τα πλεονεκτήματα τόσο των γραμμικών όσο και των μη γραμμικών προσεγγίσεων, παρέχοντας μια πιο ισχυρή και αξιόπιστη λύση πρόβλεψης σε διαφορετικές καιρικές συνθήκες. Τα μοντέλα ARIMA είναι κατάλληλα για την σύλληψη γραμμικών τάσεων, εποχικότητας (ιδιαίτερα χρήσιμο όταν πρόκειται για δεδομένα που παρουσιάζουν επαναλαμβανόμενα μοτίβα σε συγκεκριμένα χρονικά διαστήματα) και αυτοσυσχέτισης σε δεδομένα χρονοσειρών, ενώ το LSTM μπορεί να συλλάβει τα μη γραμμικά και πολύπλοκα μοτίβα. Καταγράφοντας τόσο γραμμικές τάσεις όσο και πολύπλοκα μη γραμμικά μοτίβα, ένα τέτοιο υβριδικό μοντέλο μπορεί να βελτιώσει την απόδοση πρόβλεψης και να προσαρμοστεί στην εγγενή μεταβλητότητα της παραγωγής ενέργειας ΦΒ.



Η μελέτη εστιάζει στην ανάπτυξη δυο διαφορετικών υβριδικών προσεγγίσεων ΦΒ πρόβλεψης που ενώ συνδυάζουν τις ίδιες μεθοδολογίες πρόβλεψης, χρησιμοποιούν διαφορετική αρχιτεκτονική για να παρέχουν τα προγνωστικά αποτελέσματα. Παράλληλα, τα δύο μοντέλα βελτιστοποιούνται ταυτόχρονα ώστε να παρέχουν ακριβείς προβλέψεις, ενώ παράλληλα εστιάζουν στη διατήρηση χαμηλής πολυπλοκότητας και υπολογιστικού κόστους.

#### 3.7.1 Υβριδική προσέγγιση 1

Η πρώτη μέθοδος αφορά την εξαγωγή των προβλέψεων από κάθε μοντέλο ξεχωριστά και στην συνέχεια την δημιουργία προβλέψεων ως αποτέλεσμα του μέσου όρου των προβλέψεων των δύο μοντέλων.

Τα υβριδικά μοντέλα που χρησιμοποιούν μέσες προβλέψεις μπορούν να μειώσουν τον αντίκτυπο των σφαλμάτων από οποιοδήποτε μεμονωμένο μοντέλο, καθιστώντας το υβριδικό μοντέλο πιο ανθεκτικό. Επιπλέον, τέτοιου είδους υβριδικά μοντέλα παρέχουν συχνά ακριβέστερες προβλέψεις αφού μπορούν να καταγράφουν ένα ευρύτερο φάσμα προτύπων και εξαρτήσεων στα δεδομένα. Τέλος, με χρήση του μέσου όρου των προβλέψεων, μετριάζεται ο κίνδυνος υπερπροσαρμογής που μπορεί να προκύψει σε μεμονωμένα μοντέλα.

Η εκπαίδευση των δύο μοντέλων γίνεται ανεξάρτητα. Μετά την ολοκλήρωση των σταδίων της εκπαίδευσης και της πρόβλεψης, υπολογίζεται ο μέσος όρος των προβλέψεων από το μοντέλο ARIMA και το LSTM για κάθε χρονικό βήμα στον ορίζοντα πρόβλεψης. Η εξέλιξη της αρχιτεκτονικής του υβριδικού μοντέλου παρουσιάζεται στο Σχήμα 3.5(α).




**Σχήμα 3.5** Σχηματική απεικόνιση της αρχιτεκτονικής: (α) του υβριδικού μοντέλου με εξαγωγή μέσης τιμής προβλέψεων και (β) του υβριδικού μοντέλου με χρήση προβλέψεων ARIMA ως είσοδο του LSTM.

### 3.7.2 Υβριδική προσέγγιση 2

Η δεύτερη προσέγγιση βασίζεται στη μάθηση στοιβαγμένων συνόλων που παρουσιάζει προηγμένη τεχνική εκμάθησης συνόλου, η οποία συνδυάζει τις προβλέψεις πολλαπλών βασικών μοντέλων για να δημιουργήσει ένα μετα-μοντέλο που παρέχει πιο ακριβείς προβλέψεις. Στη συγκεκριμένη περίπτωση, η διαδικασία πρόβλεψης εφαρμόζεται αρχικά με το μοντέλο ARIMA. Στη συνέχεια, τα προγνωστικά αποτελέσματα του μοντέλου ARIMA χρησιμοποιούνται ως δεδομένα εισόδου για τις διαδικασίες εκπαίδευσης και δοκιμής του μοντέλου LSTM.

Ένα από τα κύρια πλεονεκτήματα αυτής της μορφής υβριδικού μοντέλου είναι η βελτιωμένη ακρίβεια πρόβλεψής του. Τα μοντέλα ARIMA είναι αποτελεσματικά στην καταγραφή γραμμικών τάσεων και εποχικότητας, ενώ το LSTM υπερέρχει στην καταγραφή σύνθετων, μη γραμμικών μοτίβων στο σύνολο δεδομένων εισόδου. Συνδυάζοντας τα πλεονεκτήματα και των δύο μοντέλων, μπορούν να γίνουν ακριβέστερες προβλέψεις. Επιπλέον, το προτεινόμενο μοντέλο παρουσιάζει μεγάλη προσαρμοστικότητα λαμβάνοντας υπόψη το παρεχόμενο σύνολο δεδομένων. Τα δεδομένα χρονοσειρών μπορεί να παρουσιάζουν διαφορετικά χαρακτηριστικά με την πάροδο του χρόνου. Τα μοντέλα ARIMA μπορεί να έχουν καλή απόδοση σε μια περίοδο, ενώ τα LSTM μπορεί να έχουν καλύτερη απόδοση σε μια άλλη. Τα υβριδικά μοντέλα είναι σε θέση να προσαρμόζονται σε μεταβαλλόμενα πρότυπα δεδομένων χρησιμοποιώντας τις ιδιότητες του κατάλληλου μοντέλου σε κάθε περίπτωση.



**Σχήμα 3.6** Πίνακας συσχέτισης για πρόβλεψη ΦΒ ενέργειας (παράδειγμα ηλιόλουστης ημέρας).

Η ανάθεση κατάλληλων τιμών στις υπερπαραμέτρους παίζει σημαντικό ρόλο στην αξιόπιστη λειτουργία των υβριδικών μοντέλων. Για το ARIMA, αυτό περιλαμβάνει την επιλογή της τάξης ( $p$ ,  $d$ ,  $q$ ), ενώ για το LSTM, περιλαμβάνει την αρχιτεκτονική (αριθμός στρωμάτων και μονάδων) και τον ρυθμό μάθησης. Η εξέλιξη της αρχιτεκτονικής του υβριδικού μοντέλου παρουσιάζεται στο Σχήμα 3.5(β).

### 3.7.3 Αποτελέσματα

Τα προτεινόμενα βραχυπρόθεσμα υβριδικά μοντέλα πρόβλεψης ΦΒ ενέργειας αξιολογούνται σε πραγματικό σύνολο δεδομένων από ΦΒ πάρκο ισχύος 1550,78 kW που βρίσκεται στην Ελλάδα. Το σύνολο δεδομένων περιλαμβάνει μετεωρολογικά δεδομένα, συμπεριλαμβανομένης της κεκλιμένης και οριζόντιας ακτινοβολίας, της θερμοκρασίας περιβάλλοντος, της θερμοκρασίας της ΦΒ μονάδας, την ταχύτητα και την κατεύθυνση του ανέμου και τη σχετική υγρασία, καθώς και ιστορικά δεδομένα της παραγόμενης ΦΒ ισχύος. Υπάρχουν διαθέσιμα ιστορικά δεδομένα δύο ετών που χρονολογούνται από την 1<sup>η</sup> Ιανουαρίου 2020 έως την 31<sup>η</sup> Δεκεμβρίου 2021, με χρονικό βήμα ενός λεπτού. Ο ορίζοντας πρόβλεψης ορίζεται σε μία ημέρα, ενώ η ανάλυση πρόβλεψης διατηρείται στο ένα λεπτό.

Η αξιολόγηση των δύο προτεινόμενων υβριδικών μοντέλων έγινε μέσω σύγκρισης των σφαλμάτων πρόβλεψής τους με τα σύγχρονα μοντέλα LSTM και ARIMA στην απλή τους δομή. Οι συγκρίσεις βασίζονται στο μέσο απόλυτο ποσοστιαίο σφάλμα και στο κανονικοποιημένο μέσο τετραγωνικό σφάλμα ρίζας (nRMSE) που περιγράφονται στις εξισώσεις (3.9) και (3.11), αντίστοιχα.

**Πίνακας 3.1** Ανάλυση εποχικότητας και ακρίβεια πρόβλεψης με βάση τις καθημερινές διακυμάνσεις του καιρού για μετρητικό σφάλματος MAPE.

| MAPE (%)  |       |      |       |            |            |
|-----------|-------|------|-------|------------|------------|
| Εποχή     | Ημέρα | LSTM | ARIMA | Υβριδικό 1 | Υβριδικό 2 |
| Χειμώνας  | S     | 5,43 | 5,78  | 5,45       | 5,31       |
|           | LC    | 3,15 | 4,67  | 3,29       | 3,04       |
|           | HC    | 2,94 | 3,98  | 3,01       | 2,69       |
| Άνοιξη    | S     | 4,12 | 4,55  | 4,17       | 3,91       |
|           | LC    | 6,34 | 7,03  | 6,46       | 5,95       |
|           | HC    | 4,03 | 5,76  | 4,14       | 3,86       |
| Καλοκαίρι | S     | 1,60 | 2,61  | 1,61       | 1,50       |
|           | LC    | 5,24 | 6,87  | 5,55       | 4,73       |
|           | HC    | 5,01 | 6,88  | 5,89       | 4,62       |
| Φθινόπωρο | S     | 7,01 | 7,13  | 7,02       | 6,58       |
|           | LC    | 2,03 | 2,01  | 2,05       | 1,97       |
|           | HC    | 4,43 | 6,01  | 5,34       | 4,12       |

**Πίνακας 3.2** Ποσοστιαία ανάλυση βελτίωσης του μετρητικού σφάλματος MAPE με βάση το υβριδικό μοντέλο 2, ως προς τα υπόλοιπα μοντέλα σύγκρισης, με βάση τις καθημερινές διακυμάνσεις του καιρού.

| MAPE (%)  |       |      |       |            |
|-----------|-------|------|-------|------------|
| Εποχή     | Ημέρα | LSTM | ARIMA | Υβριδικό 1 |
| Χειμώνας  | S     | 2%   | 9%    | 3%         |
|           | LC    | 4%   | 54%   | 8%         |
|           | HC    | 9%   | 48%   | 12%        |
| Άνοιξη    | S     | 5%   | 16%   | 7%         |
|           | LC    | 7%   | 18%   | 9%         |
|           | HC    | 4%   | 49%   | 7%         |
| Καλοκαίρι | S     | 7%   | 74%   | 7%         |
|           | LC    | 11%  | 45%   | 17%        |
|           | HC    | 8%   | 49%   | 27%        |
| Φθινόπωρο | S     | 7%   | 8%    | 7%         |
|           | LC    | 3%   | 2%    | 4%         |
|           | HC    | 8%   | 46%   | 30%        |

**Πίνακας 3.3** Ποσοστιαία ανάλυση βελτίωσης του μετρητικού σφάλματος MAPE με βάση το υβριδικό μοντέλο 1, ως προς τα υπόλοιπα μοντέλα σύγκρισης, με βάση τις καθημερινές διακυμάνσεις του καιρού.

| MAPE (%)  |       |      |       |            |
|-----------|-------|------|-------|------------|
| Εποχή     | Ημέρα | LSTM | ARIMA | Υβριδικό 2 |
| Χειμώνας  | S     | 0%   | 6%    | -3%        |
|           | LC    | -4%  | 42%   | -8%        |
|           | HC    | -2%  | 32%   | -11%       |
| Άνοιξη    | S     | -1%  | 9%    | -6%        |
|           | LC    | -2%  | 9%    | -8%        |
|           | HC    | -3%  | 39%   | -7%        |
| Καλοκαίρι | S     | -1%  | 62%   | -7%        |
|           | LC    | -6%  | 24%   | -15%       |
|           | HC    | -15% | 17%   | -22%       |
| Φθινόπωρο | S     | 0%   | 2%    | -6%        |
|           | LC    | -1%  | -2%   | -4%        |
|           | HC    | -17% | 13%   | -23%       |

**Πίνακας 3.4** Ανάλυση εποχικότητας και ακρίβεια πρόβλεψης με βάση τις καθημερινές διακυμάνσεις του καιρού για το μετρητικό σφάλματος nRMSE.

| nRMSE (%) |       |      |       |            |            |
|-----------|-------|------|-------|------------|------------|
| Εποχή     | Ημέρα | LSTM | ARIMA | Υβριδικό 1 | Υβριδικό 2 |
| Χειμώνας  | S     | 5,49 | 6,25  | 5,55       | 5,43       |
|           | LC    | 2,87 | 4,53  | 2,85       | 2,45       |
|           | HC    | 2,87 | 3,98  | 3,03       | 2,56       |
| Άνοιξη    | S     | 4,01 | 4,98  | 4,23       | 3,69       |
|           | LC    | 5,65 | 6,78  | 5,79       | 5,56       |
|           | HC    | 4,56 | 5,25  | 4,35       | 4,23       |
| Καλοκαίρι | S     | 2,21 | 3,77  | 3,01       | 2,12       |
|           | LC    | 4,62 | 6,44  | 4,43       | 4,31       |
|           | HC    | 4,02 | 6,78  | 5,33       | 3,96       |
| Φθινόπωρο | S     | 7,00 | 9,98  | 7,56       | 6,04       |
|           | LC    | 2,34 | 2,32  | 2,24       | 2,00       |
|           | HC    | 4,03 | 4,33  | 4,24       | 3,68       |

**Πίνακας 3.5** Ποσοστιαία ανάλυση βελτίωσης του μετρητικού σφάλματος nRMSE με βάση το υβριδικό μοντέλο 2, ως προς τα υπόλοιπα μοντέλα σύγκρισης, με βάση τις καθημερινές διακυμάνσεις του καιρού.

| nRMSE (%) |       |      |       |            |
|-----------|-------|------|-------|------------|
| Εποχή     | Ημέρα | LSTM | ARIMA | Υβριδικό 1 |
| Χειμώνας  | S     | 1%   | 15%   | 2%         |
|           | LC    | 17%  | 85%   | 16%        |
|           | HC    | 12%  | 55%   | 18%        |
| Άνοιξη    | S     | 9%   | 35%   | 15%        |
|           | LC    | 2%   | 22%   | 4%         |
|           | HC    | 8%   | 24%   | 3%         |
| Καλοκαίρι | S     | 4%   | 78%   | 42%        |
|           | LC    | 7%   | 49%   | 3%         |
|           | HC    | 2%   | 71%   | 35%        |
| Φθινόπωρο | S     | 16%  | 65%   | 25%        |
|           | LC    | 17%  | 16%   | 12%        |
|           | HC    | 10%  | 18%   | 15%        |

**Πίνακας 3.6** Ποσοστιαία ανάλυση βελτίωσης του μετρητικού σφάλματος nRMSE με βάση το υβριδικό μοντέλο 1, ως προς τα υπόλοιπα μοντέλα σύγκρισης, με βάση τις καθημερινές διακυμάνσεις του καιρού.


| nRMSE (%) |       |      |       |            |
|-----------|-------|------|-------|------------|
| Εποχή     | Ημέρα | LSTM | ARIMA | Υβριδικό 2 |
| Χειμώνας  | S     | -1%  | 13%   | -2%        |
|           | LC    | 1%   | 59%   | -14%       |
|           | HC    | -5%  | 31%   | -16%       |
| Άνοιξη    | S     | -5%  | 18%   | -13%       |
|           | LC    | -2%  | 17%   | -4%        |
|           | HC    | 5%   | 21%   | -3%        |
| Καλοκαίρι | S     | -27% | 25%   | -30%       |
|           | LC    | 4%   | 45%   | -3%        |
|           | HC    | -25% | 27%   | -26%       |
| Φθινόπωρο | S     | -7%  | 32%   | -20%       |
|           | LC    | 4%   | 4%    | -11%       |
|           | HC    | -5%  | 2%    | -13%       |

Η αποτελεσματικότητα των δύο υβριδικών προσεγγίσεων εξετάζεται από εποχική προοπτική και λαμβάνοντας υπόψη τις διαφορετικές καθημερινές καιρικές συνθήκες. Θα πρέπει να σημειωθεί σε αυτό το σημείο, ότι για να είναι ακριβής μια διαδικασία πρόβλεψης φωτοβολταϊκών, πρέπει να περιλαμβάνονται συγκεκριμένα δεδομένα στη διαδικασία εκπαίδευσης. Λαμβάνοντας υπόψη την ευαισθησία των μοντέλων πρόβλεψης ΦΒ στην εμφάνιση ή την έλλειψη ηλιακού φωτός, συγκεκριμένα δεδομένα τείνουν να είναι πιο σημαντικά για τη βελτίωση της ακρίβειας και της αποτελεσματικότητας των αναπτυγμένων μεθοδολογιών πρόβλεψης. Το Σχήμα 3.6 παρουσιάζει όλες τις διαθέσιμες παραμέτρους που επηρεάζουν την παραγωγή ισχύος ΦΒ με τη μορφή ενός πίνακα θερμότητας, για το παράδειγμα μιας ημέρας με ηλιοφάνεια. Ο συντελεστής Pearson αναπαρίσταται σε κάθε πλαίσιο. Όσο αυτός ο συντελεστής πλησιάζει το 1 σε απόλυτη τιμή ή είναι ίσος σε απόλυτη τιμή με 1, σημαίνει ότι οι δύο ποσότητες, κάθετες και οριζόντιες, που αντιστοιχούν σε αυτό το πλαίσιο έχουν μια «ισχυρή» σχέση μεταξύ τους, επομένως η εξέλιξη του ενός επηρεάζει σε μεγάλο βαθμό το άλλο.


Τα αποτελέσματα πρόβλεψης για τα μετρητικά σφάλματος MAPE και nRMSE παρουσιάζονται στον Πίνακα 3.1 και 3.4, αντίστοιχα. Η ανάλυση των Πινάκων 3.1 και 3.4, παρουσιάζει αποτελέσματα για κάθε εποχή του έτους, για ηλιόλουστες ημέρες (S), ημέρες με ελαφρά συννεφιά (LC) και ημέρες με έντονη συννεφιά (HC). Αντίστοιχα, οι Πίνακες 3.2 και 3.3 παρουσιάζουν την ποσοστιαία ανάλυση βελτίωσης του μετρητικού σφάλματος MAPE με βάση το υβριδικό μοντέλο 2 και υβριδικό μοντέλο 1, ενώ οι Πίνακες 3.5 και 3.6 παρουσιάζουν την ποσοστιαία ανάλυση βελτίωσης του μετρητικού σφάλματος nRMSE με βάση το υβριδικό μοντέλο 2 και το υβριδικό μοντέλο 1.

Αρκετά συμπεράσματα μπορούν να προκύψουν από τους πίνακες 3.1 – 3.6, λαμβάνοντας υπόψη τη συμπεριφορά των δύο υβριδικών προσεγγίσεων στο διαθέσιμο σύνολο δεδομένων καθώς και την αποτελεσματικότητα πρόβλεψης λαμβάνοντας υπόψη τις ημερήσιες διακυμάνσεις του καιρού. Είναι προφανές ότι το υβριδικό μοντέλο 2 μπορεί να ξεπεράσει τόσο το υβριδικό μοντέλο 1 όσο και τα βασικά μοντέλα LSTM και ARIMA. Τα παραπάνω είναι αναμενόμενα λαμβάνοντας υπόψη την αρχιτεκτονική των δύο υβριδικών προσεγγίσεων. Το υβριδικό μοντέλο 1 επηρεάζεται σε μεγάλο βαθμό από την παραμετροποίηση των μοντέλων LSTM και ARMA καθώς και από την αποτελεσματικότητα και των δύο μοντέλων εφαρμοσμένα σε ένα συγκεκριμένο σύνολο δεδομένων. Φαίνεται ότι το μοντέλο LSTM μπορεί να ξεπεράσει το μοντέλο ARIMA σε όλες τις περιπτώσεις. Επομένως, ο μέσος όρος των αποτελεσμάτων των δύο μοντέλων δεν μπορεί να βελτιώσει περαιτέρω τα αποτελέσματα του υβριδικού μοντέλου 1 σε σύγκριση με το μοντέλο LSTM. Συγκεκριμένα, στην περίπτωση ηλιόλουστων ημερών, όπου τα σφάλματα πρόβλεψης των μοντέλων LSTM και ARIMA είναι κοντά, το υβριδικό μοντέλο 1 μπορεί να παρέχει παρόμοιας ακρίβειας αποτελέσματα. Ωστόσο, στην περίπτωση συννεφιασμένων ημερών, όπου το μοντέλο LSTM παρέχει σημαντικά καλύτερα αποτελέσματα από το μοντέλο ARIMA, το υβριδικό μοντέλο 1 μπορεί να ξεπεράσει το μοντέλο ARIMA αλλά δεν μπορεί να ξεπεράσει το μοντέλο LSTM.

Από την άλλη, η αρχιτεκτονική του μοντέλου υβριδικού μοντέλου 2, εξηγεί την υπεροχή του σε σχέση με τα άλλα μοντέλα. Η εφαρμογή του μοντέλου ARIMA πρώτα και στη συνέχεια η χρήση των προβλεπόμενων τιμών του ως δεδομένα εισαγωγής στο μοντέλο LSTM επιτρέπει



(a)




(b)

**Σχήμα 3.7** Παράδειγμα πραγματικών και προβλεπόμενων καμπυλών παραγωγής ΦΒ ενέργειας για (α) υβριδικό μοντέλο 1 και (β) υβριδικό μοντέλο 2.

την αποσύνθεση της πολυπλοκότητας του μοντέλου καταγράφοντας και αφαιρώντας αποτελεσματικά τις γραμμικές τάσεις και την εποχικότητα με το ARIMA, απλοποιώντας την εργασία για το μοντέλο LSTM. Αυτό οδηγεί σε βελτιωμένη ακρίβεια μοντέλου, καθώς τα αποτελέσματα από το πρώτο στάδιο πρόβλεψης του ARIMA μοντέλου περιέχουν λιγότερες τάσεις και εποχικότητα, επιτρέποντας στο LSTM να επικεντρωθεί σε μη γραμμικά μοτίβα, με αποτέλεσμα περισσότερες λεπτομέρειες και ακριβέστερες προβλέψεις. Η προεπεξεργασία από τη μέθοδο ARIMA βοηθά στη διαχείριση της μη στασιμότητας, καθιστώντας τα αποτελέσματα πιο στάσιμα και κατάλληλα για μοντελοποίηση από το LSTM.

Αυτή η προσέγγιση ενισχύει επίσης την ερμηνευτικότητα του μοντέλου αποσυνθέτοντας ξεκάθαρα τα γραμμικά και μη γραμμικά στοιχεία, παρέχοντας πληροφορίες για το τι “έχασε” το ARIMA και επιτρέποντας στο LSTM να αντιμετωπίσει αυτές τις πτυχές. Η εκπαίδευση του LSTM απλοποιεί τη διαδικασία εκπαίδευσης και μπορεί να οδηγήσει σε ταχύτερη σύγκλιση



**Σχήμα 3.8** Μέσες τιμές MAPE για τα συγκριτικά μοντέλα για κάθε μήνα του έτους.

λόγω μειωμένης πολυπλοκότητας των δεδομένων. Η ευελιξία και η στιβαρότητα του υβριδικού μοντέλου, του επιτρέπουν να προσαρμόζεται σε διάφορες καιρικές συνθήκες και μοτίβα δεδομένων, βελτιώνοντας τη γενίκευση σε νέα δεδομένα αξιοποιώντας τόσο γραμμικά όσο και μη γραμμικά μοτίβα. Επιπλέον, το ARIMA μπορεί να λειτουργήσει ως φίλτρο θορύβου, αφήνοντας το LSTM να μοντελοποιεί σημαντικά μη γραμμικά στοιχεία στα αρχικά αποτελέσματα.

Τα παραπάνω επιβεβαιώνονται τόσο από τους Πίνακες 3.2 και 3.3 όσο και από τους Πίνακες 3.5 και 3.6. Οι Πίνακες 3.3 και 3.5 κάνουν ξεκάθαρη τη βελτίωση που παρουσιάζει το υβριδικό μοντέλο 2 σε ότι αφορά στο MAPE και το nRMSE αντίστοιχα, κυρίως ως προς το μοντέλο ARIMA και κατά επέκταση ως προς το υβριδικό μοντέλο 1. Αντίστοιχα, οι Πίνακες 3.4 και 3.6 φανερώνουν τη δυσκολία που παρουσιάζει το υβριδικό μοντέλο 1 σε ότι αφορά στο MAPE και το nRMSE αντίστοιχα, να πλησιάσει την απόδοση του LSTM μοντέλου και έτσι να καταφέρει να αποδώσει εξίσου καλά με το υβριδικό μοντέλο 2.

Λαμβάνοντας υπόψη τα αποτελέσματα του MAPE, το υβριδικό μοντέλο 2, σε σύγκριση με το μοντέλο LSTM, μπορεί να βελτιώσει τα μέσα αποτελέσματα κατά 4,92% για ηλιόλουστες ημέρες, 5,58% για ημέρες με ελαφριά συννεφιά και 6,88% για ημέρες με έντονη συννεφιά, ενώ σε σύγκριση με το μοντέλο ARIMA, είναι σε θέση να βελτιώσει τα μέσα αποτελέσματα κατά 18,11% για ηλιόλουστες ημέρες, 20,85% για ημέρες με ελαφριά συννεφιά και 32,42% για ημέρες με έντονη συννεφιά. Τα παραπάνω αποτελέσματα επιβεβαιώνουν την υπεροχή του υβριδικού μοντέλου 2 σε σύγκριση με τα άλλα μοντέλα, την αδυναμία του μοντέλου ARIMA να παρέχει αποτελέσματα παρόμοια με το μοντέλο LSTM,

**Πίνακας 3.7** Ανάλυση εποχικότητας και ακρίβειας πρόβλεψης με βάση τις καθημερινές διακυμάνσεις του καιρού για μετρητικό σφάλματος MAPE.

| Μοντέλο    | Χρόνος εκπαίδευσης (s) | Χρονική επιβάρυνση (%) | Χρόνος εκτέλεσης (μs) | Χρονική επιβάρυνση (%) |
|------------|------------------------|------------------------|-----------------------|------------------------|
| LSTM       | 38,27                  | -16,46                 | 62,13                 | 36,07                  |
| ARIMA      | 32,86                  | 0,00                   | 45,66                 | 0,00                   |
| Υβριδικό 1 | 40,61                  | -23,58                 | 62,85                 | 37,64                  |
| Υβριδικό 2 | 47,92                  | -45,83                 | 65,44                 | 43,32                  |

καθώς και την ικανότητα του μοντέλου υβριδικού μοντέλου 2 να παρέχει πιο ακριβή αποτελέσματα σε περιπτώσεις με ελαφριά και βαριά συννεφιασμένες ημέρες όπου η ακρίβεια της πρόγνωσης μπορεί να είναι πιο δύσκολη. Τα αποτελέσματα nRMSE για το υβριδικό μοντέλο 2 δείχνουν παρόμοια βελτίωση με τη μέτρηση σφάλματος MAPE, όπου, σε σύγκριση με το μοντέλο LSTM, μπορεί να βελτιώσει τα μέσα αποτελέσματα κατά 6,71% για ηλιόλουστες ημέρες, 9,37% για ημέρες με ελαφριά συννεφιά και 7,05% για έντονες συννεφιασμένες ημέρες, ενώ σε σύγκριση με το μοντέλο ARIMA, μπορεί να βελτιώσει τα μέσα αποτελέσματα κατά 30,57% για ηλιόλουστες ημέρες, 27,69% για ημέρες με ελαφριά συννεφιά και 27,93% για ημέρες με έντονη συννεφιά.

Το Σχήμα 3.7 παρουσιάζει ένα παράδειγμα των καμπυλών παραγωγής ΦΒ των δύο υβριδικών μοντέλων σε σύγκριση με την καμπύλη πραγματικής ισχύος. Η απεικόνιση των προβλεπόμενων καμπυλών αρκεί για να προκύψει το συμπέρασμα ότι και τα δύο υβριδικά μοντέλα είναι σε θέση να παρέχουν ακριβή αποτελέσματα πρόβλεψης και είναι σε θέση να ακολουθούν τις διακυμάνσεις της καμπύλης ισχύος, αποφεύγοντας περιπτώσεις ακραίων τιμών.

Για περαιτέρω ανάλυση των αποτελεσμάτων και κατανόηση της συμπεριφοράς των αναπτυγμένων υβριδικών μοντέλων από εποχιακή προοπτική, το Σχήμα 3.8 παρουσιάζει τις μέσες τιμές MAPE για κάθε μήνα του έτους. Από το Σχήμα 3.8 προκύπτει ότι σε περιπτώσεις καλοκαιρινών μηνών, τα μοντέλα LSTM και υβριδικό μοντέλο 2 παρέχουν αποτελέσματα παρόμοιας ακρίβειας, επομένως η εφαρμογή υβριδικής αρχιτεκτονικής δεν είναι υποχρεωτική. Ωστόσο, σε περιπτώσεις φθινοπωρινών και ανοιξιάτικων μηνών, όπου η περίπτωση δεδομένων εισόδου παρουσιάζει μεγαλύτερη διακύμανση, το υβριδικό μοντέλο 2 μπορεί να αποδώσει καλύτερα. Επιπλέον, το μοντέλο ARIMA εμφανίζει προγνωστικά αποτελέσματα, όπου το MAPE μπορεί να είναι υψηλότερο από 10% και συνεπώς να επηρεάσει την απόδοση του υβριδικού μοντέλου 1.

Ο μέσος χρόνος εκπαίδευσης και ο χρόνος εκτέλεσης καθενός από τα συγκριτικά μοντέλα παρουσιάζονται στον Πίνακα 3.7. Τα συγκριτικά μοντέλα αναπτύχθηκαν στην Python και εκτελέστηκαν σε επιτραπέζιο υπολογιστή με CPU AMD Ryzen 5 3600X (3,80 GHz, 6 πυρήνες) και 16 GB μνήμης RAM. Μπορεί να φανεί ότι, παρά την εφαρμογή μιας υβριδικής αρχιτεκτονικής, και τα δύο υβριδικά μοντέλα 1 και 2 παρουσιάζουν χαμηλούς χρόνους εκπαίδευσης και εκτέλεσης, επιτυγχάνοντας υψηλή ακρίβεια διατηρώντας παράλληλα χαμηλό υπολογιστικό κόστος.

Συμπερασματικά, τα συγκριτικά αποτελέσματα δείχνουν ότι το υβριδικό μοντέλο 2 είναι σε θέση να ξεπεράσει τις υπόλοιπες προσεγγίσεις. Το μοντέλο ARIMA δεν είναι σε θέση να παρέχει αποτελέσματα παρόμοιας ή καλύτερης ακρίβειας από το μοντέλο LSTM και επομένως, το υβριδικό μοντέλο 1 δεν μπορεί να ξεπεράσει το μοντέλο LSTM. Το υβριδικό μοντέλο 2 μπορεί να βελτιώσει το σφάλμα πρόβλεψης κατά ένα μέσο MAPE 5,79% και μέσο nRMSE 7,71% σε σύγκριση με το μοντέλο LSTM και μέσο MAPE 23,79% και μέσο nRMSE 28,73% σε σύγκριση με το μοντέλο ARIMA.

# Κεφάλαιο 4

## ΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ ΑΙΟΛΙΚΗΣ ΚΑΙ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

### 4.1 Εισαγωγή

Η απόδοση της πρόβλεψης παραγόμενης ισχύος τόσο από συστήματα αιολικής όσο και συστήματα φωτοβολταϊκής παραγωγής επηρεάζεται από διάφορες παραμέτρους. Για να στηθεί σωστά ένα πρόβλημα πρόβλεψης φωτοβολταϊκής παραγωγής, απαραίτητη προϋπόθεση είναι η κατανόηση των αναγκών του προβλήματος και η κατάλληλη επιλογή του μοντέλου πρόβλεψης.

Ο ορίζοντας πρόβλεψης που εστιάζει κάθε πρόβλημα παίζει καθοριστικό ρόλο στην κατάλληλη επιλογή του μοντέλου πρόβλεψης και την κατανόηση των παραμέτρων της αρχιτεκτονικής του. Ο ορίζοντας πρόβλεψης μπορεί να ποικίλει από μερικά δευτερόλεπτα έως βάθος ετών.

Η κατανόηση των συνθηκών του προβλήματος πρόβλεψης, τόσο από άποψη ποιότητας και τύπου δεδομένων, κυρίως στην περίπτωση των αιολικών συστημάτων, όσο και των κλιματικών συνθηκών στην περίπτωση των φωτοβολταϊκών συστημάτων μπορεί να βελτιώσει περαιτέρω την κατανόηση του προβλήματος πρόβλεψης. Τέτοιες πληροφορίες έχει διαπιστωθεί ότι μπορούν να βελτιώσουν σημαντικά το σφάλμα πρόβλεψης, ενώ παράλληλα συμβάλλουν σημαντικά στην ελαχιστοποίηση του υπολογιστικού κόστους βελτιστοποιώντας την αρχιτεκτονική των μοντέλων.

Η βελτιστοποίηση των παραμέτρων των τεχνικών μηχανικής μάθησης αποτελεί ένα πραγματικό πρόβλημα. Συχνά, τα μοντέλα που βασίζονται σε τεχνικές μηχανικής μάθησης τείνουν να είναι αρκετά περίπλοκα, τόσο σε ότι αφορά την προεπεξεργασία των δεδομένων εισόδου όσο και στην υλοποίηση και εκτέλεσή τους. Η κατάλληλη επιλογή αλγορίθμου βελτιστοποίησης αλλά και η προσαρμογή του στην αρχιτεκτονική του επιλεγμένου μοντέλου αποτελεί μια από τις σημαντικότερες προκλήσεις της εξέλιξης των μοντέλων πρόβλεψης, καθώς αν και στοχεύουν στη βελτίωση των παραμέτρων του μοντέλου, συχνά μπορεί να έχουν ως αποτέλεσμα την επιβάρυνση του υπολογιστικού κόστους.

### 4.2 Συμβολή της διδακτορικής διατριβής

Στα πλαίσια της παρούσας διδακτορικής διατριβής, διερευνήθηκε η συμπεριφορά των μοντέλων πρόβλεψης ως προς το αποτέλεσμα της προγνωστικής διαδικασίας, λαμβάνοντας

υπόψη ειδικά τις κλιματικές συνθήκες που προέρχονται από τη γεωγραφική τους θέση και τα αποτελέσματα δημοσιεύθηκαν σε διεθνές επιστημονικό περιοδικό, στην εργασία [120].

Πιο συγκεκριμένα, η συγκεκριμένη έρευνα [120] εστίασε στην αξιολόγηση νέων υπερσύγχρονων, εξαιρετικά βραχυπρόθεσμων και βραχυπρόθεσμων, μοντέλων πρόβλεψης ηλιακής ενέργειας. Επιπλέον, οι εργασίες που μελετήθηκαν, ταξινομήθηκαν κατάλληλα από κλιματική άποψη. Στη συγκεκριμένη μελέτη, έγινε προσπάθεια να αποφευχθεί να αναλυθούν συγκεκριμένα οι διαφορετικές μεθοδολογίες πρόβλεψης, αλλά να παρέχει πληροφορίες και συμπεράσματα σχετικά με την επίδραση των διαφορετικών κλιματικών συνθηκών στην ακρίβεια της πρόβλεψης.

Τα σύγχρονα μοντέλα πρόβλεψης ηλιακής ενέργειας, τείνουν τα τελευταία χρόνια να αξιοποιούν την τεχνολογία σε ότι αφορά στην ανάλυση του ουρανού από τη μεριά της νεφοκάλυψης με χρήση δορυφορικών εικόνων αλλά και συσκευών απεικόνισης ουρανού. Πιο συγκεκριμένα, η χρήση δορυφορικών εικόνων απαιτεί την αναγνώριση συγκεκριμένων σταθερών χαρακτηριστικών των σύννεφων. Επιλέγονται ανιχνευτές εντός των εικόνων που υποβάλλονται σε επεξεργασία, που αντιστοιχούν σε χαρακτηριστικά νέφη που μπορούν εύκολα να εντοπιστούν. Τα συναγωγικά σύννεφα, τα οποία χαρακτηρίζονται από χαμηλές θερμοκρασίες, μεγάλες παραμορφώσεις νεφών και μετασχηματισμούς που προκαλούνται από την κίνηση του νέφους καθώς και από την κίνηση των νέφους λόγω της ταχύτητας του ανέμου είναι ιχνηθέτες που αναλύονται συνήθως από δορυφορικές εικόνες. Η συνέπεια αυτών των χαρακτηριστικών αναλύεται σε όλη τη φάση της προεπεξεργασίας. Για την αποτελεσματική παρακολούθηση αυτών των ανιχνευτών, χρησιμοποιούνται αλγόριθμοι αντιστοίχισης προτύπων για την εκτίμηση της μελλοντικής θέσης κάθε ιχνηλάτη από δεδομένες εικόνες [121].

Δορυφορικές εικόνες και δεδομένα ακτινοβολίας που προέρχονται από δορυφόρους χρησιμοποιούνται συχνά σε μοντέλα πρόβλεψης φωτοβολταϊκής παραγωγής, ειδικά σε αριθμητικά μοντέλα καιρού. Ωστόσο, λόγω σφαλμάτων στο οπτικό βάθος του αερολύματος και στα προβλήματα ανίχνευσης νέφους, τα δεδομένα από δορυφορικές εικόνες μπορεί να έχουν αβεβαιότητα και συχνά δείχνουν συστηματική προκατάληψη. Επιπλέον, η ανάλυσή τους είναι συνήθως στην εμβέλεια των χιλιομέτρων, η οποία είναι αρκετά περιορισμένη και ως εκ τούτου δεν είναι κατάλληλα για πολύ βραχυπρόθεσμες προβλέψεις.

Οι επίγειες συσκευές απεικόνισης ουρανού προσφέρουν υψηλή χωροχρονική ανάλυση. Αυτό έρχεται σε αντίθεση με τις δορυφορικές εικόνες. Ως αποτέλεσμα, τέτοιες εικόνες είναι κατάλληλες για πολύ βραχυπρόθεσμες και βραχυπρόθεσμες μεθοδολογίες πρόβλεψης όπου απαιτείται υψηλή ανάλυση. Ειδικά για ενδοωριαίες προβλέψεις, προτιμώνται οι επίγειες εικόνες ουρανού, αντί για τις δορυφορικές εικόνες και τα μοντέλα αριθμητικής πρόβλεψης καιρού. Επιπλέον, η υψηλή χωροχρονική τους ανάλυση προσφέρει τη δυνατότητα εντοπισμού συμβάντων ράμπας που οι δορυφορικές εικόνες δεν είναι σε θέση να εκτιμήσουν.

Θα πρέπει να σημειωθεί ότι η επίγεια απεικόνιση, μέσω δεικτών κάλυψης νέφους, διανυσμάτων κίνησης νέφους και ταξινομήσεων σύννεφων, συχνά στερείται χωρικής κάλυψης και επομένως περιορίζεται στη χρήση για συγκεκριμένες εφαρμογές πρόβλεψης τοποθεσίας [122].

Οι κλιματικές συνθήκες παίζουν καθοριστικό ρόλο στην παραγωγή ενέργειας από ΑΠΕ. Η μεταβλητότητα και η απρόβλεπτη φύση του καιρού καθιστούν την παραγωγή ενέργειας από αυτές τις πηγές ευάλωτη σε εξωτερικούς παράγοντες που μπορούν να επηρεάσουν σημαντικά την απόδοσή τους. Η κατανόηση αυτής της μεταβλητότητας αλλά και η σύνδεση των μετεωρολογικών δεδομένων με την επίδοση και απόδοση των εφαρμοσμένων μοντέλων πρόβλεψης, παίζουν καθοριστικό ρόλο στην ανάπτυξη και βελτίωση των μεθοδολογιών πρόβλεψης.

Με την πολυπλοκότητα των μοντέλων πρόβλεψης να αυξάνεται συνεχώς λόγω της συνεχούς ανάπτυξης των απαιτήσεων και των δυνατοτήτων των μοντέλων πρόβλεψης, η επιτάχυνση των διαδικασιών και η ελαχιστοποίηση του υπολογιστικού κόστους γίνονται παράμετροι μείζονος σημασίας για την διαδικασία της πρόβλεψης. Η εφαρμογή συγκεκριμένων μοντέλων πρόβλεψης σε περιπτώσεις δεδομένων από διαφορετικές περιοχές μεν, αλλά παρόμοιων μετεωρολογικών συνθηκών, μπορεί να συμβάλλει σημαντικά στο παραπάνω πρόβλημα. Η κατανόηση της επίδρασης των μετεωρολογικών δεδομένων, αλλά και η επίδρασή τους σε συγκεκριμένο τύπο μοντέλων πρόβλεψης μπορεί να επιτρέψει την αποφυγή χρήσης ακατάλληλων μοντέλων πρόβλεψης, αλλά και την κατάλληλη προεπεξεργασία των δεδομένων εισόδου.

### 4.3 Ορίζοντας πρόβλεψη

Η συνεχής διείσδυση της ηλιακής ενέργειας στα ενεργειακά συστήματα έχει δημιουργήσει σημαντικά προβλήματα όσον αφορά την ευστάθεια και τον έλεγχο του. Οι μεθοδολογίες πρόβλεψης έχουν χρησιμοποιηθεί ευρέως για την αντιμετώπιση αυτών των προβλημάτων και τη βελτιστοποίηση της λειτουργίας των αγορών ενέργειας και των συστημάτων ηλεκτρικής ενέργειας. Αξίζει να σημειωθεί ότι προκύπτουν διαφορετικοί τύποι προβλημάτων, ανάλογα με τον ορίζοντα πρόβλεψης των μοντέλων. Τέτοια προβλήματα ποικίλλουν από τη βελτιστοποίηση των αγορών ηλεκτρικής ενέργειας, τη διαχείριση των συστημάτων ηλεκτρικής ενέργειας, τον καθημερινό προγραμματισμό, την ενεργειακή αγορά και τον προγραμματισμό συντήρησης.

#### Υπερβραχυπρόθεσμη πρόβλεψη

Η υπερβραχυπρόθεσμη πρόβλεψη χρησιμοποιεί ιστορικά δεδομένα ενέργειας για την εκτίμηση των προγνωστικών τιμών ενέργειας με ορίζοντα πρόβλεψης που κυμαίνεται συνήθως από λίγα λεπτά έως μία ώρα [123]. Η βελτίωση της ακρίβειας των εξαιρετικά βραχυπρόθεσμων μοντέλων πρόβλεψης θα μπορούσε να διαδραματίσει αποφασιστικό ρόλο στη λειτουργία και τον σχεδιασμό των συστημάτων ηλεκτρικής ενέργειας, δεδομένου ότι θα μπορούσε να μειώσει το αποθεματικό κόστος και να βελτιώσει περαιτέρω τη δομή του ηλεκτρικού δικτύου [124].

#### Βραχυπρόθεσμη πρόβλεψη

Η βραχυπρόθεσμη πρόβλεψη στοχεύει στην παρουσίαση προγνωστικών αποτελεσμάτων που αφορούν την καθημερινή αγορά ηλεκτρικής ενέργειας και τη διαχείριση του συστήματος. Ο ορίζοντας πρόβλεψης κυμαίνεται συνήθως από μία ώρα έως 48 ώρες [125].

**Πίνακας 4.1** Γενικός τύπος δεδομένων που χρησιμοποιείται στην πρόβλεψη αιολικής παραγωγής, βάσει της βιβλιογραφικής ανασκόπησης του Κεφαλαίου 2.

| Γενικός τύπος δεδομένων              | Μελετημένες εργασίες                               |
|--------------------------------------|----------------------------------------------------|
| Ιστορικά δεδομένα αιολικής παραγωγής | [66]-[68], [71], [72], [74], [75], [77], [79]-[85] |
| Μετεωρολογικά δεδομένα               | [66], [80]-[82]                                    |
| NWP                                  | [77], [83], [84]                                   |

#### Μεσοπρόθεσμη πρόβλεψη

Η μεσοπρόθεσμη πρόβλεψη στοχεύει στη βέλτιστη λειτουργία και προγραμματισμό των συστημάτων ηλεκτρικής ενέργειας. Ο μεσοπρόθεσμος ορίζοντας προβλέψεων κυμαίνεται συνήθως από 48 ώρες έως μία εβδομάδα [125].

#### Μακροπρόθεσμη πρόβλεψη

Οι μακροπρόθεσμες προβλέψεις αποσκοπούν κυρίως στον σχεδιασμό των συστημάτων ηλεκτρικής ενέργειας και στην επέκταση της παραγωγικής ικανότητας, καθώς και στον προγραμματισμό συντήρησης και κατασκευής [126]. Ο μακροπρόθεσμος ορίζοντας προβλέψεων εκτείνεται συνήθως σε ένα ή περισσότερα έτη [123].

### 4.4 Θεωρητικό υπόβαθρο


#### 4.4.1 Βραχυπρόθεσμη πρόβλεψη συστημάτων αιολικής παραγωγής

##### 4.4.1.1 Κλιματικές συνθήκες

Όσον αφορά την ακρίβεια των μοντέλων πρόβλεψης αιολικής ενέργειας, η επιλογή των κατάλληλων δεδομένων εισόδου είναι ζωτικής σημασίας. Διαφορετικοί τύποι δεδομένων εισόδου λαμβάνονται υπόψη για πιθανοτικά μοντέλα πρόβλεψης αιολικής ενέργειας.

Ιστορικά δεδομένα της ταχύτητας του ανέμου ή της αιολικής ενέργειας έχουν χρησιμοποιηθεί τόσο σε αιτιοκρατικά όσο και σε πιθανοτικά μοντέλα πρόβλεψης. Άλλοι τύποι σημαντικών δεδομένων που φαίνεται να βελτιώνουν την ακρίβεια πολλών προτεινόμενων μοντέλων είναι τα μετεωρολογικά δεδομένα από τα αιολικά πάρκα ή τις αιολικές περιοχές που ερευνώνται καθώς και τα φυσικά μοντέλα NWP που μοντελοποιούνται από προηγμένες μεθοδολογίες.

Όπως γίνεται εύκολα κατανοητό από τον Πίνακα 4.1, τα ιστορικά δεδομένα αιολικής παραγωγής φαίνεται να παίζουν τον σημαντικότερο ρόλο στη βελτίωση των σφαλμάτων πρόβλεψης των μοντέλων πρόβλεψης αιολικής παραγωγής. Αυτό είναι αρκετά αναμενόμενο αλλά και λογικό. Η κατανόηση της συμπεριφοράς των ανέμων ανά περιοχή έρευνας είναι πολύ σημαντική, τόσο για τη βελτίωση των μοντέλων πρόβλεψης, όσο και για την ίδια την εγκατάσταση των αιολικών πάρκων. Συχνά, τα μοντέλα μηχανικής μάθησης είναι ικανά να εντοπίζουν μοτίβα και πρότυπα συμπεριφοράς του ανέμου με την αύξηση του όγκου του συνόλου των δεδομένων εκπαίδευσης, συχνά για διάρκεια ετών. Αυτό κάνει καθοριστικής σημασίας, την χρήση μετεωρολογικών δεδομένων που αφορούν κυρίως στην ταχύτητα και τη



**Σχήμα 4.1** Παγκόσμιες κλιματικές ζώνες βάσει της ταξινόμησης Köppen–Geiger.

διεύθυνση του ανέμου, αλλά και στη χρήση ιστορικών χρονοσειρών παραγωγής αιολικής ενέργειας.

#### 4.4.2 Βραχυπρόθεσμη πρόβλεψη συστημάτων φωτοβολταϊκής παραγωγής

##### 4.4.2.1 Κλιματικές συνθήκες

Οι μετεωρολογικές συνθήκες παίζουν σημαντικό ρόλο στην εκτίμηση του σφάλματος πρόβλεψης των μοντέλων φωτοβολταϊκής πρόβλεψης. Η νεφοκάλυψη, η ταχύτητα και η διεύθυνση του ανέμου, η βροχοπτώση ή η θερμοκρασία περιβάλλοντος είναι όλοι κλιματικοί παράγοντες που ποικίλλουν ανάλογα με την τοποθεσία.

Σε χώρες πιο κοντά στον ισημερινό της γης παρατηρούνται υψηλότερες θερμοκρασίες, ενώ σε χώρες πιο κοντά στους πόλους, η θερμοκρασία μπορεί να μειωθεί ακόμη και κάτω από 0 °C. Σε τροπικά κλίματα, συναντώνται μεγαλύτεροι όγκοι βροχοπτώσεων, ενώ σε ξηρά κλίματα οι βροχοπτώσεις καθώς και η ταχύτητα του ανέμου ενδέχεται να περιορίζονται σε εξαιρετικά χαμηλά επίπεδα.

Στο Σχήμα 4.1, παρουσιάζεται μια ταξινόμηση των κλιματικών ζωνών της Γης [127] με βάση το σύστημα Köppen-Geiger. Είναι φανερό ότι υπάρχουν αρκετές κλιματικές ταξινομήσεις και υποταξινομήσεις με βάση τη θέση και τις μετεωρολογικές συνθήκες.

Το σύστημα Köppen-Geiger, από τη βάση του, δεν προορίζεται για τον καθορισμό των συνθηκών στα πλαίσια των φωτοβολταϊκών συστημάτων. Αντίθετα, προτάθηκε προκειμένου να παρουσιαστούν οι κλιματολογικές συνθήκες όπως βιώνονται από τους ανθρώπους και άλλα

ζωντανά πλάσματα σε όλο τον κόσμο μέσω βαθιάς έρευνας των κλιματικών συνθηκών των διαφόρων τοποθεσιών. Παρόλα αυτά, όντας ένα ευρέως αναγνωρισμένο κλιματικό μοντέλο, αλλά και λόγω της βαθιάς ανάλυσης των μετεωρολογικών συνθηκών, μπορεί να αποτελέσει μια αξιολογική βάση για την κατανόηση των μετεωρολογικών συνθηκών, ώστε να προταθεί μια κλιματική ταξινόμηση επικεντρωμένη στα φωτοβολταϊκά συστήματα [128].

Ως αποτέλεσμα, λαμβάνοντας υπόψη τη σημασία της κλιματικής πτυχής στη διαδικασία της πρόβλεψης ΦΒ παραγωγής, οι κλιματικές υποταξινομήσεις Köppen-Geiger ομαδοποιήθηκαν, χωρίστηκαν και συνδυάστηκαν εκ νέου στις κλιματικές ζώνες που παρουσιάζονται παρακάτω [128]:

α) Ισημερινή ζώνη: αυτή η ζώνη περιορίζεται σε συγκεκριμένες ζώνες γύρω από τον ισημερινό της Γης. Αυτή η ζώνη λαμβάνει το υψηλότερο επίπεδο ηλιακής ακτινοβολίας, δεδομένου ότι η επιφάνεια είναι κάθετη στο εισερχόμενο ηλιακό φως. Αυτές οι περιοχές χαρακτηρίζονται από υψηλά επίπεδα υγρασίας και υψηλές, σταθερές θερμοκρασίες όλο τον χρόνο. Η βροχή είναι ένα σχεδόν καθημερινό φαινόμενο. Ωστόσο, μπορεί να υπάρχουν διακριτές περίοδοι ξηρασίας.

- Υγρή υποίσημερινή ζώνη, που χαρακτηρίζεται από υψηλά επίπεδα υγρασίας και τακτικές βροχοπτώσεις.
- Ξηρή υποίσημερινή ζώνη, που χαρακτηρίζεται από ξηρές συνθήκες.

β) Τροπική ζώνη: αυτή η ζώνη αναφέρεται σε περιοχές κοντά στον ισημερινό της Γης. Αυτές οι περιοχές είναι οι θερμότερες, δεδομένου ότι η ηλιακή ακτινοβολία φτάνει στο έδαφος σχεδόν κάθετα σε όλη τη διάρκεια του έτους και έτσι οδηγεί σε υψηλά επίπεδα εισερχόμενης ηλιακής ακτινοβολίας. Τα ακραία κλιματικά φαινόμενα είναι συχνότερα σε αυτές τις περιοχές.

γ) Υποτροπική ζώνη: κατά τη διάρκεια του καλοκαιριού, αυτές οι περιοχές λαμβάνουν υψηλά επίπεδα ακτινοβολίας επειδή η γωνία του ήλιου είναι σχεδόν κάθετη προς τη Γη. Ως αποτέλεσμα, τα επίπεδα υγρασίας είναι χαμηλά, τα επίπεδα ακτινοβολίας αυξάνονται και το στρώμα νεφοκάλυψης είναι λεπτό. Αντίθετα, κατά τη διάρκεια του χειμώνα, τα επίπεδα ακτινοβολίας μπορούν να μειωθούν σημαντικά, με αποτέλεσμα χαμηλές θερμοκρασίες και υψηλά επίπεδα υγρασίας.

δ) Εύκρατη ζώνη: σε σύγκριση με τις τροπικές και υποτροπικές ζώνες, οι θερμοκρασίες είναι χαμηλότερες και πιο σταθερές, καθώς η ηλιακή ακτινοβολία φτάνει στην επιφάνεια της Γης με μικρότερη γωνία και το επίπεδο ακτινοβολίας του ήλιου είναι σημαντικά χαμηλότερο από τις κλιματικές ζώνες πιο κοντά στον ισημερινό της Γης. Τα ακραία κλιματικά φαινόμενα είναι λιγότερο συχνά και οι βροχοπτώσεις κατανέμονται τακτικά σε συγκεκριμένες εποχές. Ωστόσο, λόγω του γεγονότος ότι η εύκρατη ζώνη καλύπτει τεράστιες εκτάσεις σε διαφορετικές χώρες και διαφορετικές ηπείρους, μπορούν να αντιμετωπιστούν διαφορετικές υποκατηγορίες του κλίματος της εύκρατης ζώνης, από μερικώς βροχερές έως σχετικά ξηρές.

- Υγρή υποεύκρατη ζώνη, που χαρακτηρίζεται κυρίως από βροχοπτώσεις και γενικά υγρές μετεωρολογικές συνθήκες.

**Πίνακας 4.2** Γενικός τύπος δεδομένων που χρησιμοποιείται στην πρόβλεψη φωτοβολταϊκής παραγωγής, βάσει της βιβλιογραφικής ανασκόπησης του Κεφαλαίου 2.

| Γενικός τύπος δεδομένων             | Μελετημένες εργασίες                                                                  |
|-------------------------------------|---------------------------------------------------------------------------------------|
| Ιστορικά και μετεωρολογικά δεδομένα | [32], [33], [36]-[38], [42], [44], [45], [47], [48], [49], [52]-[55], [58]-[61], [65] |
| NWP                                 | [41], [46], [50], [51], [56], [57], [64]                                              |

**Πίνακας 4.3** Ανάλυση τύπων δεδομένων που περιέχονται στην πρόβλεψη φωτοβολταϊκής παραγωγής, βάσει της βιβλιογραφικής ανασκόπησης του Κεφαλαίου 2.

| Τύπος δεδομένων           | Μελετημένες εργασίες                                      |
|---------------------------|-----------------------------------------------------------|
| Ηλιακή ακτινοβολία        | [41], [42], [44], [47], [49], [50], [52], [54], [57]-[59] |
| Ταχύτητα ανέμου           | [42], [48], [50], [51], [56], [57], [59], [60], [64]      |
| Θερμοκρασία περιβάλλοντος | [42], [47], [50], [52], [54], [56]-[59]                   |
| Διεύθυνση ανέμου          | [42], [58], [64]                                          |
| Ιστορικά δεδομένα ισχύος  | [41], [44], [49], [59], [60]                              |
| Σχετική υγρασία           | [42], [54], [56]-[59], [64]                               |
| Νεφοκάλυψη                | [49], [54], [56], [57]                                    |
| Βροχόπτωση                | [42], [49], [50], [64]                                    |


- Ξηρή υποεύκρατη ζώνη, που χαρακτηρίζεται κυρίως από ξηρές συνθήκες με σπάνια παρουσία βροχοπτώσεων.

Υποπολική ζώνη: αυτή η ζώνη αναφέρεται σε περιοχές με μεγάλους σε διάρκεια και πολύ κρύους χειμώνες και καλοκαίρια χαμηλής θερμοκρασίας. Οι ψυχροί άνεμοι από αυτή τη ζώνη επηρεάζουν συνήθως το κλίμα των περιοχών εύκρατης ζώνης κατά τη διάρκεια του χειμώνα.

Πολική ζώνη: οι περιοχές στις πολικές ζώνες λαμβάνουν τα λιγότερα επίπεδα έντασης ηλιακής ακτινοβολίας σε όλη τη διάρκεια του έτους. Η διάρκεια της ημέρας ποικίλλει σε αυτές τις περιοχές. Χαρακτηρίζεται από εξαιρετικά χαμηλές θερμοκρασίες και το επίπεδο της ηλιακής ακτινοβολίας είναι το χαμηλότερο δυνατό λόγω της μικρής γωνίας που το φως του ήλιου φτάνει στην επιφάνεια της Γης.

#### 4.4.2.2 Τύπος δεδομένων

Μια σημαντική παράμετρος που επηρεάζει την ακρίβεια των μοντέλων πρόβλεψης ηλιακής ενέργειας είναι η επιλογή των κατάλληλων δεδομένων εισόδου.



**Σχήμα 4.2** Ευρωπαϊκός χάρτης άμεσης κανονικής ακτινοβολίας.


Διαφορετικά μοντέλα πρόβλεψης φωτοβολταϊκής παραγωγής εξετάζουν και εφαρμόζονται σε διαφορετικούς τύπους δεδομένων εισόδου. Ο Πίνακας 4.2 παρουσιάζει τον τύπο των μεταβλητών εισόδου που επιλέχθηκαν σε κάθε μία από τις εργασίες που εξετάστηκαν όσον αφορά τα ιστορικά και μετεωρολογικά δεδομένα αλλά και τη χρήση NWP.

Από τη φύση τους, τα μοντέλα πρόβλεψης φωτοβολταϊκής παραγωγής εξαρτώνται σε μεγάλο βαθμό από τις μετεωρολογικές και κλιματικές συνθήκες. Ιστορικά δεδομένα ηλιακής ενέργειας και μετεωρολογικά δεδομένα έχουν χρησιμοποιηθεί στην πρόβλεψη ΦΒ παραγωγής. Όπως φαίνεται πιο αναλυτικά στον Πίνακα 4.3 μετεωρολογικά δεδομένα, όπως η ταχύτητα του ανέμου, η θερμοκρασία και η ηλιακή ακτινοβολία δείχνουν να είναι απαραίτητα για μια ακριβή πρόβλεψη φωτοβολταϊκής παραγωγής. Τα τελευταία χρόνια έχουν προταθεί μοντέλα βασισμένα στις εικόνες ουρανού, λαμβάνοντας υπόψη τις συνθήκες νεφοκάλυψης. Η ανάπτυξη τέτοιων μοντέλων, βοήθησε να συμπεριληφθεί η νεφοκάλυψη ως σημαντική παράμετρος στη διαδικασία πρόβλεψης και να βελτιωθεί περαιτέρω η ακρίβεια πρόβλεψης των μοντέλων.

Οι Πίνακες 4.2 και 4.3, αναδεικνύουν τη σημασία της κατάλληλης επιλογής δεδομένων για μια επιτυχή και ακριβή φωτοβολταϊκή πρόβλεψη ισχύος. Η σημασία των μετεωρολογικών δεδομένων έναντι ακόμα και των ιστορικών δεδομένων παραγωγής ισχύος είναι ξεκάθαρη. Συγκεκριμένα, δεδομένα όπως η ηλιακή ακτινοβολία, η θερμοκρασία περιβάλλοντος, αλλά και η ταχύτητα του ανέμου φαίνεται να παίζουν καθοριστικό ρόλο.

#### 4.4.3 Συσχέτιση δυναμικού παραγωγής ενέργειας και μετεωρολογικών συνθηκών

Η σημερινές απαιτήσεις για κάλυψη ενεργειακών αναγκών σε παγκόσμιο επίπεδο αλλά και η κατανόηση της απόκρισης των μοντέλων πρόβλεψης σε διαφορετικά σύνολα δεδομένων αποτελούν σημαντική πρόκληση της σύγχρονης ενεργειακής κοινότητας. Πιο συγκεκριμένα, σε περιπτώσεις περιοχών με υψηλό δυναμικό παραγωγής ενέργειας από ΑΠΕ, η βέλτιστη έγχυση



**Σχήμα 4.3** Ευρωπαϊκός χάρτης παραγόμενης ηλιακής ενέργειας.

της συνεχώς αυξανόμενης παραγόμενης ενέργειας, μπορεί να αποτελεί όχι μόνο πρόκληση αλλά και πρόβλημα.

Οι κλιματικές συνθήκες που υπάρχουν σε κάθε περιοχή μπορούν να επηρεάσουν τόσο τις υπάρχουσες κλιματικές συνθήκες όσο και τη σταθερότητα ή μεταβλητότητά τους. Είναι εύκολα κατανοητό ότι σε περιοχές με σταθερές κλιματικές συνθήκες ή μετεωρολογικές συνθήκες που εμφανίζουν περιοδικότητα και μπορούν εύκολα να εκτιμηθούν, απλά μοντέλα πρόβλεψης μπορούν να εφαρμοστούν και να είναι αρκετά αποδοτικά. Ωστόσο, σε περιπτώσεις υψηλής μεταβλητότητας κλιματικών συνθηκών, αντίστοιχα καιρικά μοτίβα αλλά και αναμενόμενα προφίλ παραγόμενης ενέργειας είναι δύσκολο να εκτιμηθούν. Σε τέτοιες περιπτώσεις, τα μοντέλα πρόβλεψης είναι κρίσιμο να μπορούν να λάβουν υπόψη τους πολλές παραμέτρους αλλά και να χρησιμοποιούν μεγάλο όγκο ιστορικών δεδομένων. Αυτό έχει ως αποτέλεσμα να αυξάνεται η πολυπλοκότητα των απαιτούμενων μοντέλων πρόβλεψης. Η κατανόηση λοιπόν του τρόπου λειτουργίας τους σε σύνολα δεδομένων που αντικατοπτρίζουν παρόμοιες κλιματικές και μετεωρολογικές συνθήκες, μπορεί να μειώσει σημαντικά τους χρόνους κατασκευής μοντέλων πρόβλεψης κατάλληλης αρχιτεκτονικής αλλά και να βελτιώσει τα στάδια προεπεξεργασίας των δεδομένων εισόδου και της εκπαίδευσης των μοντέλων πρόβλεψης.

Το Σχήμα 4.2 παρουσιάζει τον χάρτη της άμεσης κανονικής ακτινοβολίας (Direct Normal Irradiance - DNI) για το παράδειγμα της Ευρώπης. Η άμεση κανονική ακτινοβολία αναφέρεται στην ποσότητα της ηλιακής ακτινοβολίας που λαμβάνεται ανά μονάδα επιφάνειας μιας επιφάνειας σε συνεχώς κατακόρυφο τρόπο από τον ήλιο. Το Σχήμα 4.3 παρουσιάζει τις δυνατότητες φωτοβολταϊκής παραγωγής των χωρών της Ευρώπης. Μπορεί να φανεί από τα Σχήματα 4.2 και 4.3 ότι τα επίπεδα της άμεσης κανονικής ακτινοβολίας είναι συνεπή με την ποσότητα και την δυνατότητα της παραγωγής φωτοβολταϊκής ενέργειας. Αυτά τα στοιχεία παρέχουν μια λεπτομερή εικόνα της κατανομής της ηλιακής ακτινοβολίας στην Ευρώπη και

έτσι διευκρινίζουν τις πιο υποσχόμενες περιοχές για την παραγωγή ηλιακής ενέργειας. Ως αποτέλεσμα, χρειάζονται πιο προηγμένα μοντέλα πρόβλεψης φωτοβολταϊκής παραγωγής σε τέτοιες περιοχές και είναι πιο πιθανό οι έρευνες να επικεντρωθούν σε σύνολα δεδομένων συγκεκριμένων τοποθεσιών.

Από τα Σχήματα 4.2 και 4.3, προκύπτει ότι η πλειονότητα των χωρών που χρειάζονται τα πιο ακριβή μοντέλα πρόβλεψης είναι χώρες της κεντρικής και νότιας Ευρώπης που παρουσιάζουν τα υψηλότερα επίπεδα ακτινοβολίας. Αυτές οι χώρες έχουν υψηλότερο δυναμικό παραγωγής φωτοβολταϊκής ενέργειας. Αυτό συνδέεται με τις κλιματικές τους συνθήκες. Λόγω της αφθονίας της ηλιακής ακτινοβολίας σε τέτοια κλίματα, αυτές οι χώρες συνεχίζουν να ενσωματώνουν την ηλιακή ενέργεια όλο και περισσότερο στα συστήματα ισχύος τους. Πρέπει να σημειωθεί ότι οι σταθερές μετεωρολογικές συνθήκες ευνοούν την απόδοση των φωτοβολταϊκών. Η συνεχής πρόσπτωση του ηλιακού φωτός, ο καθαρός ουρανός και οι συνθήκες κανονικής θερμοκρασίας θα μπορούσαν να βελτιστοποιήσουν την απόδοση των φωτοβολταϊκών.

Ωστόσο, παρά το γεγονός ότι το δυναμικό παραγόμενης φωτοβολταϊκής ενέργειας σε αυτές τις περιοχές είναι σημαντικά υψηλό, οι κλιματικές συνθήκες παραμένουν αρκετά απροσδιόριστες. Πέραν της περιόδου του καλοκαιριού, όπου χαρακτηρίζεται από υψηλές θερμοκρασίες και συνεχή ηλιοφάνεια, η συμπεριφορά των μετεωρολογικών συνθηκών δεν μπορεί εύκολα να εκτιμηθεί, θεωρώντας κάποια εποχικά μοτίβα. Ειδικά τα τελευταία χρόνια, οι χειμερινοί μήνες είναι πολύ δύσκολο να εκτιμηθούν. Συχνά παρατηρείται παράταση των πολύ θερμών καλοκαιριών, με απουσία βροχοπτώσεων ή συννεφιάς, ενώ υπάρχουν και περίοδοι που παρατηρούνται συνεχείς και έντονες βροχοπτώσεις και περίοδοι μακράς συννεφιάς. Ωστόσο, ακόμα και τις περιόδους του καλοκαιριού, όπου η πρόσπτωση της ακτινοβολίας είναι σχετικά σταθερή και συνεχής, οι πολύ υψηλές θερμοκρασίες μπορούν να επηρεάσουν αρνητικά την απόδοση των ΦΒ πάνελ, υποβαθμίζοντας τις δυνατότητες παραγόμενης ενέργειας. Όλα τα παραπάνω, είναι κατανοητό πως στα πλαίσια της διαδικασίας πρόβλεψης παραγωγής ενέργειας, απαιτούν εξέλιξη των υπαρχουσών μεθοδολογιών και κατά επέκταση πιο πολύπλοκα συστήματα πρόβλεψης.

#### 4.5 Βελτιστοποίηση τεχνικών μηχανικής μάθησης

Οι αλγόριθμοι βελτιστοποίησης διαδραματίζουν κεντρικό ρόλο στα μοντέλα πρόβλεψης ισχύος ενισχύοντας την ακρίβεια, την αποτελεσματικότητα και την αξιοπιστία τους. Αυτά τα μοντέλα αποτελούν απαραίτητα εργαλεία στον ενεργειακό τομέα, βοηθώντας στην αποτελεσματική διαχείριση της παραγωγής, μεταφοράς και διανομής ηλεκτρικής ενέργειας. Η σημασία των αλγορίθμων βελτιστοποίησης σε αυτά τα μοντέλα μπορεί να γίνει κατανοητή μέσα από πολλές βασικές πτυχές.

Οι αλγόριθμοι βελτιστοποίησης επιτρέπουν στα μοντέλα πρόβλεψης ισχύος να χειρίζονται την εγγενή πολυπλοκότητα και αβεβαιότητα των ενεργειακών συστημάτων. Η ζήτηση και η προσφορά ενέργειας επηρεάζονται από πολλές μεταβλητές, όπως οι καιρικές συνθήκες, οι οικονομικοί παράγοντες και η συμπεριφορά των καταναλωτών, καθιστώντας δύσκολες τις ακριβείς προβλέψεις. Οι αλγόριθμοι βελτιστοποίησης, βοηθούν στη βελτιστοποίηση των παραμέτρων του μοντέλου για την ελαχιστοποίηση των σφαλμάτων

πρόβλεψης. Προσαρμόζουν επαναληπτικά τις εισαγωγές του μοντέλου με βάση ιστορικά δεδομένα και πληροφορίες σε πραγματικό χρόνο, με αποτέλεσμα πιο ακριβείς προβλέψεις.

Επιπλέον, διευκολύνουν την ενσωμάτωση διαφορετικών πηγών δεδομένων σε μοντέλα πρόβλεψης. Η πρόβλεψη ισχύος απαιτεί την αφομοίωση δεδομένων από διάφορες πηγές, συμπεριλαμβανομένων των μετεωρολογικών δεδομένων, των ιστορικών προτύπων παραγωγής και κατανάλωσης, των τιμών της αγοράς και των περιορισμών υποδομής. Οι αλγόριθμοι βελτιστοποίησης βοηθούν στην επιλογή των σχετικών δεδομένων, στον εντοπισμό προτύπων και στη βελτιστοποίηση των παραμέτρων του μοντέλου για την επίτευξη της καλύτερης δυνατής ακρίβειας πρόβλεψης. Με την αποτελεσματική μόχλευση των διαθέσιμων δεδομένων, αυτοί οι αλγόριθμοι ενισχύουν την αξιοπιστία των προβλέψεων ισχύος, επιτρέποντας στις επιχειρήσεις κοινής ωφέλειας και στους φορείς εκμετάλλευσης του δικτύου να λαμβάνουν τεκμηριωμένες αποφάσεις.

Οι αλγόριθμοι βελτιστοποίησης επιτρέπουν τη βελτιστοποίηση της κατανομής πόρων και του προγραμματισμού σε συστήματα ισχύος. Η παραγωγή και διανομή ενέργειας περιλαμβάνει πολύπλοκες διαδικασίες με πολλαπλούς περιορισμούς και στόχους, όπως η ελαχιστοποίηση του κόστους, η μεγιστοποίηση της απόδοσης και η διασφάλιση της ευστάθειας του συστήματος. Οι αλγόριθμοι βελτιστοποίησης βοηθούν στην εύρεση της βέλτιστης ισορροπίας μεταξύ αυτών των αντικρουόμενων στόχων, προσδιορίζοντας την πιο αποτελεσματική χρήση των πόρων, προγραμματίζοντας δραστηριότητες συντήρησης και διαχείρισης συστημάτων αποθήκευσης ενέργειας. Βελτιστοποιώντας την κατανομή πόρων, αυτοί οι αλγόριθμοι βελτιώνουν τη συνολική απόδοση των συστημάτων ισχύος και μειώνουν το λειτουργικό κόστος.

Τέλος, εστιάζοντας στην παρούσα διδακτορική διατριβή, οι αλγόριθμοι βελτιστοποίησης υποστηρίζουν την ενσωμάτωση ανανεώσιμων πηγών ενέργειας σε μοντέλα πρόβλεψης ισχύος. Η αυξανόμενη διείσδυση ανανεώσιμων πηγών ενέργειας, όπως η ηλιακή και η αιολική ενέργεια, εισάγει πρόσθετες προκλήσεις λόγω της διαλείπουσας φύσης τους και της εξάρτησής τους από τις καιρικές συνθήκες. Οι αλγόριθμοι βελτιστοποίησης βοηθούν στη βελτιστοποίηση της ενσωμάτωσης ανανεώσιμων πηγών ενέργειας στο δίκτυο, προβλέποντας την παραγωγή τους με ακρίβεια, βελτιστοποιώντας την αποστολή τους και συντονίζοντας τη λειτουργία τους με συμβατικά συστήματα παραγωγής και αποθήκευσης ενέργειας.

#### 4.5.1 Αλγόριθμος προς τα πίσω διάδοσης του σφάλματος

Ο πιο διαδεδομένος αλγόριθμος βελτιστοποίησης για την εκπαίδευση τεχνητών νευρωνικών δικτύων εμπρόσθιας τροφοδότησης είναι ο αλγόριθμος της προς τα πίσω διάδοσης του σφάλματος (back-propagation algorithm) [129].

Η αναπροσαρμογή των βαρών και των πολώσεων βασίζεται στην μέθοδο βελτιστοποίησης «μείωση της κλίσης» (gradient descent) η οποία εφαρμόζεται στην αντικειμενική συνάρτηση που έχει επιλεγεί για το εκάστοτε πρόβλημα [130]. Τα βάρη και οι πολώσεις μεταβάλλονται σε κάθε επανάληψη σύμφωνα με τις εξισώσεις (4.1) και (4.2):

$$\Delta w_{pj,qk}(n+1) = lr \cdot \delta_{qk} \cdot y_{pj} + m \cdot \Delta w_{pj,qk}(n) \quad (4.1)$$

$$w_{pj,qk}(n+1) = lr \cdot \delta_{qk} \cdot y_{pj} + m \cdot \Delta w_{pj,qk}(n) \quad (4.2)$$

όπου  $n$  ο αριθμός της τρέχουσας επανάληψης,  $w_{pj,qk}$  η τιμή του βάρους που συνδέει τον νευρώνα  $p$  του στρώματος  $j$  με τον νευρώνα  $q$  του στρώματος  $k$ ,  $\delta_{qk}$  η τιμή του συντελεστή  $\delta$  για τον νευρώνα  $q$  του στρώματος  $k$ ,  $y_{pj}$  η έξοδος του νευρώνα  $p$  του στρώματος  $j$ ,  $lr$  ο ρυθμός μάθησης και  $m$  η ορμή.

Για τον υπολογισμό του συντελεστή  $\delta$  γίνεται χρήση του γενικευμένου κανόνα  $\delta$ . Ο γενικευμένος κανόνας  $\delta$  περιλαμβάνει δύο φάσεις [131]. Αρχικά, κάθε είσοδος  $x$  προωθείται «προς τα μπροστά», ώστε να υπολογιστούν οι έξοδοι των νευρώνων στο στρώμα εξόδου. Στη συνέχεια, οι έξοδοι αυτές συγκρίνονται με τις επιθυμητές εξόδους και υπολογίζεται η αντικειμενική συνάρτηση που έχει επιλεγεί. Στη συνέχεια, το σφάλμα που προκύπτει από τον υπολογισμό της αντικειμενικής συνάρτησης, μεταδίδεται προς τα πίσω, γίνεται ο υπολογισμός του  $\delta$  για κάθε νευρώνα του τεχνητού νευρωνικού δικτύου και στη συνέχεια γίνεται η αναπροσαρμογή των βαρών και των πολώσεων.

Ο συντελεστής  $\delta$  υπολογίζεται με διαφορετικό τρόπο ανάλογα τη θέση του βάρους που πρέπει να αναπροσαρμοστεί. Εάν το βάρος αφορά τη σύνδεση νευρώνα κρυφού στρώματος με νευρώνα του στρώματος εξόδου, ο συντελεστής  $\delta$  υπολογίζεται ως εξής:

$$\delta_q^o = (\hat{y}_q - y_q) \frac{\theta f^o}{\theta z_q} \quad (4.3)$$

όπου  $\delta_q^o$  ο συντελεστής  $\delta$  του νευρώνα  $q$  του στρώματος εξόδου,  $\hat{y}_q$  η επιθυμητή έξοδος του νευρώνα  $q$  του στρώματος εξόδου,  $y_q$  η παραγόμενη έξοδος του νευρώνα  $q$  του στρώματος εξόδου,  $f^o$  η συνάρτηση ενεργοποίησης του στρώματος εξόδου και  $z_q$  η είσοδος του νευρώνα  $q$  του στρώματος εξόδου. Σε περίπτωση νευρώνων που δεν ανήκουν στο στρώμα εξόδου δεν υπάρχει επιθυμητή έξοδος, επομένως εάν το βάρος αφορά τη σύνδεση μεταξύ νευρώνων κρυφών στρωμάτων ή νευρώνα του στρώματος εισόδου με νευρώνα κρυφού στρώματος, ο συντελεστής  $\delta$  υπολογίζεται ως εξής:

$$\delta_{qk} = \frac{\theta f^k}{\theta z_{qk}} \sum_{p=1}^{N_o} \delta_q^j w_{qk,pj} \quad (4.4)$$

όπου  $\delta_{qk}$  ο συντελεστής  $\delta$  του νευρώνα  $q$  του στρώματος  $k$ ,  $f^k$  η συνάρτηση ενεργοποίησης του στρώματος  $k$ ,  $z_{qk}$  η είσοδος του νευρώνα  $q$  του στρώματος  $k$ ,  $N_o$  το πλήθος των νευρώνων του στρώματος  $j$ ,  $\delta_q^j$  ο συντελεστής  $\delta$  του νευρώνα  $p$  του στρώματος  $j$ ,  $w_{qk,pj}$  το βάρος που συνδέει τον νευρώνα  $q$  του στρώματος  $k$  με τον νευρώνα  $p$  του στρώματος  $j$ . Τέλος, ο ρυθμός μάθησης  $lr$  και η ορμή  $m$  λαμβάνουν τιμές μεταξύ του 0.01 και του 1.

Ο αλγόριθμος της προς τα πίσω διάδοσης του σφάλματος με τη μέθοδο βελτιστοποίησης «μείωση της κλίσης» λόγω της απλότητας στη χρήση του αλλά και της ταχύτητάς του, αποτελεί τον πιο διαδεδομένο αλγόριθμο βελτιστοποίησης με πληθώρα εφαρμογών. Η αναπροσαρμογή

των βαρών και των πολώσεων σε κάθε επανάληψη γίνεται με τέτοιο τρόπο ώστε να οδηγεί στη μείωση της παραγώγου της μέσης τιμής του μετρητικού σφάλματος, ώστε να τείνει προς το μηδέν και άρα σε κάποιο ελάχιστο, τοπικό ή ολικό. Το μεγαλύτερο μειονέκτημά του είναι η ευκολία με την οποία μπορεί να παγιδευτεί σε κάποιο τοπικό βέλτιστο, ειδικά όταν το πρόβλημα παρουσιάζει μεγάλη πολυπλοκότητα [132].

#### 4.5.2 Μεταευρετικοί αλγόριθμοι

Όταν η αντικειμενική συνάρτηση είναι μη παραγωγίσιμη, οι κλασικοί αλγόριθμοι βελτιστοποίησης που βασίζονται στη μέθοδο βελτιστοποίησης «μείωση της κλίσης», όπως ο αλγόριθμος της προς τα πίσω διάδοσης του σφάλματος, είναι ακατάλληλοι. Οι στοχαστικοί αλγόριθμοι βελτιστοποίησης από την άλλη, οι οποίοι διακρίνονται σε δύο κατηγορίες, τους ευρετικούς και τους μεταευρετικούς αλγορίθμους, δεν κάνουν χρήση παραγώγου και επομένως είναι ιδανικοί για τέτοια προβλήματα [133].

Οι ευρετικοί αλγόριθμοι βασίζονται στην μέθοδο της δοκιμής και σφάλματος. Κάνουν ελάχιστες έως καθόλου υποθέσεις για το πρόβλημα που πρόκειται να βελτιστοποιηθεί. Παρόλο που μπορούν να δώσουν ποιοτικές λύσεις σε εύλογα χρονικά διαστήματα, δεν υπάρχει εγγύηση ότι οι λύσεις αυτές θα είναι βέλτιστες, καθώς δεν είναι δυνατόν να εξερευνηθεί το πεδίο τιμών στο σύνολό του. Οι ευρετικοί αλγόριθμοι χρησιμοποιούνται όταν δεν είναι αναγκαίο να βρεθούν οι βέλτιστες λύσεις, αλλά κάποιες λύσεις που υπολογίζονται γρήγορα και είναι επαρκώς ποιοτικές [133].

Οι μεταευρετικοί αλγόριθμοι με τη σειρά τους αποτελούν εξέλιξη των ευρετικών αλγορίθμων. Η μέθοδος αναζήτησης ενός βέλτιστου είναι παρόμοια με αυτή των ευρετικών αλγορίθμων. Ωστόσο, αντίθετα με τους ευρετικούς αλγορίθμους, οι μεταευρετικοί αλγόριθμοι εμπλέκουν μεθόδους τυχαιοποίησης ώστε να αποφεύγεται η παγίδευση σε τοπικά βέλτιστα, αλλά και μεθόδους τοπικής αναζήτησης ώστε να εξασφαλίζεται σε όσο το δυνατό μεγαλύτερο βαθμό η εύρεση μιας βέλτιστης λύσης. Έτσι, οι μεταευρετικοί αλγόριθμοι είναι κατάλληλοι για προβλήματα καθολικής βελτιστοποίησης [133].

##### 4.5.2.1 Εξελικτικοί Αλγόριθμοι

Ο βιολογικός εξελικτικός αλγόριθμος (Evolutionary Algorithm – EA) μπορεί να οριστεί ως μια στοχαστική μέθοδος αναζήτησης που προσομοιώνει τις διαδικασίες βιολογικής εξέλιξης ή την κοινωνική συμπεριφορά των ειδών, πέρα από τα άλλα είδη μέσω της μάθησης, της προσαρμογής και της εξέλιξης. Υπάρχουν τέσσερις κύριες μέθοδοι εξελικτικών αλγορίθμων, συμπεριλαμβανομένων του γενετικού αλγορίθμου, του εξελικτικού προγραμματισμού, του γενετικού προγραμματισμού και της διαφορικής εξέλιξης, που μπορούν να χρησιμοποιηθούν σε προβλήματα πρόβλεψης παραγωγής ενέργειας.

#### Γενετικός Αλγόριθμος (Genetic Algorithm – GA)

Ο γενετικός αλγόριθμος είναι ένας αλγόριθμος που βασίζεται στη μοντελοποίηση της διαδικασίας βιολογικής εξέλιξης για την επίλυση προβλημάτων βελτιστοποίησης και αναζήτησης [134]. Το GA απεικονίζει πολλά χρωμοσώματα, καθένα από τα οποία αντιπροσωπεύει μια λύση ή μια εφικτή λύση σε ένα συγκεκριμένο πρόβλημα.

**Εξελικτικός Προγραμματισμός (Evolutionary Programming – EP)**

Ο εξελικτικός προγραμματισμός είναι ένα μοντέλο μηχανικής εξέλιξης πεπερασμένης κατάστασης. Σε αυτό το μοντέλο, η κατάσταση της μηχανής μεταγλωττίζεται σύμφωνα με τον νόμο διανομής πληροφορίας [135]. Με την εισαγωγή ενός τελεστή μετάλλαξης κανονικής κατανομής, το EP καθίσταται ικανό να αντιμετωπίσει προβλήματα βελτιστοποίησης πραγματικών συνθηκών. Το EP έχει γίνει ένας ευρέως χρησιμοποιούμενος αλγόριθμος βελτιστοποίησης και πλέον έχει εφαρμοστεί σε πολλά πρακτικά προβλήματα.

**Γενετικός Προγραμματισμός (Genetic Programming – GP)**

Ο γενετικός προγραμματισμός αποτελεί μια εξελικτική μέθοδο υπολογισμού που προέρχεται από τη θεωρία της εξέλιξης του Δαρβίνου. Σε αντίθεση με τους γενετικούς αλγόριθμους στους οποίους κάθε άτομο αντιπροσωπεύει ένα κομμάτι κωδικοποίησης χρωμοσώματος, στο GP, το άτομο υποδηλώνει προγράμματα υπολογιστή, που αντιπροσωπεύονται από μια δομή δέντρου στη μνήμη του υπολογιστή. Ξεκινώντας με χιλιάδες τυχαία δημιουργημένα προγράμματα υπολογιστών, ένας πληθυσμός προγραμμάτων εξελίσσεται προοδευτικά σε πολλές γενιές.

**Διαφορική Εξέλιξη (Differential Evolution – DE)**

Ο αλγόριθμος διαφορικής εξέλιξης είναι μια εξελικτική τεχνολογία υπολογιστών. Παρόμοια με τους άλλους εξελικτικούς αλγόριθμους, η διαφορική εξέλιξη αποτελεί ένα στοχαστικό μοντέλο που προσομοιώνει τη βιολογική εξέλιξη, επιτρέποντας στα άτομα να διατηρηθούν μέσω επαναλαμβανόμενων επαναλήψεων [136]. Ο αλγόριθμος διαφορικής εξέλιξης μειώνει την πολυπλοκότητα της γενετικής χειραγώγησης χρησιμοποιώντας πραγματική κωδικοποίηση, λειτουργίες μετάλλαξης που βασίζονται σε διαφορικά και ανταγωνιστικές στρατηγικές επιβίωσης ένας προς έναν.

**4.5.2.2 Αλγόριθμοι βασισμένοι στη φυσική**

Ένας αλγόριθμος βελτιστοποίησης που βασίζεται στη φυσική είναι ένας άψυχος αλγόριθμος μεταερευτικών μηχανισμών, που αναπτύχθηκε σύμφωνα με τις φυσικές ιδιότητες ορισμένων φυσικών συμπεριφορών ή φυσικών νόμων. Οι πιο δημοφιλείς αλγόριθμοι είναι ο αλγόριθμος βαρυτικής αναζήτησης, η προσομοιωμένη ανόπτηση, ο αλγόριθμος ημιτόνου συνημιτόνου και ο αλγόριθμος χαοτικής βελτιστοποίησης.

**Αλγόριθμος βαρυτικής αναζήτησης (Gravitational Search Algorithm – GSA)**

Η αρχή του αλγόριθμου βαρυτικής αναζήτησης είναι ο νόμος της βαρύτητας και ο δεύτερος νόμος του Νεύτωνα, ο οποίος βρίσκει τη βέλτιστη λύση μετακινώντας τη θέση των σωματιδίων στον χώρο αναζήτησης [137]. Τα σωματίδια κινούνται στον χώρο σύμφωνα με τις βαρύνσεις μεταξύ τους. Όταν ένα από τα σωματίδια κινείται στη βέλτιστη θέση, βρίσκεται η βέλτιστη λύση.

**Προσομοιωμένη ανόπτησης (Simulated Annealing – SA)**

Οι αλγόριθμοι προσομοιωμένης ανόπτησης μπορούν να λάβουν μια κατά προσέγγιση λύση σε προβλήματα βελτιστοποίησης με βάση την ιδέα του Μόντε Κάρλο [138]. Στην τυχαία

αναζήτηση στον χώρο λύσης, η καλύτερη λύση γίνεται αποδεκτή σύμφωνα με μια ορισμένη πιθανότητα.

#### **Αλγόριθμος ημιτόνου συνημιτόνου (Sine Cosine Algorithm – SCA)**

Η ιδέα του αλγόριθμου ημιτόνου συνημιτόνου προέρχεται από το μαθηματικό μοντέλο της συνημιτονοειδούς συνάρτησης, που αποτελεί έναν σχετικά σύγχρονο αλγόριθμο βελτιστοποίησης [139]. Εμπνευσμένος από τις συναρτήσεις ημιτόνου και συνημιτόνου, ο αλγόριθμος προσομοιώνει προς τα έξω ή προς τη βέλτιστη κατεύθυνση κύματος λύσης και δημιουργεί πολλαπλές αρχικές τυχαίες υποψήφιες λύσεις. Επιπλέον, ο αλγόριθμος ενσωματώνει ορισμένες τυχαίες μεταβλητές και προσαρμοστικές μεταβλητές για να τονίσει την εξερεύνηση και τη χρήση του χώρου αναζήτησης σε διάφορα προβλήματα βελτιστοποίησης.

#### **Αλγόριθμος χαοτικής βελτιστοποίησης (Chaotic Optimization Algorithm – COA)**

Το χάος είναι ένα γενικό μη γραμμικό φαινόμενο, του οποίου η συμπεριφορά είναι πολύπλοκη αλλά έχει εγγενή κανονικότητα. Ένα θεμελιώδες χαρακτηριστικό των χαοτικών συστημάτων είναι ότι μικρές διακυμάνσεις στις παραμέτρους μπορούν να οδηγήσουν σε διαφορές στη μελλοντική συμπεριφορά, όπως σταθερά σημεία, περιοδικές ταλαντώσεις και διακλαδώσεις.

##### *4.5.2.3 Ανθρώπινοι αλγόριθμοι*

Οι αλγόριθμοι που βασίζονται στον ανθρώπινο παράγοντα προέρχονται από την προσομοίωση ορισμένων συμπεριφορών σε ανθρώπινες συμπεριφορές, για παράδειγμα, ο αλγόριθμος διδασκαλίας και μάθησης που εμπνέεται από εκπαιδευτικές δραστηριότητες δασκάλου και μαθητή, οι πολιτισμικοί αλγόριθμοι που είναι εμπνευσμένοι από την ανθρώπινη κοινωνιολογία και οι αλγόριθμοι αναζήτησης αρμονίας που έχουν εμπνευστεί από τους μουσικούς που προσαρμόζουν τον τόνο του μουσικού οργάνου.

#### **Αλγόριθμος διδασκαλίας και μάθησης (Teaching and Learning Algorithm – TLA)**

Ο αλγόριθμος διδασκαλίας και μάθησης είναι ένας νέος αλγόριθμος νοημοσύνης σμήνους που προσομοιώνει τη διδακτική διαδικασία των εκπαιδευτικών και τη μαθησιακή διαδικασία των μαθητών και στοχεύει στη βελτίωση της μαθησιακής απόδοσης των μαθητών μέσω της «διδασκαλίας» και της «μάθησης» μεταξύ των μαθητών [140].

#### **Πολιτιστικός αλγόριθμος (Cultural Algorithm – CA)**

Ο πολιτιστικός αλγόριθμος είναι ένας αλγόριθμος βελτιστοποίησης εξελικτικού μηχανισμού δύο επιπέδων. Αποκτά και ενσωματώνει τη γνώση της επίλυσης προβλημάτων μέσω ενός χώρου πεποιθήσεων ανεξάρτητου από τον πληθυσμιακό χώρο, που επιτρέπει στην ταχύτητα εξέλιξης του πληθυσμού να υπερβεί την ταχύτητα εξέλιξης βασιζόμενη αποκλειστικά σε βιολογικά γονίδια.

#### **Αναζήτηση αρμονίας (Harmony Search – HS)**

Η αναζήτηση αρμονίας είναι ένας αλγόριθμος καθολικής αναζήτησης, ο οποίος έχει εφαρμοστεί σε πολλά προβλήματα βελτιστοποίησης [141]. Σύμφωνα με την αρχή του αλγόριθμου, οι μουσικοί προσαρμόζουν τους τόνους κάθε οργάνου στο συγκρότημα

επανειλημμένα ανάλογα με τη μνήμη τους και τελικά επιτυγχάνεται μια τέλεια κατάσταση αρμονίας.

#### **Βελτιστοποίηση ομαδικής αναζήτησης (Group Search Optimization – GSO)**

Η έμπνευση της μεθόδου βελτιστοποίησης ομαδικής αναζήτησης προέρχεται από τη συμπεριφορά ζώων κατά την αναζήτηση τροφής [142]. Τα μέλη της ομάδας χωρίζονται σε τρεις κατηγορίες: παραγωγούς, παράσιτα και διασκορπισμένα μέλη. Σε κάθε επανάληψη, τα μέλη με τις καλύτερες θέσεις είναι παραγωγοί και διατηρούν τις θέσεις τους αμετάβλητες, ενώ τα άλλα μέλη επιλέγονται τυχαία ως παράσιτα ή διασκορπισμένα μέλη. Τα παράσιτα κινούνται προς τους παραγωγούς σε μια ορισμένη απόσταση και τα διασκορπισμένα μέλη κάνουν τυχαίους περιπάτους.

##### *4.5.2.4 Αλγόριθμοι νοημοσύνης σμήνους*

Ως αναδυόμενη εξελικτική υπολογιστική τεχνική, ο αλγόριθμος νοημοσύνης σμήνους χρησιμοποιείται για την προσομοίωση της συλλογικής συμπεριφοράς των ζώων στην κοινωνική φύση. Αν και αυτοί οι παράγοντες είναι σχετικά απλοί και έχουν περιορισμένες δυνατότητες, μπορούν να λάβουν τις απαραίτητες εργασίες μέσω της συνεργατικής αλληλεπίδρασης.

#### **Βελτιστοποίησης σμήνους σωματιδίων (Particle Swarm Optimization – PSO)**

Η βελτιστοποίηση σμήνους σωματιδίων είναι εμπνευσμένη από αποτελέσματα έρευνας τεχνητής ζωής, με προσομοίωση της συμπεριφοράς αναζήτησης τροφής πληθυσμών στη διαδικασία της μετανάστευσής τους [143]. Όλοι οι οργανισμοί στη φύση έχουν συγκεκριμένες συμπεριφορές σμήνους και ένας από τους κύριους ερευνητικούς τομείς της τεχνητής ζωής είναι η διερεύνηση της βιολογικής φύσης της ομαδικής συμπεριφοράς και η οικοδόμηση ως ένα υπολογιστικό μοντέλο. Στον PSO, η λύση κάθε βελτιστοποίησης ονομάζεται «σωματίδιο». Σε κάθε σωματίδιο δίνεται μνήμη για να θυμάται την καλύτερη τοποθεσία για αναζήτηση. Η προεπεξεργασία δεδομένων και η επιλογή παραμέτρων εισαγωγής μπορούν να βελτιώσουν την ακρίβεια πρόβλεψης.

#### **Αλγόριθμος βελτιστοποίησης φαλαινών (Whale Optimization Algorithm – WOA)**

Ο αλγόριθμος βελτιστοποίησης φαλαινών μιμείται την κυνηγετική συμπεριφορά των φαλαινών στην οποία χρησιμοποιείται η στρατηγική «διχτυού σπειροειδούς φουσαλίδας» και συλλαμβάνει την τροφή μέσω της συστολής και της περιβάλλουσας ενημέρωσης σπειροειδούς θέσης και της τεχνικής τυχαίου κυνηγιού [144]. Ο αλγόριθμος έχει απλή δομή με λίγες παραμέτρους προσαρμογής.

#### **Αλγόριθμος νυχτερίδας (Bat Algorithm – BA)**

Ο αλγόριθμος νυχτερίδας, αποτελεί έναν μεταευρετικό αλγόριθμο αναζήτησης και είναι μια αποτελεσματική μέθοδος για την αναζήτηση ολικά βέλτιστων λύσεων [145]. Αυτός ο αλγόριθμος χρησιμοποιεί μια επαναληπτική τεχνική βελτιστοποίησης, κατά την οποία αρχικοποιούνται τυχαίες λύσεις και στη συνέχεια επιτυγχάνεται η βέλτιστη λύση μέσω της επανάληψης. Δημιουργεί τοπικές νέες λύσεις μέσω τυχαίας πτήσης γύρω από τη βέλτιστη λύση, η οποία ενισχύει την τοπική αναζήτηση.

### **Βελτιστοποίηση γκρίζου λύκου (Grey Wolf Optimizer – GWO)**

Η βελτιστοποίηση γκρίζου λύκου είναι ένας αλγόριθμος που προήλθε από την προσομοίωση του ιεραρχικού μηχανισμού και της κυνηγετικής συμπεριφοράς του γκρίζου λύκου και πραγματοποιεί τη βελτιστοποίηση των σκοπών αναζήτησης μέσω της διαδικασίας παρακολούθησης, περικύκλωσης, κυνηγιού και επίθεσης των λύκων [146].

### **Αλγόριθμος πυγολαμπίδας (Firefly Algorithm – FA)**

Ο αλγόριθμος πυγολαμπίδας μιμείται τη συμπεριφορά της πυγολαμπίδας που τρεμοπαίζει [147]. Ο κύριος σκοπός μιας πυγολαμπίδας που τρεμοπαίζει είναι να προσελκύει άλλες πυγολαμπίδες. Ο αλγόριθμος υποθέτει ότι μια πυγολαμπίδα, ανεξάρτητα από το φύλο της, θα έλκεται από άλλες πυγολαμπίδες ανάλογα με την υψηλότερη φωτεινότητά τους. Η φωτεινότητα σχετίζεται με τη λειτουργία στόχου.



# Κεφάλαιο 5

## ΠΙΘΑΝΟΤΙΚΗ ΠΡΟΒΛΕΨΗ ΑΙΟΛΙΚΗΣ ΙΣΧΥΟΣ ΜΕ ΥΒΡΙΔΙΚΗ ΜΕΘΟΔΟ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

### 5.1 Εισαγωγή

Η αιολική ενέργεια αντιπροσωπεύει έναν από τους σημαντικότερους ανανεώσιμους πόρους για την παραγωγή αιολικής ενέργειας χάρη στον ευρέως κατανεμημένο χαρακτήρα της. Από την άλλη, η ανάγκη αποτελεσματικής αξιοποίησης της αιολικής ενέργειας έχει δημιουργήσει διάφορα προβλήματα λειτουργίας και σχεδιασμού, λόγω της στοχαστικής φύσης του ανέμου. Όπως περιγράφηκε και στο Κεφάλαιο 2, διάφορες μεθοδολογίες επικεντρώνονται στην αποτελεσματική αιτιοκρατική και πιθανοτική πρόβλεψη. Η κατανόηση της αβεβαιότητας στα μοντέλα πρόβλεψης και της εφαρμογής της σε προβλήματα της πραγματικής ζωής γίνεται ένα όλο και πιο σημαντικό αντικείμενο της σύγχρονης έρευνας. Λόγω της αυξανόμενης διείσδυσης της αιολικής ενέργειας στα συστήματα ηλεκτρικής ενέργειας, τα αιτιοκρατικά μοντέλα δεν μπορούν πάντα να χρησιμοποιηθούν αποτελεσματικά για προβλήματα της πραγματικής ζωής καθώς και για εργασίες λήψης αποφάσεων. Τα πιο συμβατικά πιθανοτικά μοντέλα πρόβλεψης εξετάζουν μια παραμετρική προσέγγιση, όπου η προγνωστική συνάρτηση πυκνότητας πιθανότητας ακολουθεί μία συγκεκριμένη κατανομή. Ωστόσο, μια τέτοια υπόθεση μιας συγκεκριμένης κατανομής δεν είναι πάντα λογική για προβλήματα της πραγματικής ζωής και ως εκ τούτου η παραμετρική προσέγγιση δεν είναι ιδανική για την αντιμετώπιση προβλημάτων λήψης αποφάσεων. Η μεθοδολογία LUBE αποτελεί ένα κλασσικό παράδειγμα μη παραμετρικής προσέγγισης που αποφεύγει τη χρήση προκαθορισμένων κατανομών των δεδομένων. Η βελτιστοποίηση των σύγχρονων μοντέλων πρόβλεψης αποτελεί σημαντικό σημείο ενδιαφέροντος, καθώς ο κατάλληλος συνδυασμός τεχνικών μηχανικής μάθησης με πολύπλοκους αλγόριθμους βελτιστοποίησης μπορεί να οδηγήσει σε αξιοσημείωτη βελτίωση του σφάλματος πρόβλεψης, αποφεύγοντας παράλληλα την επιβάρυνση του υπολογιστικού κόστους. Οι σύγχρονοι αλγόριθμοι βελτιστοποίησης τύπου σμήνους είναι σε θέση να διευρύνουν τις δυνατότητες αναζήτησης των μοντέλων πρόβλεψης, ωστόσο, η κατάλληλη ενσωμάτωσή τους στα μοντέλα πρόβλεψης μπορεί να αποτελούν σημαντική πρόκληση λόγω της πολυπλοκότητάς τους.

Για να καλυφθούν οι περιορισμοί που παρουσιάστηκαν παραπάνω, το παρόν κεφάλαιο περιγράφει τη διερεύνηση της δυνατότητας κατασκευής διαστημάτων πρόβλεψης υψηλής ακρίβειας μέσω της ανάπτυξης ενός καινοτόμου μοντέλου πρόβλεψης αιολικής παραγωγής σε ένα πιθανοτικό πλαίσιο, για έναν βραχυπρόθεσμο ορίζοντα πρόβλεψης. Εστιάζοντας στην απλοποίηση της διαδικασίας κατασκευής διαστημάτων πρόβλεψης χωρίς ταυτόχρονα να υπάρχει υστέρηση στην ποιότητα της πρόβλεψης, η μεθοδολογία LUBE, ως βάση του

προτεινόμενου μοντέλου αποτελεί μια προφανή επιλογή. Για τη βελτίωση της δυνατότητας αναζήτησης του μοντέλου LUBE προτείνεται και εφαρμόζεται ένας μεταερευνητικός, βελτιωμένος αλγόριθμος βελτιστοποίησης. Επιπλέον, για την απλοποίηση της διαδικασίας προεπεξεργασίας δεδομένων του προτεινόμενου μοντέλου, υιοθετείται ένας μετασχηματισμός κυματιδίων για την αποσύνθεση των αρχικών πρωτογενών δεδομένων.

Η αξιολόγηση του προτεινόμενου υβριδικού μοντέλου καθορίζεται από την ελαχιστοποίηση της συνάρτησης κόστους του Κριτηρίου Πλάτους Κάλυψης (CWC), η οποία ταυτόχρονα βελτιστοποιεί την ευκρίνεια και τη βαθμονόμηση των παραγόμενων διαστημάτων πρόβλεψης. Τα παρεχόμενα αποτελέσματα αναλύονται από εποχιακή άποψη. Το προτεινόμενο μοντέλο πρόβλεψης αιολικής ισχύος καταφέρνει:

- i. Να προτείνει ένα καινοτόμο πιθανοτικό μοντέλο βραχυπρόθεσμης πρόβλεψης αιολικής παραγωγής βασισμένο στη μεθοδολογία LUBE για την κατασκευή διαστημάτων πρόβλεψης υψηλής ακρίβειας, εκμεταλλεύόμενο την ικανότητά της να δημιουργεί απευθείας διαστήματα πρόβλεψης από τις εξόδους ενός νευρωνικού δικτύου εμπρόσθιας τροφοδότησης.
- ii. Να ενσωματώσει επιτυχώς στο μοντέλο έναν αλγόριθμο βελτιστοποίησης PSO μαζί με έναν τελεστή μετάλλαξης, προκειμένου να βελτιστοποιηθούν τα βάρη και οι πολώσεις των χρησιμοποιούμενων νευρωνικών δικτύων. Προκειμένου να απλοποιηθεί η προεπεξεργασία των δεδομένων αιολικής ενέργειας καθώς και να βελτιωθεί η ακρίβεια πρόβλεψης του μοντέλου, ο μετασχηματισμός κυματιδίων εφαρμόζεται στο παρεχόμενο σύνολο δεδομένων.
- iii. Να προσαρμόσει κατάλληλα τη μέθοδο αρχικοποίησης Yam-Chow προκειμένου να αρχικοποιηθούν αποτελεσματικά τα βάρη του νευρωνικού δικτύου κατά τη διαδικασία εκπαίδευσης. Η χρήση του αλγορίθμου αρχικοποίησης Yam-Chow στο προτεινόμενο μοντέλο καταφέρνει να βελτιώσει την ταχύτητα εκπαίδευσης του νευρωνικού δικτύου, μειώνοντας το αρχικό σφάλμα, εμποδίζοντάς το να παγιδευτεί στη χρήση των αρχικών βαρών. Η μέθοδος αρχικοποίησης Yam-Chow τροποποιείται περαιτέρω ώστε να εφαρμοστεί στην προτεινόμενη μεθοδολογία LUBE.
- iv. Εφαρμόζει τη διασταυρούμενη επικύρωση k-fold προκειμένου να βελτιωθεί περαιτέρω η ακρίβεια του μοντέλου. Ο στόχος της διασταυρούμενης επικύρωσης k-fold είναι διττός. Αρχικά εφαρμόζεται στο προτεινόμενο μοντέλο προκειμένου να προσδιοριστεί η βέλτιστη δομή του νευρωνικού δικτύου, ενώ στη συνέχεια εφαρμόζεται περαιτέρω για τον καθορισμό του βέλτιστου αριθμού των σωματιδίων του σμήνους για τον αλγόριθμο PSO.

## 5.2 Ανάλυση και επεξεργασία αιολικών δεδομένων

Το σύνολο δεδομένων που χρησιμοποιήθηκε προέρχεται από το αρχείο του Παγκόσμιου Διαγωνισμού Ενεργειακών Προβλέψεων 2014 (GEFCom2014) [148]. Περιέχει ωριαία δεδομένα που συλλέγονται από 10 αιολικά πάρκα στην Αυστραλία, αποτελούμενα από παρατηρήσεις ανέμου από δύο διαφορετικά υψόμετρα, 10 μέτρα και 100 μέτρα πάνω από το

έδαφος. Για κάθε μία από τις δέκα περιπτώσεις, τα παρεχόμενα δεδομένα αποτελούνται από τις συνιστώσες του ζωνικού και μεσημβρινού ανέμου, αντίστοιχα ( $u_{10}$ ,  $v_{10}$ ,  $u_{100}$ ,  $v_{100}$ ) καθώς και τις τιμές της παραγόμενης αιολικής ενέργειας κανονικοποιημένες από την ονομαστική ισχύ κάθε πάρκου. Η ταχύτητα του ανέμου ( $ws$ ) και η διεύθυνση του ανέμου ( $wd$ ) υπολογίζονται από:

$$ws = \sqrt{u^2 + v^2} \quad (5.1)$$


και

$$wd = \frac{180}{\pi} \tan^{-1}(u, v) = \begin{cases} \tan^{-1}\left(\frac{v}{u}\right) & \text{αν } u > 0 \\ \tan^{-1}\left(\frac{v}{u}\right) + \pi & \text{αν } u < 0 \text{ και } v \geq 0 \\ \tan^{-1}\left(\frac{v}{u}\right) + \pi & \text{αν } u < 0 \text{ και } v < 0 \\ \frac{\pi}{2} & \text{αν } u = 0 \text{ και } v > 0 \\ -\frac{\pi}{2} & \text{αν } u = 0 \text{ και } v < 0 \\ \text{δεν ορίζεται} & \text{αν } u = 0 \text{ και } v = 0 \end{cases} \quad (5.2)$$

Η συσχέτιση μεταξύ της ταχύτητας του ανέμου και της διεύθυνσης του ανέμου με τις συνιστώσες του ζωνικού και μεσημβρινού ανέμου παρουσιάζεται στο Σχήμα 5.1.

Τα σύνολα δεδομένων που χρησιμοποιούνται για την εκπαίδευση και την αξιολόγηση του μοντέλου περιέχουν ωριαίες πληροφορίες από την 1η Ιουνίου 2012 έως τις 31 Μαΐου 2013 για καθένα από τα αιολικά πάρκα. Τα δεδομένα αιολικής ισχύος από το σύνολο δεδομένων εκπαίδευσης κανονικοποιούνται στο διάστημα  $[0, 1]$ , ενώ τα δεδομένα ταχύτητας και διεύθυνσης ανέμου κανονικοποιούνται στο διάστημα  $[-1, 1]$ .

Για την απλοποίηση των χρονοσειρών αιολικής ενέργειας και την ανάλυσή τους στις συνιστώσες τους, επιλέχθηκε ο μετασχηματισμός κυματιδίων (Wavelet Transform – WT). Η χρήση του WT στοχεύει στην αποσύνθεση του αρχικού σήματος και στην εξαγωγή ζωτικών χαρακτηριστικών σε διαφορετικά επίπεδα αποσύνθεσης, [149]. Ένα από τα κύρια πλεονεκτήματα της ανάλυσης κυματιδίων είναι η ικανότητά της να αποκαλύπτει πτυχές δεδομένων που άλλες τεχνικές ανάλυσης σήματος δεν μπορούν να εντοπίζουν. Ως αποτέλεσμα, η ανάλυση κυματιδίων επιτρέπει την ανίχνευση προβλημάτων στα δεδομένα, όπως ελλιπή δεδομένα, ασυνέχειες ή ψευδή δεδομένα. Οι δυνατότητες φιλτραρίσματος του μετασχηματισμού κυματιδίων προσφέρουν σειρές δεδομένων αιολικής ισχύος με καλύτερη συνολική συμπεριφορά και έτσι δίνουν τη δυνατότητα ακριβέστερων προβλέψεων [150]. Οι χρονοσειρές αιολικής ενέργειας περιέχουν συνιστώσες διαφορετικών συχνοτήτων, όπου οι συνεισφορές των συνιστωσών χαμηλής συχνότητας και υψηλής συχνότητας τείνουν να έχουν διαφορετική δυναμική σημασία στη συμπεριφορά του μοντέλου. Ένα άλλο σημαντικό πλεονέκτημα της ανάλυσης κυματιδίων είναι η ικανότητά της να αντιμετωπίζει αποτελεσματικά προβλήματα μη στατικών χρονοσειρών, όπως τα δεδομένα αιολικής ενέργειας [151].



**Σχήμα 5.1** Συσχέτιση μεταξύ της ταχύτητας του ανέμου και της διεύθυνσης του ανέμου με τις ζωνικές και μεσημβρινές συνιστώσες τους.

Ο μετασχηματισμός κυματιδίων μπορεί να χωριστεί σε δύο κατηγορίες: τον συνεχή μετασχηματισμό κυματιδίων (Continuous Wavelet Transform – CWT) και τον διακριτό μετασχηματισμό κυματιδίων (Distinctive Wavelet Transform – DWT).

Ο συνεχής μετασχηματισμός κυματιδίων παρουσιάζεται από:

$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(x) \phi\left(\frac{x-b}{a}\right) dx \quad (5.3)$$

όπου  $f(x)$  είναι το σήμα,  $\phi(x)$  είναι το μητρικό κυματίδιο, η παράμετρος κλίμακας  $a$  ελέγχει την εξάπλωση του κυματιδίου και η παράμετρος μετάφρασης  $b$  καθορίζει την κεντρική θέση του κυματιδίου.

Ο διακριτός μετασχηματισμός κυματιδίων παρουσιάζεται από:


$$W(m, n) = 2^{-\left(\frac{m}{2}\right)} \sum_{t=0}^{T-1} f(t) \phi\left(\frac{t - n \cdot 2^m}{2^m}\right) \quad (5.4)$$

όπου  $f(t)$  είναι το σήμα,  $T$  είναι το μήκος του σήματος,  $t$  είναι ο διακριτός δείκτης χρόνου και η παράμετρος κλίμακας  $a$  και η παράμετρος μετάφρασης  $b$  προέρχονται από τις ακέραιες μεταβλητές  $m$  και  $n$  οι οποίες ορίζονται όπως:

$$a = 2^m \quad (5.5)$$

και

$$b = n \cdot 2^m \quad (5.6)$$



**Σχήμα 5.2** Διαδικασία αποσύνθεσης μετασχηματισμού κυματιδίων του αρχικού σήματος.


Οι ακέραιες μεταβλητές  $m$  και  $n$  ελέγχουν τη διαστολή και τη μετάφραση του κυματιδίου, αντίστοιχα, και περιέχονται στο σύνολο όλων των ακεραίων, θετικών και αρνητικών [152].

Ένας αλγόριθμος διακριτού μετασχηματισμού κυματιδίων που βασίζεται σε τέσσερα φίλτρα [153] εξετάζεται στο υπό εξέταση πρόβλημα. Η πολλαπλή ανάλυση, βασισμένη στον αλγόριθμο του Mallat, προτείνεται για τη λήψη "προσεγγίσεων" και "λεπτομερειών" από το σήμα που αναλύεται. Ενώ η προσέγγιση ακολουθεί το σχήμα του αρχικού σήματος, οι λεπτομέρειες περιγράφουν συστατικά του σήματος από υψηλότερες συχνότητες. Η διαδικασία αποσύνθεσης παρουσιάζεται στο Σχήμα 5.2.

Μια συνάρτηση κυματιδίων τύπου Daubechies τάξης 4 ( $Db4$ ), η οποία χρησιμοποιείται ως μητρικό κυματίδιο, μαζί με τρία επίπεδα αποσύνθεσης, εξετάζεται σε αυτό το πρόβλημα. Η προτεινόμενη μεθοδολογία χρησιμοποιεί ως δεδομένα εισόδου την προσέγγιση  $A3$  και τις λεπτομέρειες  $D3$ ,  $D2$  και  $D1$ .

### 5.3 Εκτίμηση κάτω και άνω ορίου του διαστήματος πρόβλεψης με βελτιστοποίηση σμήνους σωματιδίων του κριτηρίου του εύρους κάλυψης

Ένα από τα πιο συνηθισμένα προβλήματα που συναντώνται στις μεθοδολογίες για την κατασκευή διαστημάτων πρόβλεψης από προβλέψεις με χρήση νευρωνικών δικτύων είναι η υπόθεση της κατανομής δεδομένων. Ενώ τέτοιες παραδοχές των σφαλμάτων πρόβλεψης μπορούν να απλοποιήσουν τη διαδικασία κατασκευής διαστημάτων πρόβλεψης, δημιουργούν άλλα προβλήματα σχετικά με την πιθανή απόκλιση των δεδομένων από την προκαθορισμένη κατανομή. Ως αποτέλεσμα, τέτοιες μεθοδολογίες δεν είναι βέλτιστες για να αντιμετωπίσουν πραγματικές εφαρμογές και συνήθως υποφέρουν από υψηλό υπολογιστικό κόστος.



**Σχήμα 5.3** Αναπαράσταση ενός νευρωνικού δικτύου που χρησιμοποιείται στη μεθοδολογία LUBE για την κατασκευή του κάτω και άνω ορίου.

### 5.3.1 Μέθοδος εκτίμησης κάτω και άνω ορίου (Lower Upper Bound Estimation – LUBE)

Σε αυτό το κεφάλαιο παρουσιάζεται ένα καινοτόμο μοντέλο πρόβλεψης αιολικής ισχύος βασισμένο στη μέθοδο εκτίμησης κάτω και άνω ορίου [154]. Το κύριο πλεονέκτημα της μεθοδολογίας LUBE είναι η απλοποίηση της κατασκευής διαστημάτων πρόβλεψης. Η μέθοδος LUBE χρησιμοποιεί ένα FFNN για να εκτιμήσει το κατώτερο και το ανώτερο όριο ενός διαστήματος πρόβλεψης. Το FFNN έχει δύο εξόδους σημειακής πρόβλεψης που αντιπροσωπεύουν το κατώτερο και το ανώτερο όριο του διαστήματος πρόβλεψης. Σε αντίθεση με τις περισσότερες μεθόδους πιθανοτικής πρόβλεψης, η μέθοδος LUBE παράγει απευθείας τα διαστήματα πρόβλεψης μέσω του τεχνητού νευρωνικού δικτύου, χωρίς κάποια επιπρόσθετη στατιστική διαδικασία. Σχηματικό διάγραμμα της μεθόδου LUBE παρουσιάζεται στο Σχήμα 5.3.

Η μη ανάγκη παραπάνω μαθηματικών υπολογισμών και στατιστικών μεθόδων για την παραγωγή των διαστημάτων πρόβλεψης καθιστούν τη μέθοδο LUBE ταχύτερη σε σύγκριση με άλλες μεθόδους πιθανοτικής πρόβλεψης, και πιο απλή στην υλοποίησή της. Επίσης, το γεγονός ότι δεν γίνονται υπολογισμοί παραγώγων κατά τη διάρκεια της εκπαίδευσης του τεχνητού νευρωνικού δικτύου μειώνει την πιθανότητα η μέθοδος LUBE να παγιδευτεί σε κάποιο τοπικό βέλτιστο, καθιστώντας τη μέθοδο LUBE πιο αξιόπιστη σε σχέση με άλλες πιθανοτικές μεθόδους [155]. Η μέθοδος LUBE είναι μια μη παραμετρική μέθοδος, που σημαίνει ότι δεν κάνει καμία υπόθεση για την κατανομή των δεδομένων και των σφαλμάτων πρόβλεψης [154].

### 5.3.2 Αλγόριθμος σμήνους σωματιδίων (PSO)

Η βελτιστοποίηση σμήνους σωματιδίων είναι μια μεταερευνητική προσέγγιση βελτιστοποίησης, η οποία ανήκει στον τομέα της νοημοσύνης σμήνους. Προτάθηκε και εισήχθη ως εξελικτική υπολογιστική μέθοδος για την αντιμετώπιση της βελτιστοποίησης προβλημάτων λήψης αποφάσεων συνεχούς και ασυνεχούς συνάρτησης [156]. Όντας μέρος του πεδίου της

νοημοσύνης σμήνους, το PSO θεωρεί ένα περιβάλλον αναζήτησης όπου κάθε πιθανή λύση αντιπροσωπεύεται ως σωματίδιο ενός σμήνους. Σε κάθε πρόβλημα, κάθε σωματίδιο πετάει στο χώρο λύσης, προτείνοντας μια πιθανή λύση, σε κάθε επανάληψη, στο πρόβλημα που βελτιστοποιείται.

Η κίνηση κάθε σωματιδίου στον χώρο λύσης ορίζεται ως εξής: μια τυχαία θέση εκχωρείται σε κάθε σωματίδιο που αντιστοιχεί σε μια πιθανή λύση για τη δεδομένη επανάληψη του προβλήματος βελτιστοποίησης. Κάθε σωματίδιο ορίζεται από ένα διάνυσμα ταχύτητας, την τρέχουσα θέση του και την καλύτερη θέση του στο χώρο λύσης. Στη συνέχεια, αξιολογείται η θέση κάθε σωματιδίου σε κάθε επανάληψη, αντιπροσωπεύοντας πόσο κοντά είναι η θέση σε μια βέλτιστη λύση.

Κάθε σωματίδιο απομνημονεύει την καλύτερη θέση του σε όλες τις επαναλήψεις ως  $P_{best}$  και η καλύτερη τιμή του που ορίζεται λαμβάνοντας υπόψη ολόκληρο το σμήνος απομνημονεύεται ως  $G_{best}$ . Οι εξισώσεις που χρησιμοποιούνται για την ενημέρωση της ταχύτητας και της θέσης κάθε σωματιδίου σε κάθε επανάληψη είναι οι ακόλουθες:

$$v_n(G+1) = wv_n(G) + c_1r_1(P_{best,n} - x_n(G)) + c_2r_2(G_{best,n} - x_n(G)) \quad (5.7)$$

$$x_n(G+1) = x_n(G) + v_n(G+1) \quad (5.8)$$


όπου,  $v_n$  και  $x_n$  αντιπροσωπεύουν την ταχύτητα και τη θέση του n-οστού σωματιδίου στην επανάληψη  $G$ ,  $r_1, r_2 \in [0, 1]$  είναι τυχαίες μεταβλητές,  $c_1, c_2 \in [1, 2]$  είναι σταθερές επιτάχυνσης,  $w$  είναι το βάρος αδράνειας που αντιπροσωπεύεται από:

$$w = w_{max} - \frac{w_{max} - w_{min}}{G_{max}} \times G \quad (5.9)$$

όπου,  $w_{max}$  και  $w_{min}$  ορίζουν το αρχικό και τελικό βάρος αδράνειας και οι τιμές τους επιλέγονται ως 1.2 και 0.2 αντίστοιχα, και  $G_{max}$  είναι ο μέγιστος αριθμός επαναλήψεων. Το βάρος αδράνειας είναι ένας σημαντικός παράγοντας στη σύγκλιση των σωματιδίων ενός σμήνους.

#### 5.4 Τελικό προτεινόμενο μοντέλο πιθανοτικής πρόβλεψης αιολικής παραγωγής

Στο παρόν κεφάλαιο παρουσιάζεται ένα καινοτόμο μοντέλο πρόβλεψης αιολικής παραγωγής βασισμένο στη μέθοδο LUBE για την κατασκευή των διαστημάτων πρόβλεψης αιολικής ισχύος. Χρησιμοποιείται μια μέθοδος διασταυρούμενης επικύρωσης k-fold προκειμένου να προσδιοριστεί η βέλτιστη δομή του νευρωνικού δικτύου για το προτεινόμενο μοντέλο. Η διασταυρούμενη επικύρωση k-fold χρησιμοποιείται στο σύνολο δεδομένων εκπαίδευσης για να διαχωριστεί από το σύνολο δεδομένων δοκιμής. Η μέθοδος k-fold χωρίζει το σύνολο εκπαίδευσης σε  $k$  συμπληρωματικές πτυχές, όπου οι  $k-1$  πτυχές χρησιμοποιούνται για τη διαδικασία εκπαίδευσης των νευρωνικών και οι υπόλοιπες πτυχές χρησιμοποιούνται για τη διαδικασία επικύρωσης [157]. Μια πενταπλή διασταυρούμενη επικύρωση προτείνεται στο υπό διερεύνηση πρόβλημα.



**Σχήμα 5.4** Διάγραμμα ροής της διαδικασίας αρχικοποίησης του Yam-Chow.

Ο αλγόριθμος PSO χρησιμοποιείται περαιτέρω προκειμένου να βελτιστοποιηθούν τα βάρη και οι πολώσεις του νευρωνικού δικτύου. Εκτός από τον ορισμό της βέλτιστης δομής του νευρωνικού δικτύου, όπως περιγράφηκε παραπάνω, εφαρμόζεται περαιτέρω μια πενταπλή διασταυρούμενη επικύρωση για τον καθορισμό του βέλτιστου αριθμού των σωματιδίων του σμήνους για τον αλγόριθμο PSO.

Η ελαχιστοποίηση της συνάρτησης κόστους CWC είναι το κριτήριο βελτιστοποίησης του προτεινόμενου μοντέλου, καθώς επιτρέπει την ταυτόχρονη βελτιστοποίηση τόσο της βαθμονόμησης όσο και της ευκρίνειας των κατασκευασμένων διαστημάτων πρόβλεψης.

Πιο συγκεκριμένα, για κάθε μία από τις δύο ζώνες που ερευνήθηκαν, το σύνολο δεδομένων χωρίζεται τυχαία σε ένα σύνολο εκπαίδευσης και ένα σύνολο δοκιμών. Από τα δεδομένα, το 75% χρησιμοποιείται για τη διαδικασία εκπαίδευσης και το υπόλοιπο 25% χρησιμοποιείται για δοκιμές. Το σύνολο δεδομένων εκπαίδευσης χωρίζεται σε σύνολα υποεκπαίδευσης και σύνολα επικύρωσης μέσω της μεθόδου πενταπλής διασταυρούμενης επικύρωσης.

Η διαδικασία αρχικοποίησης αφορά στην αρχικοποίηση των παραμέτρων του νευρωνικού δικτύου και του PSO. Η βέλτιστη αρχικοποίηση των βαρών του νευρωνικού δικτύου οδηγεί σε καλύτερα και ακριβέστερα αποτελέσματα για το μοντέλο πρόβλεψης. Η μέθοδος αρχικοποίησης Yam-Chow υιοθετήθηκε στο παρόν πρόβλημα προκειμένου να εκτελεστεί η αρχικοποίηση των βαρών του FFNN που χρησιμοποιείται για την διαδικασία εκπαίδευσης. Ο αλγόριθμος αρχικοποίησης Yam-Chow εισήχθη στο [158], προκειμένου να βελτιωθεί η ταχύτητα εκπαίδευσης του FFNN. Ο στόχος αυτής της μεθόδου είναι να μειώσει το αρχικό σφάλμα πρόβλεψης εμποδίζοντας το νευρωνικό δίκτυο να “κολλήσει” στα αρχικά βάρη. Οι έξοδοι των κρυφών στρωμάτων παραμένουν στην ενεργή περιοχή όπου η παράγωγος της λειτουργίας ενεργοποίησης δίνει μεγάλες τιμές. Οι βέλτιστες τιμές των βαρών από το τελευταίο κρυφό στρώμα αξιολογούνται με τη μέθοδο των ελαχίστων τετραγώνων. Ένα διάγραμμα ροής της διαδικασίας αρχικοποίησης του Yam-Chow παρουσιάζεται στο Σχήμα 5.4.


Το μέγεθος των βαρών για ένα μοτίβο  $p$  ορίζεται από:

$$\theta_p^l \leq \bar{s} \begin{cases} \sqrt{\frac{3}{(n_l + 1) \sum_{i=1}^{n_l+1} (Q_{p,i}^l)^2}} & \text{για βάρη με ομοιόμορφη κατανομή} \\ \sqrt{\frac{1}{(n_l + 1) \sum_{i=1}^{n_l+1} (Q_{p,i}^l)^2}} & \text{για βάρη με κανονική κατανομή} \end{cases} \quad (5.10)$$

όπου,  $\theta_p^l$  είναι το μέγεθος των βαρών,  $Q$  είναι η έξοδος του στρώματος  $l$  και  $n_l$  είναι ένας μεγάλος αριθμός. Προκειμένου να επιβεβαιωθεί ότι οι έξοδοι των κρυφών νευρώνων παραμένουν στην ενεργή περιοχή, χρησιμοποιείται η ακόλουθη τιμή:

$$\theta^l = \min(\theta_p^l) \quad \text{για } p = 1, \dots, P \quad (5.11)$$

Η διαδικασία αρχικοποίησης είναι η ακόλουθη: το  $\theta^l$  αξιολογείται εφαρμόζοντας τις εξισώσεις (5.10) και (5.11), χρησιμοποιώντας τα στρώματα εισόδου για  $l = 1$ . Στη συνέχεια, τα βάρη αρχικοποιούνται τυχαία με ομοιόμορφη κατανομή μεταξύ  $-\theta^l$  και  $\theta^l$  ή με κανονική κατανομή  $N(0, (\theta_p^l)^2)$ . Στη συνέχεια, το  $a_{p,i}^2$  αξιολογείται με την εμπρόσθια τροφοδότηση των



**Σχήμα 5.5** Πλήρες διάγραμμα ροής της προτεινόμενης μεθοδολογίας WT-LUBE-PSO-CWC.

μοτίβων εισόδου μέσω του δικτύου με τα αρχικά βάρη. Στη συνέχεια, για  $l = 1, 2, \dots, L - 2$ , η  $\theta^l$  αξιολογείται εφαρμόζοντας τις εξισώσεις (5.10) και (5.11), χρησιμοποιώντας την έξοδο του στρώματος  $l$ . Τα βάρη αρχικοποιούνται και πάλι τυχαία με ομοιόμορφη κατανομή μεταξύ  $-\theta^l$  και  $\theta^l$  ή με κανονική κατανομή  $N(0, (\theta_p^l)^2)$ . Στη συνέχεια, το  $a_{p,i}^{l+1}$  αξιολογείται με επανατροφοδότηση των αποτελεσμάτων του  $a_{p,i}^l$  μέσω του δικτύου με τα αρχικά βάρη. Όταν το  $a_{p,i}^{L+1}$  ή το  $A^{L-1}$  εντοπίζεται, το τελευταίο στρώμα βαρών  $W^{L-1}$  υπολογίζεται με τη μέθοδο των ελαχίστων τετραγώνων και προκύπτει από:

$$\text{minimize} \|A^{L-1}W^{L-1} - S\|_2 \quad (5.12)$$

όπου  $S$  είναι ένας πίνακας με καταχωρίσεις:

$$S_{i,j} = f^{-1}(K_{i,j}) \quad (5.13)$$

όπου  $K_{i,j}$  είναι οι καταχωρίσεις του πίνακα-στόχου  $D$ .

Ωστόσο, λόγω του ότι το προτεινόμενο μοντέλο που βασίζεται στη μεθοδολογία LUBE που χρησιμοποιείται σε αυτή την εργασία έχει δύο εξόδους προκειμένου να κατασκευαστούν τα όρια των διαστημάτων πρόβλεψης, η μεθοδολογία αρχικοποίησης Yam-Chow τροποποιείται κατάλληλα ώστε ο πίνακας  $D$  να έχει δύο στήλες εξόδου αντί για μία.

Η ενημέρωση της ταχύτητας και θέσης των σωματιδίων είναι δύο βασικές διαδικασίες του αλγορίθμου PSO. Μέσω των εξισώσεων (5.7) και (5.8), ενημερώνεται η ταχύτητα και η θέση των σωματιδίων του σμήνους.

Επιπλέον, εφαρμόζεται ένας τελεστής μετάλλαξης για το PSO. Οι τελεστές μετάλλαξης αποσκοπούν στο να προσθέσουν μεταβλητότητα σε έναν πληθυσμό δημιουργώντας παραλλαγή σε ένα παρόν άτομο και ως εκ τούτου να μειώσουν την πιθανότητα παγίδευσης του πληθυσμού σε τοπικά βέλτιστα [159]. Ως αποτέλεσμα, με την εφαρμογή ενός τελεστή μετάλλαξης στο PSO, η προτεινόμενη μεθοδολογία καταφέρνει να ενισχύσει περαιτέρω την απόδοση του αλγορίθμου βελτιώνοντας την ικανότητα ολικής αναζήτησης. Ο Γκαουσιανός τελεστής μετάλλαξης εφαρμόζεται στα σωματίδια μέσω:

$$\text{mutate}(x_{id}) = x_{id} + \text{gaussian}(\sigma) \quad (5.14)$$

όπου  $x_{id}$  είναι η διάσταση θέσης σωματιδίων και  $\sigma$  ορίζεται σε 0.1 φορές το εύρος της διάστασης σωματιδίων.

Ο ρυθμός μετάλλαξης μειώνεται γραμμικά κατά τη διάρκεια της διαδικασίας βελτιστοποίησης, προκειμένου να παρέχει περισσότερο χώρο αναζήτησης στον αλγόριθμο πριν από τη σύγκλιση των σωματιδίων.

Όταν ολοκληρωθεί η επικαιροποίηση των βαρών, τα νέα διαστήματα πρόβλεψης κατασκευάζονται μέσω της μεθοδολογίας LUBE, ακολουθούμενη από την εκτίμηση των PICP, PINRW μετρητικών αξιολόγησης, καθώς και τον υπολογισμό της συνάρτησης κόστους CWC. Για την ενημέρωση των τιμών  $P_{best}$  και  $G_{best}$ , χρησιμοποιείται το κριτήριο της συνάρτησης κόστους CWC. Για κάθε σωματίδιο, όταν η νέα τιμή CWC είναι μικρότερη από την ήδη υπάρχουσα τιμή CWC του  $P_{best}$ , τότε η τιμή  $P_{best}$  για αυτό το σωματίδιο αντικαθίσταται από τα νέα βάρη. Όσο για το  $G_{best}$ , εάν η νέα τιμή του CWC του  $P_{best}$  είναι μικρότερη από αυτή του  $G_{best}$ , τότε το  $G_{best}$  ενημερώνεται.

Η εκπαιδευτική διαδικασία ολοκληρώνεται όταν επιτευχθεί ο μέγιστος αριθμός επαναλήψεων. Η αξιολόγηση του παραπάνω μοντέλου πραγματοποιείται με τα μετρητικά

αξιολόγησης των PICP, PINAW, CWC και CRPS. Η όλη διαδικασία επαναλαμβάνεται πέντε φορές, προκειμένου να είναι δυνατή η στατιστική ανάλυση της απόδοσης του μοντέλου πρόβλεψης.

Η πλήρης αρχιτεκτονική του τελικού μοντέλου πρόβλεψης απεικονίζεται στο Σχήμα 5.5.

## 5.5 Βελτιστοποίηση υπερπαραμέτρων μοντέλου πρόβλεψης

Οι τελικές υπερπαραμέτροι τόσο του προτεινόμενου μοντέλου όσο και του βασικού μοντέλου σύγκρισης, μετά από διαδικασία δοκιμής και σφάλματος παρουσιάζονται στους Πίνακες 5.1 και 5.2, αντίστοιχα.

**Πίνακας 5.1** Βέλτιστες τιμές των υπερπαραμέτρων του προτεινόμενου μοντέλου WT-LUBE-PSO-CWC.

| Παράμετρος                                   | Τιμή                           |
|----------------------------------------------|--------------------------------|
| Συνάρτηση ενεργοποίησης κρυφού στρώματος     | Διπολική σιγμοειδής            |
| Συνάρτηση ενεργοποίησης στρώματος εξόδου     | Σιγμοειδής                     |
| Αριθμός νευρώνων στρώματος εισόδου ( $N_i$ ) | 9                              |
| Αριθμός νευρώνων κρυφού στρώματος ( $N_h$ )  | 5 (WT-LUBE-PSO-CWC)            |
| Διάστημα εμπιστοσύνης ( $\mu$ )              | 0.9                            |
| $h$                                          | 80                             |
| Αριθμός σωματιδίων ( $n_{particles}$ )       | 80                             |
| $w$                                          | $w_{max} = 0.7, w_{min} = 0.4$ |
| $c_1$                                        | 1.2                            |
| $c_2$                                        | 1.3                            |
| Αριθμός επαναλήψεων ( $n_{iter}$ )           | 100                            |
| $X_{max}$                                    | 4                              |
| $V_{max}$                                    | 1                              |

**Πίνακας 5.2** Βέλτιστες τιμές των υπερπαραμέτρων του μοντέλου BELM.

| Παράμετρος                                   | Τιμή       |
|----------------------------------------------|------------|
| Συνάρτηση ενεργοποίησης κρυφού στρώματος     | Σιγμοειδής |
| Συνάρτηση ενεργοποίησης στρώματος εξόδου     | Σιγμοειδής |
| Αριθμός νευρώνων στρώματος εισόδου ( $N_i$ ) | 4          |
| Αριθμός νευρώνων κρυφού στρώματος ( $N_h$ )  | 80         |
| Διάστημα εμπιστοσύνης ( $\mu$ )              | 0.9        |
| Αριθμός ELM                                  | 300        |

### 5.6 Εποχική ανάλυση και σύγκριση αποδοτικότητας σφαλμάτων πρόβλεψης

Οι Πίνακες 5.3 έως 5.6 παρουσιάζουν τα αποτελέσματα της αξιολόγησης πέντε διαφορετικών δοκιμών, για κάθε εποχή της Ζώνης 1, του προτεινόμενου WT-LUBE-PSO-CWC σε σύγκριση με το BELM για επίπεδο εμπιστοσύνης 90%. Οι επιλεγμένοι δείκτες αξιολόγησης είναι PICP, PINAW, CWC και CRPS. Για κάθε δείκτη αξιολόγησης, υπολογίζεται η διάμεση τιμή των πέντε διαφορετικών διαδικασιών εκπαίδευσης, ενώ οι καλύτερες διάμεσες τιμές υποδεικνύονται με έντονους χαρακτήρες. Παρόμοια, οι Πίνακες 5.7 έως 5.10 συγκρίνουν τα αποτελέσματα του προτεινόμενου WT-LUBE-PSO-CWC με τα αποτελέσματα του BELM, για δεδομένα που αντιστοιχούν στη Ζώνη 7.

**Πίνακας 5.3** Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 1, για το καλοκαίρι του 2012, για διάστημα εμπιστοσύνης 90%.

| Επανάληψη    | WT-LUBE-PSO-CWC |        |        |        | BELM   |        |        |        |
|--------------|-----------------|--------|--------|--------|--------|--------|--------|--------|
|              | PICP            | PINAW  | CWC    | CRPS   | PICP   | PINAW  | CWC    | CRPS   |
| 1            | 0,9293          | 0,5877 | 0,5877 | 0,1212 | 0,9130 | 0,6115 | 0,6115 | 0,1522 |
| 2            | 0,9365          | 0,5609 | 0,5609 | 0,1211 | 0,9221 | 0,5899 | 0,5899 | 0,1325 |
| 3            | 0,9402          | 0,5711 | 0,5711 | 0,1127 | 0,8659 | 0,5798 | 15,830 | 0,1380 |
| 4            | 0,9293          | 0,5927 | 0,5927 | 0,1184 | 0,8894 | 0,6118 | 2,9295 | 0,1487 |
| 5            | 0,9365          | 0,5774 | 0,5774 | 0,1200 | 0,9166 | 0,6160 | 0,6160 | 0,1303 |
| Διάμεση τιμή | 0,9365          | 0,5774 | 0,5774 | 0,1211 | 0,9130 | 0,6115 | 0,6160 | 0,1325 |
| Βελτίωση (%) | 2,57            | 5,58   | 5,58   | 8,6    | 0,00   | 0,00   | 0,00   | 0,00   |

**Πίνακας 5.4** Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 1, για το φθινόπωρο του 2012, για διάστημα εμπιστοσύνης 90%.

| Επανάληψη    | WT-LUBE-PSO-CWC |        |        |        | BELM   |        |        |        |
|--------------|-----------------|--------|--------|--------|--------|--------|--------|--------|
|              | PICP            | PINAW  | CWC    | CRPS   | PICP   | PINAW  | CWC    | CRPS   |
| 1            | 0,9267          | 0,5029 | 0,5029 | 0,1129 | 0,8864 | 0,5025 | 3,4597 | 0,1257 |
| 2            | 0,9249          | 0,5214 | 0,5214 | 0,1097 | 0,9029 | 0,5076 | 0,5076 | 0,1348 |
| 3            | 0,9304          | 0,5349 | 0,5349 | 0,1115 | 0,9047 | 0,5236 | 0,5236 | 0,1114 |
| 4            | 0,9249          | 0,5247 | 0,5247 | 0,1124 | 0,8992 | 0,5291 | 1,5895 | 0,1309 |
| 5            | 0,9468          | 0,5141 | 0,5141 | 0,1189 | 0,9047 | 0,5360 | 0,5360 | 0,1228 |
| Διάμεση τιμή | 0,9267          | 0,5214 | 0,5214 | 0,1124 | 0,9029 | 0,5236 | 0,5360 | 0,1257 |
| Βελτίωση (%) | 2,64            | 0,42   | 0,42   | 10,58  | 0,00   | 0,00   | 0,00   | 0,00   |

**Πίνακας 5.5** Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 1, για τον χειμώνα του 2012/2013, για διάστημα εμπιστοσύνης 90%.

| Επανάληψη    | WT-LUBE-PSO-CWC |        |        |        | BELM   |        |        |        |
|--------------|-----------------|--------|--------|--------|--------|--------|--------|--------|
|              | PICP            | PINAW  | CWC    | CRPS   | PICP   | PINAW  | CWC    | CRPS   |
| 1            | 0,9370          | 0,5814 | 0,5814 | 0,1092 | 0,9148 | 0,5501 | 0,5501 | 0,1050 |
| 2            | 0,9370          | 0,5481 | 0,5481 | 0,1144 | 0,9259 | 0,5525 | 0,5525 | 0,1288 |
| 3            | 0,9444          | 0,5440 | 0,5440 | 0,1086 | 0,9092 | 0,5352 | 0,5352 | 0,1060 |
| 4            | 0,9240          | 0,5607 | 0,5607 | 0,1092 | 0,9222 | 0,5552 | 0,5552 | 0,0977 |
| 5            | 0,9277          | 0,5363 | 0,5363 | 0,1087 | 0,8925 | 0,5517 | 2,3604 | 0,1101 |
| Διάμεση τιμή | 0,9370          | 0,5481 | 0,5481 | 0,1092 | 0,9148 | 0,5517 | 0,5525 | 0,1060 |
| Βελτίωση (%) | 2,43            | 0,65   | 0,65   | -3,02  | 0,00   | 0,00   | 0,00   | 0,00   |

**Πίνακας 5.6** Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 1, για την άνοιξη του 2013, για διάστημα εμπιστοσύνης 90%.

| Επανάληψη    | WT-LUBE-PSO-CWC |        |        |        | BELM   |        |        |        |
|--------------|-----------------|--------|--------|--------|--------|--------|--------|--------|
|              | PICP            | PINAW  | CWC    | CRPS   | PICP   | PINAW  | CWC    | CRPS   |
| 1            | 0,9384          | 0,5051 | 0,5051 | 0,0998 | 0,8876 | 0,4606 | 3,1398 | 0,1131 |
| 2            | 0,9130          | 0,5081 | 0,5081 | 0,1050 | 0,8967 | 0,4931 | 1,7911 | 0,1060 |
| 3            | 0,9021          | 0,4937 | 0,4937 | 0,1022 | 0,9021 | 0,4904 | 0,4904 | 0,1105 |
| 4            | 0,9311          | 0,4787 | 0,4787 | 0,1063 | 0,9148 | 0,4916 | 0,4916 | 0,1096 |
| 5            | 0,9329          | 0,4845 | 0,4845 | 0,1090 | 0,9021 | 0,4836 | 0,4836 | 0,1079 |
| Διάμεση τιμή | 0,9311          | 0,4937 | 0,4937 | 0,1050 | 0,9021 | 0,4904 | 0,4916 | 0,1096 |
| Βελτίωση (%) | 3,12            | -0,67  | -0,67  | 4,20   | 0,00   | 0,00   | 0,00   | 0,00   |

**Πίνακας 5.7** Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 7, για το καλοκαίρι του 2012, για διάστημα εμπιστοσύνης 90%.

| Επανάληψη    | WT-LUBE-PSO-CWC |        |        |        | BELM   |        |        |        |
|--------------|-----------------|--------|--------|--------|--------|--------|--------|--------|
|              | PICP            | PINAW  | CWC    | CRPS   | PICP   | PINAW  | CWC    | CRPS   |
| 1            | 0,9057          | 0,4208 | 0,4208 | 0,0799 | 0,9275 | 0,5207 | 0,5207 | 0,1108 |
| 2            | 0,9365          | 0,4544 | 0,4544 | 0,0890 | 0,9076 | 0,5125 | 0,5125 | 0,1008 |
| 3            | 0,9547          | 0,4989 | 0,4989 | 0,0781 | 0,9021 | 0,4950 | 0,4950 | 0,1042 |
| 4            | 0,9184          | 0,4576 | 0,4576 | 0,0814 | 0,9003 | 0,5029 | 0,5029 | 0,0964 |
| 5            | 0,9021          | 0,4378 | 0,4378 | 0,0861 | 0,8894 | 0,5112 | 2,8289 | 0,1133 |
| Διάμεση τιμή | 0,9184          | 0,4544 | 0,4544 | 0,0814 | 0,9021 | 0,5112 | 0,5125 | 0,1042 |
| Βελτίωση (%) | 1,81            | 11,11  | 11,11  | 21,88  | 0,00   | 0,00   | 0,00   | 0,00   |

**Πίνακας 5.8** Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 7, για το φθινόπωρο του 2012, για διάστημα εμπιστοσύνης 90%.

| Επανάληψη    | WT-LUBE-PSO-CWC |        |        |        | BELM   |        |        |        |
|--------------|-----------------|--------|--------|--------|--------|--------|--------|--------|
|              | PICP            | PINAW  | CWC    | CRPS   | PICP   | PINAW  | CWC    | CRPS   |
| 1            | 0,9230          | 0,4216 | 0,4216 | 0,0853 | 0,8992 | 0,4264 | 1,4868 | 0,0815 |
| 2            | 0,9450          | 0,4253 | 0,4253 | 0,0790 | 0,8919 | 0,4141 | 2,3195 | 0,0958 |
| 3            | 0,9450          | 0,4395 | 0,4395 | 0,0756 | 0,9029 | 0,3999 | 0,3999 | 0,0897 |
| 4            | 0,9285          | 0,4414 | 0,4414 | 0,0813 | 0,9047 | 0,4195 | 0,4195 | 0,0992 |
| 5            | 0,9304          | 0,4135 | 0,4135 | 0,0876 | 0,9175 | 0,4313 | 0,4313 | 0,0864 |
| Διάμεση τιμή | 0,9304          | 0,4253 | 0,4253 | 0,0813 | 0,9029 | 0,4195 | 0,4313 | 0,0897 |
| Βελτίωση (%) | 3,05            | -1,38  | -1,38  | 9,37   | 0,00   | 0,00   | 0,00   | 0,00   |

**Πίνακας 5.9** Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 7, για τον χειμώνα του 2012/2013, για διάστημα εμπιστοσύνης 90%.

| Επανάληψη    | WT-LUBE-PSO-CWC |        |        |        | BELM   |        |        |        |
|--------------|-----------------|--------|--------|--------|--------|--------|--------|--------|
|              | PICP            | PINAW  | CWC    | CRPS   | PICP   | PINAW  | CWC    | CRPS   |
| 1            | 0,9259          | 0,4269 | 0,4269 | 0,0794 | 0,8944 | 0,4561 | 2,0157 | 0,0798 |
| 2            | 0,9259          | 0,4263 | 0,4263 | 0,0785 | 0,9333 | 0,4851 | 0,4851 | 0,0824 |
| 3            | 0,9370          | 0,4250 | 0,4250 | 0,0719 | 0,8907 | 0,4780 | 2,5755 | 0,0852 |
| 4            | 0,9203          | 0,4218 | 0,4218 | 0,0729 | 0,9166 | 0,4978 | 0,4978 | 0,0942 |
| 5            | 0,9481          | 0,4471 | 0,4471 | 0,0750 | 0,9055 | 0,4630 | 0,4630 | 0,0896 |
| Διάμεση τιμή | 0,9259          | 0,4263 | 0,4263 | 0,0750 | 0,9055 | 0,4780 | 0,4978 | 0,0852 |
| Βελτίωση (%) | 2,26            | 10,82  | 10,82  | 11,97  | 0,00   | 0,00   | 0,00   | 0,00   |

**Πίνακας 5.10** Αποτελέσματα αξιολόγησης 5 επαναλήψεων εκπαίδευσης για τη Ζώνη 7, για την άνοιξη του 2013, για διάστημα εμπιστοσύνης 90%.

| Επανάληψη    | WT-LUBE-PSO-CWC |        |        |        | BELM   |        |        |        |
|--------------|-----------------|--------|--------|--------|--------|--------|--------|--------|
|              | PICP            | PINAW  | CWC    | CRPS   | PICP   | PINAW  | CWC    | CRPS   |
| 1            | 0,9057          | 0,4889 | 0,4889 | 0,0898 | 0,9239 | 0,4688 | 0,4688 | 0,0955 |
| 2            | 0,9221          | 0,4414 | 0,4414 | 0,0876 | 0,9166 | 0,4550 | 0,4550 | 0,1013 |
| 3            | 0,9474          | 0,4747 | 0,4747 | 0,1036 | 0,9202 | 0,4654 | 0,4654 | 0,0972 |
| 4            | 0,9547          | 0,4495 | 0,4495 | 0,0863 | 0,9257 | 0,4648 | 0,4648 | 0,0948 |
| 5            | 0,9275          | 0,4367 | 0,4367 | 0,0915 | 0,9257 | 0,4686 | 0,4686 | 0,0922 |
| Διάμεση τιμή | 0,9275          | 0,4495 | 0,4495 | 0,0898 | 0,9239 | 0,4654 | 0,4654 | 0,0955 |
| Βελτίωση (%) | 0,39            | 3,42   | 3,42   | 5,97   | 0,00   | 0,00   | 0,00   | 0,00   |

Οι Πίνακες 5.3 έως 5.10 δείχνουν ότι το προτεινόμενο WT-LUBE-PSO-CWC υπερτερεί του BELM τόσο στις τιμές του PICP όσο και στις τιμές του CWC. Συγκεκριμένα, το WT-LUBE-PSO-CWC επιτυγχάνει υψηλότερη διάμεση τιμή PICP σε όλες τις περιπτώσεις και χαμηλότερη διάμεση τιμή CWC σε επτά από τις οκτώ περιπτώσεις. Το BELM επιτυγχάνει μια ελαφρώς καλύτερη διάμεση τιμή CWC μόνο για το σύνολο δεδομένων της Ζώνης 1 την άνοιξη του 2013. Αυτό σημαίνει ότι τα παραγόμενα διαστήματα εμπιστοσύνης από το WT-LUBE-PSO-CWC έχουν μεγαλύτερο ποσοστό κάλυψης, παρόλο που έχουν μικρότερο εύρος κατά μέσο όρο. Το προτεινόμενο μοντέλο έχει επίσης μια πιο σταθερή απόκριση, δεδομένου ότι σε κάθε εκτέλεση κάθε περίπτωσης, το PICP είναι ίσο ή υψηλότερο από το ονομαστικό επίπεδο εμπιστοσύνης. Από την άλλη, η πιθανότητα κάλυψης των διαστημάτων εμπιστοσύνης που παράγονται από το BELM δεν μπορεί να φτάσει το ονομαστικό επίπεδο εμπιστοσύνης σε αρκετές δοκιμές, με αποτέλεσμα μια πολύ υψηλότερη τιμή CWC. Επιπλέον, όσον αφορά τη μέτρηση σφάλματος CRPS, το προτεινόμενο μοντέλο υπερέβη σημαντικά το μοντέλο BELM σε επτά από τις οκτώ περιπτώσεις.

Προκειμένου να αποδειχθεί περαιτέρω η ανωτερότητα του προτεινόμενου μοντέλου, τα συγκριτικά αποτελέσματα μεταξύ του προτεινόμενου μοντέλου WT-LUBE-PSO-CWC και του BELM παρουσιάζονται στους Πίνακες 5.11 - 5.12 και 5.13 - 5.14 για επίπεδο εμπιστοσύνης 85% και 95%, αντίστοιχα. Διαπιστώνεται ότι σε 14 από τις 16 περιπτώσεις, το προτεινόμενο μοντέλο WT-LUBE-PSO-CWC επιτυγχάνει υψηλότερη διάμεση τιμή PICP, ενώ μόνο σε 2 από τις 16 περιπτώσεις το BELM έχει ελαφρώς καλύτερη διάμεση τιμή PICP. Οι διάμεσες τιμές PICP του προτεινόμενου μοντέλου παραμένουν ίσες ή υψηλότερες από το ονομαστικό επίπεδο εμπιστοσύνης σε όλες τις περιπτώσεις. Όσον αφορά τις διάμεσες τιμές CWC, το προτεινόμενο μοντέλο υπερτερεί του μοντέλου BELM σε όλες τις περιπτώσεις. Όσον αφορά το CRPS, το προτεινόμενο μοντέλο ξεπέρασε το μοντέλο BELM σε 13 από τις 16 περιπτώσεις. Πιο συγκεκριμένα, για το σύνολο δεδομένων της Ζώνης 1, το προτεινόμενο μοντέλο ξεπέρασε το μοντέλο BELM τόσο για το επίπεδο εμπιστοσύνης 85% όσο και για το επίπεδο εμπιστοσύνης 95%. Για το σύνολο δεδομένων της Ζώνης 7, το μοντέλο BELM έδωσε ελαφρώς καλύτερα αποτελέσματα για το φθινόπωρο και για τα δύο επίπεδα εμπιστοσύνης, γεγονός που είναι πιθανώς αποτέλεσμα της ποιότητας των δεδομένων σε σύγκριση με το σύνολο δεδομένων της Ζώνης 1.

**Πίνακας 5.11** Αποτελέσματα αξιολόγησης για τις Ζώνες 1 και 7, για το καλοκαίρι και το φθινόπωρο του 2012, για διάστημα εμπιστοσύνης 85%.

| Ζώνη | Μοντέλο                           | Καλοκαίρι |        |        | Φθινόπωρο |        |        |
|------|-----------------------------------|-----------|--------|--------|-----------|--------|--------|
|      |                                   | PICP      | CWC    | CRPS   | PICP      | CWC    | CRPS   |
| 1    | WT-LUBE-PSO-CWC<br>(προτεινόμενο) | 0,8759    | 0,5475 | 0,1120 | 0,8654    | 0,4589 | 0,1061 |
|      | BELM                              | 0,8586    | 0,5747 | 0,1398 | 0,8571    | 0,5943 | 0,1110 |
|      | Βελτίωση προτεινόμενου (%)        | 2,01      | 4,73   | 19,90  | 0,97      | 22,78  | 4,41   |
| 7    | WT-LUBE-PSO-CWC<br>(προτεινόμενο) | 0,8949    | 0,4278 | 0,0789 | 0,8973    | 0,4029 | 0,0806 |
|      | BELM                              | 0,8586    | 0,5143 | 0,1070 | 0,8699    | 0,5430 | 0,0765 |
|      | Βελτίωση προτεινόμενου (%)        | 4,23      | 16,82  | 26,26  | 3,15      | 25,80  | -5,36  |

**Πίνακας 5.12** Αποτελέσματα αξιολόγησης για τις Ζώνες 1 και 7, για το χειμώνα του 2012/2013 έως την άνοιξη του 2013, για διάστημα εμπιστοσύνης 85%.


| Ζώνη | Μοντέλο                           | Χειμώνας |        |        | Άνοιξη |        |        |
|------|-----------------------------------|----------|--------|--------|--------|--------|--------|
|      |                                   | PICP     | CWC    | CRPS   | PICP   | CWC    | CRPS   |
| 1    | WT-LUBE-PSO-CWC<br>(προτεινόμενο) | 0,8703   | 0,4987 | 0,1156 | 0,8792 | 0,4793 | 0,0966 |
|      | BELM                              | 0,8962   | 0,6410 | 0,1206 | 0,8659 | 0,5397 | 0,1096 |
|      | Βελτίωση προτεινόμενου (%)        | -2,90    | 22,2   | 4,15   | 1,54   | 11,20  | 11,86  |
| 7    | WT-LUBE-PSO-CWC<br>(προτεινόμενο) | 0,8746   | 0,3990 | 0,0734 | 0,8649 | 0,4273 | 0,0851 |
|      | BELM                              | 0,8944   | 0,6432 | 0,0892 | 0,8804 | 0,5669 | 0,0867 |
|      | Βελτίωση προτεινόμενου (%)        | -2,21    | 37,97  | 17,71  | -1,76  | 24,63  | 1,85   |

**Πίνακας 5.13** Αποτελέσματα αξιολόγησης για τις Ζώνες 1 και 7, για το καλοκαίρι και το φθινόπωρο του 2012, για διάστημα εμπιστοσύνης 95%.


| Ζώνη | Μοντέλο                           | Καλοκαίρι |        |        | Φθινόπωρο |        |        |
|------|-----------------------------------|-----------|--------|--------|-----------|--------|--------|
|      |                                   | PICP      | CWC    | CRPS   | PICP      | CWC    | CRPS   |
| 1    | WT-LUBE-PSO-CWC<br>(προτεινόμενο) | 0,9782    | 0,6986 | 0,1296 | 0,9780    | 0,6546 | 0,1196 |
|      | BELM                              | 0,9655    | 0,7730 | 0,1364 | 0,9523    | 0,7562 | 0,1207 |
|      | Βελτίωση προτεινόμενου (%)        | 1,32      | 9,62   | 5,00   | 2,70      | 13,44  | 0,91   |
| 7    | WT-LUBE-PSO-CWC<br>(προτεινόμενο) | 0,9800    | 0,5942 | 0,0946 | 0,9871    | 0,5563 | 0,0937 |
|      | BELM                              | 0,9673    | 0,7747 | 0,0996 | 0,9523    | 0,7583 | 0,0864 |
|      | Βελτίωση προτεινόμενου (%)        | 1,31      | 23,30  | 5,02   | 3,65      | 26,64  | 8,45   |

**Πίνακας 5.14** Αποτελέσματα αξιολόγησης για τις Ζώνες 1 και 7, για το χειμώνα του 2012/2013 έως την άνοιξη του 2013, για διάστημα εμπιστοσύνης 95%.

| Ζώνη | Μοντέλο                           | Χειμώνας |        |        | Άνοιξη |        |        |
|------|-----------------------------------|----------|--------|--------|--------|--------|--------|
|      |                                   | PICP     | CWC    | CRPS   | PICP   | CWC    | CRPS   |
| 1    | WT-LUBE-PSO-CWC<br>(προτεινόμενο) | 0,9759   | 0,6840 | 0,0995 | 0,9800 | 0,6174 | 0,0974 |
|      | BELM                              | 0,9537   | 0,7781 | 0,1129 | 0,9619 | 0,7032 | 0,1194 |
|      | Βελτίωση προτεινόμενου (%)        | 2,33     | 12,09  | 11,87  | 1,88   | 12,20  | 18,43  |
| 7    | WT-LUBE-PSO-CWC<br>(προτεινόμενο) | 0,9740   | 0,5301 | 0,0839 | 0,9764 | 0,5867 | 0,1041 |
|      | BELM                              | 0,9555   | 0,7805 | 0,0942 | 0,9601 | 0,7049 | 0,0802 |
|      | Βελτίωση προτεινόμενου (%)        | 1,94     | 32,08  | 10,94  | 1,70   | 16,77  | -29,80 |



**Σχήμα 5.6** Διαστήματα πρόβλεψης κατασκευασμένα από το προτεινόμενο μοντέλο WT-LUBE-PSO-CWC, για το φθινοπωρινό σύνολο δεδομένων 2012 για τη Ζώνη 7.



**Σχήμα 5.7** Διαστήματα πρόβλεψης κατασκευασμένα από το προτεινόμενο μοντέλο BELM, για το φθινοπωρινό σύνολο δεδομένων 2012 για τη Ζώνη 7.

Στα Σχήματα 5.6 και 5.7 παρουσιάζονται τα διαστήματα πρόβλεψης που παράγονται από τις μεθόδους WT-LUBE-PSO-CWC και BELM, αντίστοιχα, για το σύνολο δεδομένων της ζώνης 7 για το φθινόπωρο του 2012. Σε κάθε σχήμα, το άνω διάγραμμα δείχνει τα διαστήματα εμπιστοσύνης για τις πρώτες 48 προβλέψεις του συνόλου δοκιμών (πρώτες δύο ημέρες) και το κάτω διάγραμμα δείχνει τα προβλεπόμενα διαστήματα εμπιστοσύνης για ολόκληρο το σύνολο δοκιμών (546 δείγματα, δηλαδή 23 ημέρες). Οι κόκκινες κηλίδες στα Σχήματα 5.6 και 5.7 αναφέρονται στις σημειακές προβλέψεις σε κάθε περίπτωση, ενώ οι μπλε γραμμές στα

παραπάνω διαγράμματα δείχνουν το πλάτος των PI. Η ποιότητα των διαστημάτων εμπιστοσύνης που παράγονται από WT-LUBE-PSO-CWC είναι γενικά υψηλότερη από την ποιότητα των διαστημάτων εμπιστοσύνης που παράγονται από το BELM.

Στον Πίνακα 5.15, γίνεται μια συνολική σύγκριση μεταξύ του BELM και του προτεινόμενου μοντέλου WT-LUBE-PSO-CWC για κάθε περίπτωση κάθε ζώνης όσον αφορά το επίπεδο εμπιστοσύνης 90%. Οι μέσες τιμές των CWC, PICP και ο χρόνος εκτέλεσης του μοντέλου λαμβάνονται από τις αντίστοιχες διάμεσες τιμές των οκτώ περιπτώσεων που παρουσιάζονται στους Πίνακες 5.3-5.10. Η μέση τιμή του CWC του προτεινόμενου μοντέλου WT-LUBE-PSO-CWC είναι 0.4870, η οποία είναι 5,05% καλύτερη (μικρότερη) από τη μέση τιμή CWC του BELM. Ο μέσος όρος PICP του WT-LUBE-PSO-CWC είναι 0.9292, δηλαδή 2,29% καλύτερος (μεγαλύτερος) από τον μέσο όρο PICP του BELM. Το συμπέρασμα είναι ότι τόσο το ποσοστό κάλυψης (CWC) όσο και το μέσο εύρος διαστημάτων πρόβλεψης (PICP) βελτιώνονται με το προτεινόμενο μοντέλο WT-LUBE-PSO-CWC. Όπως ήταν αναμενόμενο, ωστόσο, το BELM είναι ταχύτερο, καθώς ο πυρήνας του αποτελείται από ακραίες μηχανές μάθησης. Παρόλα αυτά, οι χρόνοι τρεξίματος του προτεινόμενου μοντέλου επιτρέπουν τη χρήση του σε προβλήματα πιθανοτικής πρόβλεψης αιολικής παραγωγής στην πραγματική ζωή.

**Πίνακας 5.15** Συνολική σύγκριση μοντέλων WT-LUBE-PSO-CWC και BELM για κάθε περίπτωση κάθε ζώνης.

| Συγκρίσεις                        | WT-LUBE-PSO-CWC | BELM   | Διαφορά (%) |
|-----------------------------------|-----------------|--------|-------------|
| Μέσο CWC                          | 0,4870          | 0,5129 | -5,05       |
| Μέσο PICP                         | 0,9292          | 0,9084 | 2,29        |
| Μέσο CRPS                         | 0,0968          | 0,1060 | -9,53       |
| Μέσος χρόνος εκτέλεσης (s)        | 126             | 27     | 366,67      |
| Περιπτώσεις με καλύτερη τιμή CWC  | 7               | 1      | 600,00      |
| Περιπτώσεις με καλύτερη τιμή PICP | 8               | 0      | $\infty$    |
| Περιπτώσεις με καλύτερη τιμή CRPS | 7               | 1      | 600,00      |

**Πίνακας 5.16** Αποτελέσματα αξιολόγησης μοντέλων WT-LUBE-PSO-CWC, LUBE-PSO-CWC και BELM, για ετήσια σύνολα δεδομένων, για τις Ζώνες 1 και 7.

| Ζώνη | Διάμεση τιμή | WT-LUBE-PSO-CWC | LUBE-PSO-CWC | BELM   | Συνδυασμένο WT-LUBE-PSO-CWC/BELM |
|------|--------------|-----------------|--------------|--------|----------------------------------|
| 1    | PICP         | 0,9369          | 0,9356       | 0,9105 | 0,9360                           |
|      | CWC          | 0,5447          | 0,5496       | 0,5545 | 0,5497                           |
|      | CRPS         | 0,1020          | 0,1029       | 0,1075 | 0,1055                           |
| 7    | PICP         | 0,9338          | 0,9260       | 0,9063 | 0,9143                           |
|      | CWC          | 0,4432          | 0,4552       | 0,4774 | 0,4689                           |
|      | CRPS         | 0,0736          | 0,0776       | 0,0824 | 0,0963                           |

Προκειμένου να επιτευχθεί μια πιο αξιόπιστη αξιολόγηση της απόδοσης των WT-LUBE-PSO-CWC και BELM, τα δύο μοντέλα εκπαιδεύονται και αξιολογούνται ξανά, αυτή τη φορά με σύνολα δεδομένων διάρκειας ενός έτους, που περιέχουν πληροφορίες από την 1η Ιουνίου 2012 έως τις 31 Μαΐου 2013 και για τις δύο Ζώνες 1 και 7. Έτσι, το σύνολο δεδομένων κάθε ζώνης αποτελείται από 8760 ωριαία σύνολα δεδομένων. Και πάλι, τα σύνολα εκπαίδευσης αποτελούνται από το 75% των αρχικών συνόλων δεδομένων και το υπόλοιπο 25% αντιστοιχεί στα σύνολα δοκιμών. Τα αποτελέσματα παρουσιάζονται στον Πίνακα 5.16. Οι διάμεσες τιμές των PICP, CWC και CRPS για κάθε ζώνη λαμβάνονται μετά από πέντε εφαρμογές της διαδικασίας εκπαίδευσης και αξιολόγησης. Προκειμένου να αποδειχθεί η επίδραση του μετασχηματισμού κυματιδίων, τα αποτελέσματα λαμβάνονται επίσης για το LUBE-PSO-CWC χωρίς τον μετασχηματισμό κυματιδίων. Επομένως, τα δεδομένα εισόδου της LUBE-PSO-CWC χωρίς κυματίδια αποτελούνται μόνο από τα αρχικά δεδομένα εισόδου της GEFCOM 2014. Και πάλι, το WT-LUBE-PSO-CWC ξεπερνά το BELM τόσο στο ποσοστό κάλυψης όσο και στο μέσο εύρος διαστημάτων εμπιστοσύνης, και στις δύο ζώνες. Επιπλέον, μπορεί να φανεί από τον Πίνακα 5.16 ότι η εφαρμογή του μετασχηματισμού κυματιδίων βελτιώνει τα τελικά αποτελέσματα του LUBE-PSO-CWC, τόσο στις τιμές του PICP όσο και στις τιμές του CWC.


Στον Πίνακα 5.16 παρουσιάζονται επίσης τα αποτελέσματα των συνδυασμένων μεθόδων BELM και WT-LUBE-PSO-CWC. Τα συνδυασμένα διαστήματα εμπιστοσύνης μπορούν να βελτιώσουν τις προβλέψεις τόσο ως προς την ακρίβεια όσο και ως προς τη βαθμονόμηση [160]. Η συσχέτιση μεταξύ των δύο μοντέλων είναι μικρή. Δεδομένου ότι υπάρχουν μόνο δύο μεθοδολογίες σύγκρισης, επιλέγεται η μέθοδος μέσης τιμής για τον συνδυασμό τους. Τα συνδυασμένα διαστήματα εμπιστοσύνης δεν φαίνεται να βελτιώνουν τη συνολική απόδοση των προβλέψεων. Αν και τα αποτελέσματα της συνδυασμένης μεθόδου είναι καλύτερα από αυτά του BELM, η μέθοδος WT-LUBE-PSO-CWC εξακολουθεί να έχει την καλύτερη απόδοση. Ωστόσο, εάν συνδυαστούν περισσότερες μέθοδοι και χρησιμοποιηθεί μια πιο σύνθετη μέθοδος συνδυασμού, τα αποτελέσματα θα μπορούσαν πιθανώς να βελτιωθούν.

Προκειμένου να παρουσιαστεί η ακρίβεια των αποτελεσμάτων από εποχιακή άποψη, το Σχήμα 5.8 δείχνει τη μέση τιμή των διάμεσων CWC μεταξύ του προτεινόμενου μοντέλου WT-LUBE-PSO-CWC και του BELM για κάθε εποχή στις Ζώνες 1 και 7. Και για τις δύο ζώνες, η χειρότερη απόδοση επιτυγχάνεται το καλοκαίρι. Οι μέσες τιμές ανά εποχή των τιμών που παρουσιάζονται στο Σχήμα 5.8 παρουσιάζονται στον Πίνακα 5.17. Και πάλι, ο υψηλότερος μέσος όρος CWC παρατηρείται το καλοκαίρι. Αυτό είναι αναμενόμενο, δεδομένου ότι το καλοκαίρι η μέση ταχύτητα του ανέμου είναι συνήθως χαμηλότερη από ό, τι κατά τη διάρκεια του υπόλοιπου έτους, με αποτέλεσμα μεγαλύτερη διακύμανση στην παραγωγή αιολικής ενέργειας, ή καθόλου παραγωγή ισχύος, για μεγαλύτερες χρονικές περιόδους. Από την άλλη, τα καλύτερα αποτελέσματα επιτυγχάνονται την άνοιξη και το φθινόπωρο. Κατά συνέπεια, το καλοκαίρι θα πρέπει να αναμένεται μεγαλύτερο ποσοστό σφάλματος όσον αφορά τις προβλέψεις αιολικής ενέργειας, ενώ τα μικρότερα ποσοστά σφάλματος θα πρέπει να αναμένονται την άνοιξη και το φθινόπωρο.

Ο Πίνακας 5.17 παρουσιάζει την τυπική απόκλιση των τιμών του CWC που φαίνεται στο Σχήμα 5.8. Η μεγαλύτερη τυπική απόκλιση του CWC παρατηρείται το καλοκαίρι, ενώ η χαμηλότερη τυπική απόκλιση της CWC επιτυγχάνεται την άνοιξη. Αυτό σημαίνει ότι όταν χρησιμοποιούνται δεδομένα άνοιξης, τα WT-LUBE-PSO-CWC και BELM έχουν πιο σταθερή

**Πίνακας 5.17** Μέση τιμή και τυπική απόκλιση του CWC για κάθε εποχή και για τα δυο μοντέλα, WT-LUBE-PSO-CWC και BELM και για τις 2 Ζώνες έρευνας.

| Παράμετρος          | Καλοκαίρι | Φθινόπωρο | Χειμώνας | Άνοιξη |
|---------------------|-----------|-----------|----------|--------|
| Μέση τιμή CWC       | 0.5401    | 0.4785    | 0.5062   | 0.4751 |
| Τυπική απόκλιση CWC | 0.0713    | 0.0583    | 0.0587   | 0.0213 |



**Σχήμα 5.8** Μέση τιμή της διάμεσης τιμής CWC μεταξύ WT-LUBE-PSO-CWC και BELM για κάθε εποχή στις ζώνες 1 και 7.

απόκριση, ανεξάρτητα από τη γεωγραφική θέση του αιολικού πάρκου. Από την άλλη, όταν χρησιμοποιούνται θερινά δεδομένα, τα μοντέλα έχουν πιο ασταθή απόκριση, πράγμα που σημαίνει ότι η ποιότητα των αποτελεσμάτων εξαρτάται πολύ περισσότερο από τη γεωγραφική θέση του αιολικού πάρκου.

Μπορεί επίσης να παρατηρηθεί από το Σχήμα 5.8 ότι υπάρχει μια μικρή διαφορά στη διάμεση CWC μεταξύ άνοιξης και φθινοπώρου στη Ζώνη 1 και στη Ζώνη 7. Λαμβάνοντας υπόψη ότι κάθε ζώνη δεδομένων αφορά αιολικά πάρκα σε διαφορετικές τοποθεσίες, η διαφορά στη διάμεση τιμή CWC θα μπορούσε να είναι αποτέλεσμα της διαφορετικής ποιότητας των δεδομένων κατά τη διάρκεια αυτών των συγκεκριμένων εποχών. Ως αποτέλεσμα, για τη Ζώνη 1 τα δεδομένα της άνοιξης είναι καλύτερης ποιότητας από τα δεδομένα του φθινοπώρου, ενώ για τη Ζώνη 7 τα δεδομένα του φθινοπώρου παρέχουν καλύτερα αποτελέσματα. Επιπλέον, τα τεχνικά χαρακτηριστικά των αιολικών πάρκων που βρίσκονται σε κάθε ζώνη θα μπορούσαν να διαδραματίζουν σημαντικό ρόλο στην παρατηρούμενη διαφορά στη μέση διάμεση τιμή CWC μεταξύ άνοιξης και φθινοπώρου στη Ζώνη 1 και στη Ζώνη 7.

Οι Πίνακες 5.18 και 5.19 παρουσιάζουν τον μέσο αριθμό παρατηρήσεων κάτω από το κατώτατο όριο και πάνω από το ανώτατο όριο των διαστημάτων πρόβλεψης. Για τη μέθοδο BELM, ο μέσος αριθμός παρατηρήσεων πάνω από το ανώτατο όριο πρόβλεψης είναι σημαντικά υψηλότερος από τις παρατηρήσεις κάτω από το κατώτερο όριο πρόβλεψης, για σχεδόν κάθε περίπτωση δοκιμής. Αυτό είναι ακόμη πιο εμφανές για τη μέθοδο WT-LUBE-

**Πίνακας 5.18** Μέσος αριθμός παρατηρήσεων χαμηλότερα από το κάτω όριο και υψηλότερα από το άνω όριο των διαστημάτων πρόβλεψης, για το καλοκαίρι και το φθινόπωρο του 2012 και για τις 2 Ζώνες έρευνας, για διάστημα εμπιστοσύνης 90%.

| Ζώνη | Μοντέλο         | Καλοκαίρι |          | Φθινόπωρο |          |
|------|-----------------|-----------|----------|-----------|----------|
|      |                 | Μέσο Κάτω | Μέσο Άνω | Μέσο Κάτω | Μέσο Άνω |
| 1    | WT-LUBE-PSO-CWC | 17        | 18       | 7,8       | 27,8     |
|      | BELM            | 27        | 23,6     | 21        | 20,2     |
| 7    | WT-LUBE-PSO-CWC | 19,6      | 13,4     | 16        | 18,6     |
|      | BELM            | 26,8      | 24,4     | 14,4      | 19       |

**Πίνακας 5.19** Μέσος αριθμός παρατηρήσεων χαμηλότερα από το κάτω όριο και υψηλότερα από το άνω όριο των διαστημάτων πρόβλεψης, για το χειμώνα του 2012/2013 έως την άνοιξη του 2013 και για τις 2 Ζώνες έρευνας, για διάστημα εμπιστοσύνης 90%.

| Ζώνη | Μοντέλο         | Χειμώνας  |          | Άνοιξη    |          |
|------|-----------------|-----------|----------|-----------|----------|
|      |                 | Μέσο Κάτω | Μέσο Άνω | Μέσο Κάτω | Μέσο Άνω |
| 1    | WT-LUBE-PSO-CWC | 0,8       | 35,2     | 6,8       | 31,8     |
|      | BELM            | 15,4      | 28,6     | 18,8      | 23,4     |
| 7    | WT-LUBE-PSO-CWC | 8,4       | 22,8     | 10,6      | 29,6     |
|      | BELM            | 26        | 34       | 19,4      | 22,4     |

PSO-CWC. Αυτό πιθανώς σχετίζεται με το γεγονός ότι περισσότερες τιμές-στόχοι των συνόλων δεδομένων βρίσκονται κοντά στο 0 αντί για 1, δεδομένου ότι η παραγωγή ενός αιολικού πάρκου σπάνια πλησιάζει το ονομαστικό του επίπεδο. Το γεγονός ότι για τη μέθοδο WT-LUBE-PSO-CWC οι παρατηρήσεις κάτω από το κατώτερο όριο πρόβλεψης είναι λιγότερες σε σύγκριση με εκείνες για τη μέθοδο BELM αποδεικνύει ότι η μέθοδος WT-LUBE-PSO-CWC είναι ακριβέστερη. Οι μόνες περιπτώσεις δοκιμής όπου ο μέσος αριθμός παρατηρήσεων κάτω από το κατώτερο όριο πρόβλεψης είναι υψηλότερος από τον μέσο αριθμό παρατηρήσεων πάνω από το ανώτατο όριο πρόβλεψης είναι εκείνες που σχετίζονται με τα θερινά σύνολα δεδομένων.

Συμπεραίνεται ότι το προτεινόμενο μοντέλο WT-LUBE-PSO-CWC με τον προτεινόμενο Γκαουσιανό τελεστή μετάλλαξης που εφαρμόστηκε στον αλγόριθμο βελτιστοποίησης PSO συνολικά επιτυγχάνει καλύτερα αποτελέσματα από την υπερσύγχρονη μεθοδολογία BELM. Τα διαστήματα πρόβλεψής του έχουν, κατά μέσο όρο, μεγαλύτερο ποσοστό κάλυψης, διατηρώντας παράλληλα μικρότερο μέσο εύρος. Αυτά τα αποτελέσματα παρατηρούνται τόσο για εποχιακά σύνολα δεδομένων όσο και για σύνολα δεδομένων διάρκειας ενός έτους, τόσο για τη Ζώνη 1 όσο και για τη Ζώνη 7. Επιπλέον, το WT-LUBE-PSO-CWC έχει πολύ πιο σταθερή απόκριση από το BELM, καθώς το ποσοστό κάλυψής του είναι ίσο ή υψηλότερο από το ονομαστικό επίπεδο εμπιστοσύνης σε όλες τις περιπτώσεις. Η αρχικοποίηση των βαρών και των πολώσεων του LUBE-PSO-CWC με την τεχνική Yam-Chow οδηγεί σε υψηλότερο ρυθμό σύγκλισης, ενώ

η χρήση του μετασχηματισμού κυματιδίων βελτιώνει περαιτέρω τα αποτελέσματα του μοντέλου τόσο στις τιμές PICP όσο και στις τιμές CWC. Το καλοκαίρι, τα παραγόμενα διαστήματα εμπιστοσύνης είναι χαμηλότερης ποιότητας, τόσο όσον αφορά τις τιμές του CWC όσο και τη σταθερότητα. Από την άλλη, τα καλύτερα αποτελέσματα επιτυγχάνονται το φθινόπωρο και την άνοιξη. Την άνοιξη, όχι μόνο επιτυγχάνεται η καλύτερη μέση τιμή CWC, αλλά και η τυπική απόκλιση των αποτελεσμάτων είναι η χαμηλότερη, με αποτέλεσμα την υψηλή σταθερότητα.

Το κύριο πλεονέκτημα του προτεινόμενου μοντέλου είναι η αρχιτεκτονική του. Λαμβάνοντας υπόψη το γεγονός ότι είναι ένα μοντέλο που βασίζεται σε τεχνικές μηχανικής μάθησης, προσφέρει πολλές δυνατότητες στη χρήση του. Με την επιτυχή τροποποίηση των δεδομένων εισόδου για διαφορετικά προβλήματα, το προτεινόμενο μοντέλο θα μπορούσε να προσαρμοστεί αποτελεσματικά σε προβλήματα πρόβλεψης αιολικής ισχύος της πραγματικής ζωής. Χάρη στην τεχνολογία που βασίζεται σε χρήση νευρωνικών δικτύων, το προτεινόμενο μοντέλο δεν περιορίζεται από τις τεχνικές παραμέτρους των αιολικών πάρκων. Επιπλέον, η προσαρμογή του σε εποχιακό πλαίσιο έδειξε ότι τα εποχικά αποτελέσματα ακολουθούν ένα συγκεκριμένο μοτίβο. Αυτό θα μπορούσε να επιτρέψει περαιτέρω την προσαρμογή του μοντέλου πρόβλεψης σύμφωνα με την περίοδο πρόβλεψης που ενδιαφέρει το χρήστη, προκειμένου να βελτιστοποιηθούν τα αποτελέσματα πρόβλεψης από εποχιακή οπτική.



# Κεφάλαιο 6

## ΠΙΘΑΝΟΤΙΚΗ ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΙΣΧΥΟΣ ΜΕ ΥΒΡΙΔΙΚΗ ΜΕΘΟΔΟ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

### 6.1 Εισαγωγή

Η πρόβλεψη της ηλιακής ενέργειας αποτελεί ένα δυναμικό περιβάλλον για την έρευνα. Όπως περιγράφηκε και στο Κεφάλαιο 2, διάφορες μεθοδολογίες επικεντρώνονται στην αποτελεσματική αιτιοκρατική και πιθανοτική πρόβλεψη. Ωστόσο, η κατανόηση της αβεβαιότητας στη διαδικασία πρόβλεψης και της εφαρμογής της σε προβλήματα της πραγματικής ζωής γίνεται όλο και πιο αναγκαία. Ως εκ τούτου, η ανάγκη αξιολόγησης μοντέλων που συνδυάζουν αιτιοκρατική και πιθανοτική πρόβλεψη είναι ένας τομέας με μεγάλες δυνατότητες βελτίωσης και κατανόησης. Επιπλέον, οι αλγόριθμοι βελτιστοποίησης που εστιάζουν στη βελτίωση των σφαλμάτων πρόβλεψης εφαρμόζονται συνήθως σε ένα μονοδιάστατο πλαίσιο, όπου εστιάζουν είτε στο μέρος της προεπεξεργασίας της πρόβλεψης είτε στον επανυπολογισμό των παραμέτρων του μοντέλου. Λαμβάνοντας υπόψη τους αλγόριθμους βελτιστοποίησης τύπου σμήνους, ενώ είναι σε θέση να διευρύνουν τις δυνατότητες αναζήτησης των μοντέλων πρόβλεψης, τείνουν να βασίζονται σε απλά μεμονωμένα σμήνη πληθυσμού, εύκολα παγιδευμένα σε τοπικά βέλτιστα. Συγκεκριμένα, για την πιθανοτική πρόβλεψη ηλιακής ενέργειας, η εφαρμογή προηγμένων αλγορίθμων βελτιστοποίησης τύπου σμήνους είναι εξαιρετικά περιορισμένη. Επιπλέον, η χρήση του υπερσύγχρονου δικτύου LSTM έχει γίνει ευρέως δημοφιλής τα τελευταία χρόνια, λόγω της μεγάλης ικανότητάς του να χειρίζεται δεδομένα χρονοσειρών. Ωστόσο, το ίδιο το LSTM, έχοντας μια διαδικασία εκπαίδευσης που βασίζεται στην προς τα πίσω διάδοση του σφάλματος μπορεί να είναι ακόμη πιο επιρρεπής στο να παγιδευτεί σε τοπικά βέλτιστα. Η εφαρμογή τεχνικών αναδειγματοληψίας για πιθανοτική πρόβλεψη ισχύος μαζί με το LSTM δεν έχει ερευνηθεί ενεργά, δεδομένου ότι τέτοιες τεχνικές τείνουν να αναμιγνύουν τις χρονοσειρές και επομένως χάνεται η διαδοχικότητά τους. Ωστόσο, στην περίπτωση της παραγωγής φωτοβολταϊκής ισχύος όπου υπάρχει ημερήσια επανάληψη, οι χρονοσειρές μπορούν να «σπάσουν» σε ημερήσια δείγματα και να εφαρμοστεί επαναδειγματοληψία σε αυτά. Επομένως, ο συνδυασμός των πλεονεκτημάτων των τεχνικών αναδειγματοληψίας, όπως η μέθοδος Bootstrap, και του μοντέλου LSTM γίνεται μια βιώσιμη επιλογή.

Με στόχο να καλύψει τους περιορισμούς που παρουσιάστηκαν παραπάνω, το παρόν κεφάλαιο περιγράφει τη διερεύνηση της δυνατότητας κατασκευής διαστημάτων πρόβλεψης υψηλής ακρίβειας μέσω της ανάπτυξης ενός καινοτόμου μοντέλου πρόβλεψης φωτοβολταϊκής ισχύος κάτω από το πιθανοτικό φάσμα, για έναν βραχυπρόθεσμο ορίζοντα πρόβλεψης επόμενης ημέρας. Λαμβάνοντας υπόψη την ισχυρή φύση των χρονοσειρών του προβλήματος που

διερευνάται, το LSTM ως κύριο μοντέλο αποτελεί μια σαφή επιλογή, σε συνδυασμό με μια τεχνική επαναδειγματοληψίας προκειμένου να εφαρμοστεί για πιθανοτική πρόβλεψη. Με στόχο την περαιτέρω βελτίωση των δυνατοτήτων αναζήτησης της βαθιάς μάθησης, και ως εκ τούτου του επιλεγμένου μοντέλου LSTM, διασφαλίζοντας την καθολική βελτιστοποίηση χωρίς παράλληλα να επηρεάζεται η υπολογιστική απόδοση του μοντέλου, προτείνεται και εφαρμόζεται ένας προηγμένος, μεταερευτικός, βελτιωμένος αλγόριθμος βελτιστοποίησης. Για να επεκταθεί περαιτέρω η ικανότητα καθολικής βελτιστοποίησης του προτεινόμενου αλγορίθμου και να εξαλειφθεί όσο το δυνατόν περισσότερο η πιθανότητα παγίδευσής του σε τοπικά βέλτιστα, εφαρμόζεται ένας άλλος μεταερευτικός μηχανισμός. Επιπλέον, λαμβάνοντας υπόψη την αυξανόμενη ανάγκη αξιολόγησης και εφαρμογής της αβεβαιότητας της διαδικασίας πρόβλεψης σε προβλήματα πραγματικής ζωής, αλλά και ακολουθώντας τις πρόσφατες ερευνητικές τάσεις, λαμβάνονται υπόψη αιτιοκρατικές προβλέψεις καθώς και προβλέψεις αβεβαιότητας, ώστε να παρέχεται μια ολοκληρωμένη εικόνα των προγνωστικών αποτελεσμάτων.

Η αξιολόγηση του προτεινόμενου υβριδικού μοντέλου καθορίζεται από την ελαχιστοποίηση της συνάρτησης κόστους του Κριτηρίου Πλάτους Κάλυψης (CWC), η οποία ταυτόχρονα βελτιστοποιεί την ευκρίνεια και τη βαθμονόμηση των παραγόμενων διαστημάτων πρόβλεψης. Οι ενδοωριαίες αιτιοκρατικές προβλέψεις υπολογίζονται και αξιολογούνται ποιοτικά από το τελικό προτεινόμενο πιθανοτικό μοντέλο, προκειμένου να εκτιμηθούν πιθανές διακυμάνσεις ισχύος. Τα παρεχόμενα αποτελέσματα αναλύονται περαιτέρω από εποχιακή άποψη. Το προτεινόμενο μοντέλο πρόβλεψης φωτοβολταϊκής ισχύος καταφέρει:

- i. Να προτείνει ένα καινοτόμο υβριδικό πιθανοτικό μοντέλο, αξιοποιώντας την ικανότητα αναδειγματοληψίας της μεθόδου Bootstrap και την αρχιτεκτονική του μοντέλου LSTM, η οποία του επιτρέπει να συλλαμβάνει διαδοχικές εξαρτήσεις και πολύπλοκες σχέσεις μέσα στα δεδομένα χρονοσειρών. Το προτεινόμενο μοντέλο πρόβλεψης έχει αναπτυχθεί για την ακριβή κατασκευή διαστημάτων πρόβλεψης και την αποτελεσματική εκτίμηση της απόδοσης φωτοβολταϊκής ισχύος με χρονικό ορίζοντα επόμενης ημέρας.
- ii. Να εφαρμόσει μια βελτιωμένη έκδοση του αλγορίθμου Chicken Swarm Optimizer (ICSO) προκειμένου να βελτιστοποιηθούν τα βάρη και οι πολώσεις του αναπτυγμένου νευρωνικού δικτύου. Συμπεριλαμβάνοντας έναν βελτιωμένο τρόπο ενημέρωσης της θέσης των σωματιδίων του σμήνους των πληθυσμών του ICSO, η ικανότητα τοπικής και ολικής αναζήτησης των βέλτιστων σωματιδίων του σμήνους ενισχύεται, αποφεύγοντας παράλληλα της παγίδευσής τους σε τοπικό ελάχιστο. Επιπλέον, ένας αλγόριθμος θηράματος-θηρευτή προσαρμόστηκε και βελτιστοποιήθηκε προσεκτικά για την περαιτέρω βελτίωση του ICSO. Ο αλγόριθμος θηράματος-θηρευτή (Prey-Predator – PP) χρησιμεύει και εφαρμόζεται ως μηχανισμός διαφυγής που ενθαρρύνει τα σωματίδια του σμήνους να εκμεταλλευτούν πολλά υποσχόμενες περιοχές ή νέες περιοχές του χώρου αναζήτησης, γεγονός που επιτρέπει καλύτερη σύγκλιση και προβλέψεις υψηλότερης ποιότητας. Το τελικό προτεινόμενο υβριδικό μοντέλο Boot-LSTM, με την εφαρμογή του προσαρμοσμένου PP, καταφέρει να κατασκευάσει ακριβή

διαστήματα πρόβλεψης υψηλής ποιότητας και να ξεπεράσει σύγχρονες μεθοδολογίες όσον αφορά τα προγνωστικά σφάλματα και την ακρίβεια.

- iii. Να εξετάσει ενδοωριαίες σημειακές προβλέψεις φωτοβολταϊκής ισχύος, προκειμένου να παρέχει στο προτεινόμενο υβριδικό μοντέλο ένα ποιοτικό εργαλείο αξιολόγησης των πιθανών διακυμάνσεων ισχύος επόμενης ημέρας. Με τη σειρά του, το μοντέλο είναι σε θέση να χρησιμοποιήσει αποτελεσματικά τις παραπάνω πληροφορίες για να κατασκευάσει πιο ακριβή διαστήματα πρόβλεψης.

## 6.2 Ανάλυση και επεξεργασία μετεωρολογικών δεδομένων και δεδομένων φωτοβολταϊκής ισχύος


Προκειμένου να αξιολογηθεί επαρκώς η αποτελεσματικότητα του προτεινόμενου υβριδικού μοντέλου πιθανοτικής πρόβλεψης φωτοβολταϊκής ισχύος, εφαρμόστηκε σε σύνολο δεδομένων δύο διαφορετικών φωτοβολταϊκών πάρκων.

Η πρώτη περίπτωση αφορά φωτοβολταϊκό πάρκο ισχύος 1551 kWp. Δύο χρόνια ιστορικών δεδομένων είναι διαθέσιμα που χρονολογούνται από την 1η Ιανουαρίου 2020 έως τις 31 Δεκεμβρίου 2021, με χρονικό βήμα ενός λεπτού. Το διαθέσιμο σύνολο δεδομένων περιλαμβάνει ιστορικά δεδομένα παραγωγής ισχύος καθώς και μετεωρολογικά δεδομένα, συμπεριλαμβανομένης της ακτινοβολίας στο κεκλιμένο επίπεδο των ΦΒ συλλεκτών, της θερμοκρασίας των φωτοβολταϊκών συλλεκτών, της θερμοκρασίας περιβάλλοντος, της σχετικής υγρασίας, της βροχόπτωσης καθώς και της ταχύτητας και της διεύθυνσης του ανέμου.

Η δεύτερη περίπτωση αφορά φωτοβολταϊκό πάρκο ισχύος 11900 kWp. Δύο χρόνια ιστορικών δεδομένων είναι διαθέσιμα που χρονολογούνται από την 1η Ιανουαρίου 2019 έως τις 31 Δεκεμβρίου 2020, με χρονικό βήμα 15 λεπτών. Το διαθέσιμο σύνολο δεδομένων περιλαμβάνει ιστορικά δεδομένα παραγωγής ισχύος και μετεωρολογικά δεδομένα, συμπεριλαμβανομένης της κεκλιμένης ακτινοβολίας, της θερμοκρασίας των φωτοβολταϊκών συλλεκτών, της θερμοκρασίας περιβάλλοντος και της σχετικής υγρασίας.

Λαμβάνοντας υπόψη ότι για την πλειοψηφία των δεδομένων παρατηρήθηκε ότι η ισχύς των ΦΒ έφτασε στο μέγιστο σε ώρες κοντά στις 13:00, για τη βελτιστοποίηση της όλης διαδικασίας, θεωρήθηκε ότι η ΦΒ ισχύς φτάνει στο μέγιστο στις 13:00. Λαμβάνοντας υπόψη την καμπύλη παραγωγής φωτοβολταϊκής ενέργειας για κάθε ημέρα, οι ημέρες υποκατηγοριοποιήθηκαν περαιτέρω σε ηλιόλουστες ημέρες, ημέρες με ελαφρά σύννεφα και ημέρες με βαριά σύννεφα. Παράδειγμα των αντίστοιχων καμπυλών παραγωγής φωτοβολταϊκής παραγόμενης ενέργειας των ανωτέρω τριών υποκατηγοριών παρουσιάζεται στο Σχήμα 6.1.

Οι καμπύλες ισχύος εξόδου των φωτοβολταϊκών συστημάτων παραγωγής ηλεκτρικής ενέργειας αποτυγχάνουν να επιδείξουν ένα μοτίβο υπό συνθήκες ελαφριάς και βαριάς συννεφιάς. Η παραγωγή φωτοβολταϊκής ισχύος κατά τη διάρκεια ελαφριάς και βαριάς συννεφιάς παρουσιάζει μεγαλύτερες διακυμάνσεις από ό,τι σε ηλιόλουστες καιρικές συνθήκες και δεν υπάρχει κανόνας για την εκτίμηση της παραγόμενης ισχύος σε αυτές τις συνθήκες. Λαμβάνοντας υπόψη ότι η μείωση κατά ένα βαθμό της θερμοκρασίας της φωτοβολταϊκής μονάδας θα μπορούσε να οδηγήσει σε απώλεια παραγωγής ισχύος της τάξης του 0,5%, η εξάρτηση των ηλιακών συλλεκτών από τη θερμοκρασία επηρεάζεται σε μεγάλο βαθμό από τις



**Σχήμα 6.1** Απεικόνιση τυπικών καμπυλών παραγωγής φωτοβολταϊκής ενέργειας για ημέρες με ήλιο, ελαφρά σύννεφα και βαριά σύννεφα. Παράδειγμα από ΦΒ Πάρκο1.

διακυμάνσεις της σύννεφιάς. Ως εκ τούτου, η εκτίμηση της παραγωγής ενέργειας σε συνθήκες ελαφριάς και βαριάς σύννεφιάς είναι γενικά πολύ δύσκολη [161], [162].

### 6.3 Πρώιμο προτεινόμενο μοντέλο μηχανικής μάθησης


Η αρχική ιδέα υλοποίησης του μοντέλου πρόβλεψης βασίστηκε στη χρήση ενός LSTM νευρωνικού δικτύου βελτιστοποιημένο με έναν αλγόριθμο τύπου σμήνους σωματιδίων.

#### 6.3.1 Νευρωνικά δίκτυα μακράς βραχυπρόθεσμης μνήμης (LSTM)

Το νευρωνικό δίκτυο στο οποίο βασίστηκε το προτεινόμενο υβριδικό μοντέλο πρόβλεψης αποτελεί ένα νευρωνικό δίκτυο μακράς βραχυπρόθεσμης μνήμης (Long Short Tem Memory – LSTM), το οποίο είναι ένας τύπος αναδρομικού νευρωνικού δικτύου (Recurrent Neural Network – RNN) που μπορεί να μάθει την εξάρτηση τάξης σε προβλήματα πρόβλεψης με χρονοσειρές, διατηρώντας προηγούμενες πληροφορίες και δημιουργώντας χρονικές συσχετίσεις μεταξύ διαδοχικών δεδομένων με εσωτερικά αυτοεπαναλαμβανόμενα δίκτυα [163]. Το LSTM περιέχει τέσσερα συνδεδεμένα στρώματα, τρία στρώματα πύλης και ένα στρώμα tanh. Η κατάσταση κελιού αποτελεί μια βασική μεταβλητή του LSTM που μπορεί να διατρέξει την αρχιτεκτονική του νευρωνικού δικτύου, μεταφέροντας πληροφορίες προηγούμενων βημάτων [163]. Η αρχιτεκτονική ενός τυπικού κελιού LSTM παρουσιάζεται στο Σχήμα 6.2. Το LSTM είναι ικανό να αφαιρεί ή να προσθέτει πληροφορίες στην κατάσταση κελιού, που ρυθμίζεται από πύλες.

Το πρώτο στρώμα είναι η πύλη λήθης που αποφασίζει ποιες πληροφορίες προηγούμενων βημάτων θα ξεχαστούν. Η μαθηματική εξίσωση για την έξοδο της πύλης λήθης ( $f_t$ ) δίνεται από τη σχέση:

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (6.1)$$



**Σχήμα 6.2** Τυπική αρχιτεκτονική κελιού LSTM.

όπου  $\sigma$  είναι η σιγμοειδής συνάρτηση ενεργοποίησης,  $W_f$  είναι το βάρος της πύλης λήθης,  $b_f$  είναι η πόλωση της πύλης λήθης,  $X_t$  είναι η είσοδος τη στιγμή  $t$  και  $h_{t-1}$  είναι η έξοδος του κρυφού στρώματος τη στιγμή  $t-1$ .

Το δεύτερο στρώμα είναι η πύλη εισόδου ( $i_t$ ), η οποία αποφασίζει ποιες νέες πληροφορίες θα αποθηκευτούν στην κατάσταση κελιού χρησιμοποιώντας:

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \quad (6.2)$$

όπου  $W_i$  είναι το βάρος της πύλης εισόδου και  $b_i$  είναι η πόλωση της πύλης εισόδου.

Το τρίτο στρώμα είναι το στρώμα  $\tanh$  ή το στρώμα κατάστασης κελιού ( $\check{C}_t$ ). Δημιουργεί ένα διάνυσμα με νέες υποψήφιες τιμές, που ορίζονται από τη σχέση:

$$\check{C}_t = \varphi(W_C \cdot [h_{t-1}, X_t] + b_C) \quad (6.3)$$

όπου  $\varphi$  είναι η συνάρτηση  $\tanh$ ,  $W_C$  είναι το βάρος του κυττάρου και  $b_C$  είναι η πόλωση του κελιού.

Μετά τα τρία πρώτα στρώματα, η παλιά κατάσταση κελιού  $C_{t-1}$  ενημερώνεται από την  $C_t$ . Η ενημέρωση προέρχεται από τον συνδυασμό της εξόδου της πύλης λήθης και της πύλης εισόδου, όπου η πρώτη καθορίζει τι πρέπει να ξεχαστεί στην πορεία της εκπαίδευσης και η δεύτερη καθορίζει τι πρέπει να προστίθεται στη νέα κατάσταση κελιού, όπως φαίνεται από τη σχέση:

$$C_t = f_t C_{t-1} + i_t \check{C}_t \quad (6.4)$$

Το τελικό στρώμα είναι η πύλη εξόδου ( $o_t$ ), η οποία παράγει την τελική έξοδο σύμφωνα με το ενημερωμένο κελί. Η διαδικασία της πύλης εξόδου είναι:

$$o_t = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o) \cdot \varphi(C_t) \quad (6.5)$$

όπου  $W_o$  είναι το βάρος της πύλης εξόδου και  $b_o$  είναι η πόλωση της πύλης εξόδου.

### 6.3.2 Μέθοδος επαναδειγματοληψίας Bootstrap

Η μέθοδος Bootstrap θεωρείται μια γενική προσέγγιση στατιστικής εξαγωγής συμπερασμάτων που βασίζεται στην οικοδόμηση μιας κατανομής δειγματοληψίας με ομοιόμορφη δειγματοληψία με αντικαταστάσεις από τα αρχικά δεδομένα [164]. Εφαρμόζεται ευρέως ως μια ισχυρή εναλλακτική λύση στη στατιστική εξαγωγή συμπερασμάτων με βάση τις παραμετρικές παραδοχές, οι οποίες μπορεί να είναι αναξιόπιστες και ακόμη και αδύνατες λόγω της πολυπλοκότητας που εμπλέκεται στον υπολογισμό των τυπικών σφαλμάτων σε ορισμένες συνθήκες.

Τρεις διαφορετικοί αλγόριθμοι Bootstrap μπορούν να εφαρμοστούν για ανάλυση παλινδρόμησης [165], συμπεριλαμβανομένων των ζευγών Bootstrap, του Bootstrap τυπικών υπολειμμάτων αναδειγματοληψίας και του Bootstrap άγριων υπολειμμάτων αναδειγματοληψίας. Σε σύγκριση με τις άλλες τεχνικές, η τεχνική ζευγών Bootstrap επιλέγεται επειδή είναι πιο κατάλληλη για προβλήματα, όπως η πρόβλεψη φωτοβολταϊκής παραγωγής, όπου οι παρατηρήσεις είναι αλληλοσυσχετιζόμενες και επειδή είναι παραπάνω ικανή να διατηρήσει τη δομή εξάρτησης μεταξύ παρατηρήσεων. Για  $N$  αυθαίρετα διακριτά δείγματα  $\{(x_i, t_i)\}_{i=1}^N$ , όπου  $x_i \in \mathbf{R}^n$  με  $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T$ ,  $t_i \in \mathbf{R}^m$  με  $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T$  και  $\hat{y}_i = (x_i)$  την τιμή πρόβλεψης των δειγμάτων εισόδου που δημιουργούνται από το  $I$ στο σύνολο δεδομένων που έχει εφαρμοστεί το Bootstrap, τα ζεύγη Bootstrap μπορούν να εφαρμοστούν σύμφωνα με τα ακόλουθα βήματα:

Βήμα 1) Συλλογή δειγμάτων εκπαίδευσης  $\{(x_i, t_i)\}_{i=1}^N$ .

Βήμα 2) Δημιουργία ζευγών Bootstrap  $\{(x_i^*, t_i^*)\}_{i=1}^N$  με ομοιόμορφη δειγματοληψία με αντικατάσταση από τα αρχικά δεδομένα εκπαίδευσης  $\{(x_i, t_i)\}_{i=1}^N$ .

Βήμα 3) Εκτίμηση του μοντέλου  $\hat{y}_i = (x_i^*)$  από το  $I$ στο σύνολο δεδομένων που έχει εφαρμοστεί το Bootstrap  $\{(x_i^*, t_i^*)\}_{i=1}^N$ .

Βήμα 4) Επανάληψη των βημάτων 2 και 3 για να εξαγωγή αντιγράφων Bootstrap.

### 6.3.3 Αλγόριθμος σμήνους κοτόπουλων (CSO)

Ο αλγόριθμος βελτιστοποίησης σμήνους κοτόπουλων CSO αποτελεί έναν έξυπνο μεταερευτικό αλγόριθμο βελτιστοποίησης που προσομοιώνει το ιεραρχικό σύστημα και τη συμπεριφορά αναζήτησης τροφής του σμήνους κοτόπουλων [166]. Σε σύγκριση με άλλους αλγόριθμους βελτιστοποίησης, το CSO φαίνεται να είναι πιο ευέλικτο, καθώς μπορεί να εφαρμοστεί σε διάφορα προβλήματα βελτιστοποίησης, τόσο σε μεμονωμένα όσο και σε πολυκριτηριακά προβλήματα. Ο αλγόριθμος χωρίζει τα κοτόπουλα σε ομάδες. Κάθε ομάδα περιλαμβάνει έναν κόκορα, αρκετές κότες και μερικούς νεοσσούς. Στη βελτιστοποίηση CSO, χρησιμοποιούνται οι ακόλουθοι κανόνες για την προσομοίωση των συμπεριφορών του κοπαδιού [167]:

i. Υπάρχουν αρκετοί υποπληθυσμοί στο σύνολο του πληθυσμού κοτόπουλων. Κάθε υποπληθυσμός περιλαμβάνει έναν κόκορα, πολλές κότες και νεοσσούς. Οι κόκορες έχουν την ισχυρότερη ικανότητα αναζήτησης τροφής και έτσι κυριαρχούν στο κοπάδι. Οι κότες έχουν τη

δεύτερη καλύτερη ικανότητα αναζήτησης τροφής και οι νεοσσοί έχουν τη χειρότερη ικανότητα αναζήτησης τροφής.

ii. Τα κοπάδια ταξινομούνται με βάση τις τιμές καταλληλότητας ( $S$ ). Μερικά από τα κοτόπουλα με καλές τιμές καταλληλότητας επιλέγονται ως κόκορες και μερικά από τα κοτόπουλα με κακές τιμές καταλληλότητας επιλέγονται ως νεοσσοί. Τα υπόλοιπα κοτόπουλα επιλέγονται ως μητρικές κότες. Οι κότες προστίθενται αυθαίρετα σε μια υποομάδα.

(3) Η σχέση μεταξύ μητέρων ορνίθων και νεοσσών, καθώς και η ηγετική σχέση, παραμένουν αμετάβλητες υπό συγκεκριμένη ιεραρχία. Αλλά καθώς οι νεοσσοί μεγαλώνουν, αυτές οι καταστάσεις ενημερώνονται κάθε φορά ( $G$  είναι ο χρόνος ενημέρωσης, ο οποίος έχει μια ορισμένη τιμή).

(4) Οι κότες ακολουθούν τα κοκόρια της ομάδας τους για αναζήτηση τροφής και μπορούν να κλέψουν τροφή από άλλους νεοσσούς. Με τη σειρά τους, οι νεοσσοί ακολουθούν τις όρνιθες για να αναζητήσουν φαγητό γύρω τους.

Κατά τη διάρκεια της διαδικασίας βελτιστοποίησης, η θέση κάθε κοτόπουλου αντιπροσωπεύει μια εφικτή λύση. Δεδομένου ότι κάθε κοτόπουλο έχει διαφορετικές δυνατότητες αναζήτησης τροφής, διαφορετικά κοτόπουλα έχουν διαφορετικές στρατηγικές ενημέρωσης. Υποθέτοντας ότι ο χώρος αναζήτησης των κοτόπουλων είναι  $d$ , υπάρχουν  $N_{chickens}$  συνολικά. Υπάρχουν νεοσσοί  $N_c$ , κότες  $N_h$  και κόκορες  $N_r$ . Η εξίσωση για την ενημέρωση του  $i$ -ου κόκορα είναι:

$$Z_{i,j}^{t+1} = Z_{i,j}^t + Z_{i,j}^t randn(0, \sigma^2) \quad (6.6)$$

όπου,

$$\sigma^2 = \begin{cases} 1, & S_e \geq S_i \\ \exp\left(\frac{S_e - S_i}{|S_i - \varepsilon|}\right), & S_e < S_i \end{cases} \quad (6.7)$$

όπου  $randn(0, \sigma^2)$  αντιπροσωπεύει την κατανομή Γκαουσιανή κατανομή,  $S_e$  ( $e \in [1, N_r]$ ,  $i \neq e$ ) δείχνει έναν κόκορα διαφορετικό από τον  $i$ -οστό κόκορα,  $\varepsilon$  είναι μια απειροελάχιστη τιμή, η οποία εξασφαλίζει ότι ο παρονομαστής της εξίσωσης (6.7) δεν είναι μηδέν.

Η εξίσωση για την ενημέρωση της  $i$ -οστής κότας είναι:

$$Z_{i,j}^{t+1} = Z_{i,j}^t + p1 \cdot randm(Z_{r1,j}^t - Z_{i,j}^t) + p2 \cdot randm(Z_{r2,j}^t - Z_{i,j}^t) \quad (6.8)$$

όπου,

$$\begin{cases} p1 = \exp\left(\frac{S_i - S_{r1}}{ads(S_i + \varepsilon)}\right) \\ p2 = (S_{r2} - S_i) \end{cases} \quad (6.9)$$

όπου  $\text{randm}$  είναι ένας τυχαίος αριθμός μεταξύ 0 και 1,  $r1$  αντιπροσωπεύει τον κόκορα στην ομάδα όπου βρίσκεται η  $i$ -οστή κότα,  $r2$  ( $r1 \neq r2$ ) είναι ο κόκορας σε άλλη ομάδα.

Προκειμένου να ενημερωθούν τα σωματίδια νεοσσών, χρησιμοποιείται η ακόλουθη εξίσωση:

$$Z_{i,j}^{t+1} = Z_{i,j}^t + GL(i) \cdot (Z_{mj}^t - Z_{i,j}^t) \quad (6.10)$$

όπου  $Z_{mj}^t$  είναι το μητρικό κοτόπουλο ακολουθούμενο από το  $i$ -οστό νεοσσό και το  $GL$  αντιπροσωπεύει έναν τυχαίο αριθμό μεταξύ 0 και 2 [168].

#### 6.4 Εισαγωγή μηχανισμού θηράματος-θηρευτή

Ο μηχανισμός θηράματος-θηρευτή (Prey-Predator – PP) περιλαμβάνεται προκειμένου να βελτιωθεί περαιτέρω η ικανότητα αναζήτησης του αλγορίθμου. Ο μηχανισμός θηράματος-θηρευτή μπορεί να συμβάλει στην εξισορρόπηση των ικανοτήτων εξερεύνησης και εκμετάλλευσης της διαδικασίας αναζήτησης, γεγονός που μπορεί να οδηγήσει σε καλύτερη σύγκλιση και προβλέψεις υψηλότερης ποιότητας [169]. Συγκεκριμένα, η μέθοδος ενθαρρύνει τα σωματίδια του σμήνους να εκμεταλλευτούν πολλά υποσχόμενες περιοχές του χώρου αναζήτησης που έχουν ήδη εξερευνηθεί, μετακινώντας ένα κοτόπουλο στη θέση ενός από τα κοτόπουλα βέλτιστης θέσης (μηχανισμός διαφυγής).

Ο μηχανισμός διαφυγής του PP μετατοπίζει την εστίαση αναζήτησης του σμήνους προς πολλά υποσχόμενες αλλά και ήδη εξερευνημένες περιοχές, ενώ ο μηχανισμός αναπαραγωγής του θηράματος-θηρευτή απελευθερώνει σωματίδια που παγιδεύονται σε τοπικά βέλτιστα. Με τη χρήση αυτών των μηχανισμών, το PP επιτυγχάνει μια αντιστάθμιση μεταξύ του ποσοστού σύγκλισης και της παγκόσμιας αναζήτησης. Επίσης, το σμήνος ενθαρρύνεται να εξερευνησει νέες περιοχές του χώρου αναζήτησης αρχικοποιώντας τις θέσεις των κοτόπουλων που πιάνονται από τον θηρευτή. Η παραπάνω διαδικασία μπορεί να βοηθήσει στην πρόληψη της πρόωρης σύγκλισης και στη βελτίωση της ευρωστίας των λύσεων, καθώς διατηρεί την ποικιλομορφία εντός του σμήνους, εμποδίζοντας τα άτομα να συνωστίζονται πολύ στενά μεταξύ τους και ενθαρρύνοντάς τα να εξερευνήσουν διαφορετικές περιοχές του χώρου αναζήτησης.

#### 6.5 Τελικό προτεινόμενο μοντέλο πιθανοτικής πρόβλεψης φωτοβολταϊκής ισχύος

##### 6.5.1 Μοντέλο Bootstrap-LSTM

Στο προτεινόμενο υβριδικό μοντέλο, ο μηχανισμός Bootstrap βοηθά στη βελτίωση της ευρωστίας του μοντέλου LSTM εκπαιδεύοντάς το σε πολλαπλά σύνολα δεδομένων. Αυτή η προσέγγιση είναι ιδιαίτερα χρήσιμη για τον χειρισμό της μεταβλητότητας των δεδομένων παραγωγής ηλιακής ενέργειας που προκαλείται από τις μεταβαλλόμενες καιρικές συνθήκες. Στη συγκεκριμένη περίπτωση, η διαδικασία επαναδειγματοληψίας πραγματοποιείται σε καθημερινά σύνολα δεδομένων, τα οποία λειτουργούν ως bootstrapped δείγματα. Ο λόγος για αυτό είναι να διατηρηθεί η χρονική αυτοσυσχέτιση της φωτοβολταϊκής ισχύος εξόδου που παρατηρείται κατά τη διάρκεια της ημέρας.

Επιπλέον, ο μηχανισμός Bootstrap επιτρέπει την εξερεύνηση της συμπεριφοράς του μοντέλου LSTM σε διαφορετικές αλληλουχίες αναδειγματοληψίας ημερήσιων συνόλων δεδομένων, με διαφορετικές καιρικές συνθήκες. Μέσω της συνεχούς έκδοσης διαφορετικών προβλέψεων κατά τη διαδικασία επαναδειγματοληψίας και των χρονικών αλληλεξαρτήσεων που προσδιορίζονται από το LSTM, παράγονται ποιοτικά διαστήματα πρόβλεψης που ενσωματώνουν την εγγενή αβεβαιότητα των εκτιμήσεων επόμενης ημέρας. Τα βάρη του μοντέλου στη συνέχεια αναπροσαρμόζονται μέσω του βελτιωμένου αλγορίθμου βελτιστοποίησης CSO προκειμένου να βελτιωθεί η ακρίβεια του τελικού κατασκευασμένου διαστήματος πρόβλεψης. Η συνολική υβριδική διαδικασία μπορεί να οδηγήσει σε καλύτερη απόδοση του μοντέλου και προσαρμοστικότητα στα διαθέσιμα δεδομένα.

### 6.5.2 Βελτιωμένος αλγόριθμος σμήνους κοτόπουλων (ICSO)

Προκειμένου να βελτιωθεί περαιτέρω και να βελτιστοποιηθεί η ακρίβεια της μεθοδολογίας που βασίζεται στο LSTM, συμπεριλήφθηκε ένας CSO.

Λαμβάνοντας υπόψη τη χρήση του CSO, ο συνολικός πληθυσμός κοτόπουλων χωρίζεται σε τρεις διαφορετικούς υποπληθυσμούς, σε κόκορες, κότες και νεοσσούς. Σημειώνεται ότι οι σχέσεις μεταξύ των κοτόπουλων του σμήνους ενημερώνονται κάθε αριθμό γενεών  $G$ . Οι παραπάνω παράμετροι επιλέγονται με βάση τη διαδικασία έρευνας και βελτιστοποίησης που επικεντρώνεται στην ελαχιστοποίηση της αντικειμενικής συνάρτησης CWC, όπως αυτή ορίζεται στην εξίσωση (3.17).

Δεδομένου ότι ο παραδοσιακός αλγόριθμος CSO είναι σε θέση να βρει ένα τοπικό ελάχιστο, εφαρμόζεται ένας βελτιωμένος CSO (ICSO) για να επεκτείνει τις δυνατότητες αναζήτησης του αλγορίθμου. Ο κόκορας λειτουργεί ως αρχηγός του σμήνους. Όταν κολλάει σε ένα τοπικό ελάχιστο, έχει ως αποτέλεσμα το σμήνος να χάσει το ολικό βέλτιστο. Επομένως, ένας παράγοντας συνημιτόνου περιλαμβάνεται στην εξίσωση ενημέρωσης θέσης του κόκορα για την ενίσχυση της ικανότητας τοπικής και ολικής αναζήτησης του κόκορα:

$$Z_{ij}^{t+1} = Cip \cdot Z_{ij}^t + Z_{ij}^t \cdot randn(0, \sigma^2) \quad (6.11)$$

$$Cip = Cip_{min} + (Cip_{max} - Cip_{min}) \cdot \cos\left(\pi \cdot \frac{t}{T}\right) \quad (6.12)$$

όπου  $Cip_{min} = 0.3$ ,  $Cip_{max} = 0.8$  και  $T$  είναι ο μέγιστος αριθμός γενεών.

Επιπλέον, τα σωματίδια των νεοσσών αντί να ακολουθούν μόνο τις κότες, επηρεάζονται από το καλύτερο σωματίδιο του σμήνους, ώστε να μπορούν να αποφύγουν να πιαστούν στο τοπικό ελάχιστο. Μετά τη βελτίωση, η εξίσωση ενημέρωσης θέσης του  $i$ -στου νεοσσού είναι:

$$Z_{ij}^{t+1} = Z_{ij}^t + GL(i) \cdot (Z_{m,j}^t - Z_{ij}^t) + BL(i) \cdot (Z_{best,j}^t - Z_{ij}^t) \quad (6.13)$$

όπου  $BL$  είναι ο συντελεστής μάθησης και υπολογίζεται ως εξής:

$$BL(i) = \exp(S_{best} - S_i) \quad (6.14)$$

Επιπλέον, εισήχθη ένας Γκαουσιανός τελεστής μετάλλαξης, ο οποίος μετατοπίζει τη θέση του κοτόπουλου χρησιμοποιώντας την κανονική κατανομή γύρω από το μηδέν και τη διακύμανση κατά 0.1, όπως παρουσιάζεται παρακάτω:

$$Z_{i,j}^{t*} = Z_{i,j}^t + randn(\mu = 0, \sigma^2 = 0.1) \quad (6.15)$$

όπου  $Z_{i,j}^t$  είναι το προ-μεταλλαγμένο κοτόπουλο,  $Z_{i,j}^{t*}$  είναι το μεταλλαγμένο κοτόπουλο και το  $randn(\mu = 0, \sigma^2 = 0.1)$  αντιπροσωπεύει την κανονική κατανομή με μηδενική μέση τιμή και διακύμανση 0.1.

Ο μηχανισμός θηράματος-θηρευτή αποδείχθηκε ιδανικός για την περαιτέρω βελτιστοποίηση των συνιστωσών του ICSO, καθώς ενισχύει την ολική αναζήτηση διατηρώντας παράλληλα το ποσοστό σύγκλισης σε υψηλά επίπεδα. Ως αλγόριθμος βελτιστοποίησης που βασίζεται σε σμήνη, το ICSO μπορεί ακόμα να υποφέρει από πρόωρη σύγκλιση. Από την άλλη, το ICSO έχει ακραίες δυνατότητες σύγκλισης. Επιπλέον, χαρακτηρίζεται από υψηλή πολυπλοκότητα. Ως εκ τούτου, το PP καταφέρνει να επιτύχει μια αντιστάθμιση μεταξύ του ποσοστού σύγκλισης και της ολικής αναζήτησης, μειώνοντας παράλληλα τον απαιτούμενο χρόνο εκπαίδευσης.

Ο μηχανισμός θηράματος-θηρευτή εφαρμόζεται αμέσως μετά το τέλος κάθε γενιάς αλγορίθμων ICSO. Νέα μέλη εντάσσονται στο σμήνος, το οποίο ενημερώνεται πριν από την επόμενη επανάληψη ICSO και επεκτείνεται το πεδίο αναζήτησης του αλγορίθμου βελτιστοποίησης. Επίσης, τα τρέχοντα τοπικά βέλτιστα λαμβάνονται υπόψη μέσω της αντικατάστασης ενός κοτόπουλου με έναν τυχαίο καλύτερο μηχανισμό. Με αυτόν τον τρόπο, ο αλγόριθμος αποφεύγει την πρόωρη σύγκλιση σε τοπικό βέλτιστο, ενώ αυξάνει τις πιθανότητες επίτευξης του ολικού βέλτιστου.

Ως εκ τούτου, ο αλγόριθμος ICSO είναι σε θέση να ενισχύσει την απόδοση πρόβλεψης του μοντέλου LSTM στην πρόβλεψη φωτοβολταϊκής ισχύος, καθώς, μαζί με τον μηχανισμό PP, η αξιοποίηση προωθείται ενθαρρύνοντας το σμήνος να εξερευνήσει ελπιδοφόρες περιοχές του χώρου αναζήτησης που έχουν ήδη εξερευνηθεί, δηλαδή βοηθά το LSTM να τελειοποιήσει τις παραμέτρους του και να βελτιστοποιήσει τους κρυμμένους κόμβους, βάρη και πολώσεις. Επίσης, βοηθά το LSTM να επιτύχει καλύτερη ισορροπία μεταξύ υπερπροσαρμογής και υποπροσαρμογής, καθώς διατηρεί την ποικιλομορφία εντός του σμήνους και έτσι αποτρέπει τις πρόωρες συγκλίσεις σε λύσεις που αντιστοιχούν στα τοπικά ελάχιστα.

### 6.5.3 Αρχιτεκτονική προτεινόμενου μοντέλου Boot-LSTM-ICSO-PP

Με στόχο την αξιοποίηση των πλεονεκτημάτων των παραπάνω μηχανισμών, η αρχιτεκτονική του τελικού μοντέλου υλοποιεί προσεκτικά και σταδιακά τα χαρακτηριστικά τους. Η δομή του προτεινόμενου μοντέλου μπορεί να παρουσιαστεί με τη μορφή σταδίων που

ασχολούνται με διαφορετικά μέρη του προβλήματος. Η αιτιοκρατική διαδικασία πρόβλεψης προηγείται των υπόλοιπων λειτουργιών του μοντέλου λόγω του ότι χρησιμοποιείται ως αρχικό σημείο ρύθμισης για τις παραμέτρους του μοντέλου. Ο μηχανισμός Bootstrap υλοποιείται στη συνέχεια, για την αναδειγματοληψία των δεδομένων εισόδου προκειμένου να ξεκινήσει η πιθανοτική διαδικασία πρόβλεψης, λαμβάνοντας υπόψη τις παραμέτρους του σταδίου αιτιοκρατικής πρόβλεψης. Τέλος, υλοποιείται ο αλγόριθμος βελτιστοποίησης που αποτελείται από το ICSO και τον μηχανισμό PP. Κατά τη διάρκεια αυτού του σταδίου, κάθε κοτόπουλο ( $Z_{i,j}^t$ ) αντιπροσωπεύει μια συστοιχία που αποτελείται από τα βάρη και τις πολώσεις κάθε LSTM. Στο Σχήμα 6.3 παρουσιάζεται το πλήρες προτεινόμενο μοντέλο όπου παρουσιάζεται η αλληλεπίδραση μεταξύ των διαφόρων σταδίων.

#### Στάδιο 1

Κατά την αρχικοποίηση της διαδικασίας, το μοντέλο λειτουργεί ως αιτιοκρατικό μοντέλο πρόβλεψης για τη δημιουργία λεπτομερών σημειακών προβλέψεων επόμενης ημέρας, καθώς και για την εκτίμηση των αρχικών βαρών και τιμών πόλωσης που θα λειτουργήσουν ως καλά σημεία εκκίνησης για το πιθανοτικό μοντέλο πρόβλεψης.

Εισάγοντας ένα αιτιοκρατικό στάδιο σε ολόκληρο το μοντέλο, ο χρήστης είναι σε θέση να χρησιμοποιήσει τα βελτιστοποιημένα βάρη και τις πολώσεις του μοντέλου προκειμένου να εκπαιδεύσει αρχικά το πιθανοτικό μοντέλο πρόβλεψης που προτείνεται στα στάδια 2 και 3. Επίσης, οι αιτιοκρατικές εκτιμήσεις μπορούν να αξιολογηθούν περαιτέρω από το πιθανοτικό μοντέλο προκειμένου να βελτιωθούν τα τελικά διαστήματα πρόβλεψης. Επιπλέον, μια αιτιοκρατική εικόνα, σε συνδυασμό με το πιθανοτικό μοντέλο, θα μπορούσε να προσφέρει στον χρήστη μια πληρέστερη εικόνα της προγνωστικής ικανότητας και αξιοπιστίας του μοντέλου.


#### Στάδιο 2

Πριν από το δεύτερο στάδιο, τα δεδομένα εισόδου υποβάλλονται στον μηχανισμό Bootstrap, όπου η διαδικασία επαναδειγματοληψίας εφαρμόζεται σε ημερήσια σύνολα δεδομένων. Τα βάρη και οι πολώσεις που εκτιμώνται από το αιτιοκρατικό μοντέλο χρησιμοποιούνται για την κατασκευή του αρχικού συνόλου διαστημάτων πρόβλεψης.

Αυτό το στάδιο στοχεύει να εκμεταλλευτεί την ικανότητα του μηχανισμού εκκίνησης να εντοπίζει και να καταγράφει τις διαδοχικές εξαρτήσεις και τις διαφορετικές σχέσεις των δεδομένων εισόδου. Επιπλέον, αυτό το στάδιο εκμεταλλεύεται το προηγούμενως εκπαιδευμένο αιτιοκρατικό μοντέλο και χρησιμοποιεί τα βελτιστοποιημένα βάρη και τις πολώσεις του για την αρχικοποίηση του πιθανοτικού μοντέλου. Τα παραπάνω έχουν ως αποτέλεσμα την ταχύτερη σύγκλιση και εκπαίδευση του προτεινόμενου μοντέλου καθώς και βελτιωμένα προγνωστικά αποτελέσματα.

#### Στάδιο 3

Κατά τη διάρκεια του τελικού σταδίου, οι παράμετροι του μοντέλου LSTM βελτιστοποιούνται εκ νέου χρησιμοποιώντας τον αλγόριθμο ICSO-PP, προκειμένου να βελτιωθούν οι αρχικές πιθανοτικές προβλέψεις και να δημιουργηθεί ένα βέλτιστο τελικό σύνολο διαστημάτων πρόβλεψης επόμενης ημέρας.



**Σχήμα 6.3** Αρχιτεκτονική προτεινόμενου μοντέλου πρόβλεψης και αλληλεπίδραση μεταξύ των σταδίων.

Αυτό το στάδιο εκμεταλλεύεται τα πλεονεκτήματα του αλγορίθμου CSO και τη λειτουργία του με την εφαρμογή του μηχανισμού θηράματος-θηρευτή. Ο αλγόριθμος ICSO που εισάγεται στην προτεινόμενη μεθοδολογία είναι μια προηγμένη βελτιστοποιημένη έκδοση του απλού αλγορίθμου CSO. Ως αλγόριθμος τύπου σμήνους, το ICSO λαμβάνει υπόψη περισσότερους από έναν πληθυσμούς για τα δεδομένα εκπαίδευσης, τα οποία, ενώ καθιστούν τη διαδικασία εκπαίδευσης πιο περίπλοκη, βελτιώνουν σημαντικά την ικανότητα ολικής αναζήτησης των σωματιδίων. Η εφαρμογή του μηχανισμού θηράματος-θηρευτή ενισχύει τις δυνατότητες αναζήτησης του ICSO καθώς επιτρέπει στα σωματίδια του σμήνους να αυξήσουν τον εξερευνημένο χώρο αναζήτησης και να αποφύγουν να παγιδευτούν σε τοπικά βέλτιστα, συμβάλλοντας έτσι με τον καλύτερο δυνατό τρόπο στα τελικά προγνωστικά αποτελέσματα.

## 6.6 Βελτιστοποίηση υπερπαραμέτρων μοντέλου πρόβλεψης

Η παραμετροποίηση του προτεινόμενου μοντέλου απαιτήσε πειραματισμό για τον βέλτιστο συνδυασμό των παραμέτρων του LSTM και του ICSO. Ο αριθμός των νευρώνων του κρυφού στρώματος προσδιορίζεται μέσω της τεχνικής διασταυρούμενης επικύρωσης k-fold. Η βελτιστοποίηση των υπερπαραμέτρων ήταν μια περίπλοκη διαδικασία, λαμβάνοντας υπόψη το γεγονός ότι, σε σύγκριση με άλλους αλγόριθμους βελτιστοποίησης τύπου σμήνους, στο CSO υπάρχουν περισσότεροι από ένας πληθυσμοί που πρέπει να βελτιστοποιηθούν.

Κατά τη διάρκεια του σταδίου προεπεξεργασίας δεδομένων, όλα τα δείγματα κανονικοποιούνται στο διάστημα  $[0, 1]$  χρησιμοποιώντας τη μέθοδο μέγιστου-ελάχιστου, ώστε τα χαρακτηριστικά εισόδου να κανονικοποιούνται στην ίδια κλίμακα. Στη συνέχεια, προσδιορίζονται οι υπερπαραμέτροι του μοντέλου. Όσον αφορά το μοντέλο LSTM, τα επίπεδα εμπιστοσύνης που χρησιμοποιούνται για την πρόβλεψη είναι 90%, 95% και 99% και τα κρυφά επίπεδα του μοντέλου ορίζονται ίσα με 30. Η βελτιστοποίηση του προτεινόμενου μοντέλου εκτελείται σε δύο στάδια. Πρώτον, οι παράμετροι του LSTM έχουν ρυθμιστεί ώστε να δημιουργούν βέλτιστες προβλέψεις σημείων χρησιμοποιώντας τον αλγόριθμο βελτιστοποίησης Adam. Στη συνέχεια, το σύνολο εκπαίδευσης χωρίζεται σε ημερήσια υποσύνολα, για να διατηρηθεί η χρονική αυτοσυσχέτιση της παραγωγής φωτοβολταϊκής ενέργειας μετά τη διαδικασία επαναδειγματοληψίας. Τα αρχικά διαστήματα πρόβλεψης σχηματίζονται χρησιμοποιώντας την τεχνική Bootstrap. Στη συνέχεια, οι παράμετροι του LSTM αναδιαμορφώνονται χρησιμοποιώντας τον προτεινόμενο αλγόριθμο ICSO-PP, για τη βελτιστοποίηση των παραγόμενων διαστημάτων πρόβλεψης. Η σιγμοειδής συνάρτηση ενεργοποίησης χρησιμοποιείται στο στρώμα εξόδου του μοντέλου LSTM.

Λαμβάνοντας υπόψη τις εφαρμογές της CSO, ο αριθμός των κοτόπουλων ορίζεται ίσος με 40, το 30% των οποίων είναι κόκορες, το 50% είναι κότες και το 40% των ορνίθων είναι μητέρες. Σημειώνεται ότι οι σχέσεις μεταξύ των κοτόπουλων του σμήνους ενημερώνονται κάθε γενιά  $G = 5$  και ο μέγιστος αριθμός γενεών ορίζεται ίσος με 20. Ο τελεστής μετάλλαξης εφαρμόζεται με πιθανότητα γραμμικής μείωσης για το πρώτο 70% των γενεών. Οι τελικές παράμετροι που επιλέχθηκαν ήταν αποτέλεσμα τελειοποίησης με βάση την ελαχιστοποίηση του σφάλματος πρόβλεψης. Με αυτόν τον τρόπο, η τελική διαμόρφωση σμήνους αποφεύγει αποτελεσματικά να κολλήσει σε τοπικά ελάχιστα. Ο Πίνακας 6.1 παρουσιάζει τις εφαρμοζόμενες υπερπαραμέτρους του συνδυασμένου αλγορίθμου ICSO-PP.

Η πιθανότητα ενός θηράματος να συναντήσει έναν θηρευτή ορίζεται στο 20% και ο μηχανισμός θηράματος-θηρευτή εφαρμόζεται για το πρώτο 70% των γενεών, όταν η τιμή καταλληλότητας ενός κοτόπουλου είναι 15% υψηλότερη από τη βέλτιστη του σμήνους. Στη συνέχεια, εκτελείται ένας πιθανοτικός «διαγωνισμός», για το αν το σωματίδιο θα ξεφύγει από τον θηρευτή ή θα πιαστεί, με πιθανότητες 75% και 25%, αντίστοιχα. Οι παραπάνω παράμετροι επιλέγονται με βάση την ελαχιστοποίηση της αντικειμενικής συνάρτησης CWC που ορίζεται στην εξίσωση (3.17).

**Πίνακας 6.1** Βέλτιστες τιμές των υπερπαραμέτρων του προτεινόμενου μοντέλου WT-LUBE-PSO-CWC.

| Παράμετρος     | Τιμή |
|----------------|------|
| G              | 5    |
| $N_{chickens}$ | 40   |
| $N_r$          | 12   |
| $N_h$          | 20   |
| $N_m$          | 8    |
| $N_c$          | 8    |
| $Cip_{min}$    | 0.3  |
| $Cip_{max}$    | 0.8  |

**Πίνακας 6.2** Ελαχιστοποίηση του CWC από επτά διαφορετικά μοντέλα για το ΦΒ Πάρκο1.

| Test day | CL (%) | CWC (%) |        |           |               |                |              |                   |
|----------|--------|---------|--------|-----------|---------------|----------------|--------------|-------------------|
|          |        | BELM    | LSTM   | Boot-LSTM | Boot-LSTM-CSO | Boot-LSTM-ICSO | BELM-ICSO-PP | Boot-LSTM-ICSO-PP |
| W/Sun    | 90     | 0,7234  | 0,4973 | 0,3682    | 0,3219        | 0,3086         | 0,2957       | 0,2549            |
|          | 95     | 0,8692  | 0,5102 | 0,4537    | 0,4136        | 0,3618         | 0,3753       | 0,3276            |
|          | 99     | 1,2931  | 0,5934 | 0,4928    | 0,4538        | 0,4021         | 0,4901       | 0,3971            |
| W/LC     | 90     | 0,5937  | 0,4365 | 0,3216    | 0,2846        | 0,2812         | 0,2585       | 0,2401            |
|          | 95     | 0,3889  | 0,4618 | 0,3925    | 0,3596        | 0,3269         | 0,3163       | 0,3137            |
|          | 99     | 0,5532  | 0,4731 | 0,4481    | 0,4001        | 0,3781         | 0,4149       | 0,3497            |
| W/HC     | 90     | 0,4293  | 0,3299 | 0,2821    | 0,2543        | 0,2103         | 0,2315       | 0,1218            |
|          | 95     | 0,4690  | 0,3518 | 0,2850    | 0,2621        | 0,2276         | 0,2537       | 0,1537            |
|          | 99     | 0,6173  | 0,3574 | 0,2953    | 0,2743        | 0,2453         | 0,2943       | 0,2134            |
| S/Sun    | 90     | 0,5224  | 0,3532 | 0,2927    | 0,2437        | 0,2398         | 0,1954       | 0,2021            |
|          | 95     | 0,5509  | 0,3945 | 0,3267    | 0,2814        | 0,2586         | 0,2407       | 0,2348            |
|          | 99     | 0,6241  | 0,4474 | 0,4406    | 0,3608        | 0,3124         | 0,2606       | 0,2891            |
| S/LC     | 90     | 0,4964  | 0,4220 | 0,3895    | 0,3491        | 0,2634         | 0,2143       | 0,1369            |
|          | 95     | 0,5043  | 0,4881 | 0,4628    | 0,3939        | 0,2941         | 0,2389       | 0,1713            |
|          | 99     | 0,7805  | 0,5007 | 0,4934    | 0,3987        | 0,3165         | 0,3205       | 0,2894            |
| S/HC     | 90     | 0,4108  | 0,3598 | 0,2318    | 0,2024        | 0,1847         | 0,2109       | 0,1246            |
|          | 95     | 0,4897  | 0,3718 | 0,3259    | 0,2238        | 0,2196         | 0,2481       | 0,1482            |
|          | 99     | 0,5075  | 0,4107 | 0,3711    | 0,3187        | 0,2781         | 0,2882       | 0,2234            |

**Πίνακας 6.3** Σύγκριση του CWC έξι μοντέλων, σε σχέση με το CWC του προτεινόμενου μοντέλου Boot-LSTM-ICSO-PP, για το ΦΒ Πάρκο 1.

| Test day | CL (%) | CWC (%) |      |           |               |                |              |
|----------|--------|---------|------|-----------|---------------|----------------|--------------|
|          |        | BELM    | LSTM | Boot-LSTM | Boot-LSTM-CSO | Boot-LSTM-ICSO | BELM-ICSO-PP |
| W/Sun    | 90     | 184%    | 95%  | 44%       | 26%           | 21%            | 16%          |
|          | 95     | 165%    | 56%  | 38%       | 26%           | 10%            | 15%          |
|          | 99     | 226%    | 49%  | 24%       | 14%           | 1%             | 23%          |
| W/LC     | 90     | 147%    | 82%  | 34%       | 19%           | 17%            | 8%           |
|          | 95     | 24%     | 47%  | 25%       | 15%           | 4%             | 1%           |
|          | 99     | 58%     | 35%  | 28%       | 14%           | 8%             | 19%          |
| W/HC     | 90     | 252%    | 171% | 132%      | 109%          | 73%            | 90%          |
|          | 95     | 205%    | 129% | 85%       | 71%           | 48%            | 65%          |
|          | 99     | 189%    | 67%  | 38%       | 29%           | 15%            | 38%          |
| S/Sun    | 90     | 158%    | 75%  | 45%       | 21%           | 19%            | -3%          |
|          | 95     | 135%    | 68%  | 39%       | 20%           | 10%            | 3%           |
|          | 99     | 116%    | 55%  | 52%       | 25%           | 8%             | -10%         |
| S/LC     | 90     | 263%    | 208% | 185%      | 155%          | 92%            | 57%          |
|          | 95     | 194%    | 185% | 170%      | 130%          | 72%            | 39%          |
|          | 99     | 170%    | 73%  | 70%       | 38%           | 9%             | 11%          |
| S/HC     | 90     | 230%    | 189% | 86%       | 62%           | 48%            | 69%          |
|          | 95     | 230%    | 151% | 120%      | 51%           | 48%            | 67%          |
|          | 99     | 127%    | 84%  | 66%       | 43%           | 24%            | 29%          |

## 6.7 Εποχική ανάλυση και σύγκριση αποδοτικότητας σφαλμάτων πρόβλεψης

Με στόχο την επιβεβαίωση της αποτελεσματικότητας και της ακρίβειας του προτεινόμενου μοντέλου, η απόδοσή του συγκρίνεται με διάφορες μεθοδολογίες πιθανοτικής πρόβλεψης φωτοβολταϊκής παραγωγής. Τα επιλεγμένα μοντέλα αναφοράς είναι το απλό μοντέλο LSTM καθώς και το μοντέλο BELM το οποίο έχει αποτελέσει το επίκεντρο της προσοχής για την πρόβλεψη φωτοβολταϊκών τα τελευταία χρόνια. Ο απλός CSO και ο βελτιωμένος αλγόριθμος CSO εφαρμόστηκαν στη συνέχεια στο απλό LSTM. Τέλος, ο μηχανισμός θηράματος-θηρευτή προστέθηκε στους αλγόριθμους CSO και ICSO. Έτσι, συγκρίνονται επτά μοντέλα: 1) LSTM, 2) Boot-LSTM, 3) Boot-LSTM-CSO, 4) Boot-LSTM-ICSO, 5) BELM, 6) BELM-CSO-PP και 7) το προτεινόμενο μοντέλο Boot-LSTM-ICSO-PP.

**Πίνακας 6.4** Ελαχιστοποίηση του CWC από επτά διαφορετικά μοντέλα για το ΦΒ Πάρκο2.

| Test day | CL (%) | CWC (%) |        |           |               |                |              |                   |
|----------|--------|---------|--------|-----------|---------------|----------------|--------------|-------------------|
|          |        | BELM    | LSTM   | Boot-LSTM | Boot-LSTM-CSO | Boot-LSTM-ICSO | BELM-ICSO-PP | Boot-LSTM-ICSO-PP |
| W/Sun    | 90     | 0,4423  | 0,3624 | 0,2425    | 0,2397        | 0,2031         | 0,1943       | 0,2006            |
|          | 95     | 0,6481  | 0,3812 | 0,3318    | 0,3006        | 0,2845         | 0,2342       | 0,2212            |
|          | 99     | 0,5627  | 0,4039 | 0,3648    | 0,3394        | 0,3036         | 0,2610       | 0,2118            |
| W/LC     | 90     | 0,5608  | 0,5326 | 0,5123    | 0,4936        | 0,4730         | 0,4355       | 0,3847            |
|          | 95     | 0,8893  | 0,5536 | 0,4982    | 0,4637        | 0,4249         | 0,3972       | 0,3514            |
|          | 99     | 2,8967  | 0,5782 | 0,5279    | 0,4863        | 0,4312         | 0,3832       | 0,3177            |
| W/HC     | 90     | 0,4372  | 0,3932 | 0,3862    | 0,3698        | 0,3701         | 0,3742       | 0,3699            |
|          | 95     | 0,4699  | 0,4039 | 0,3211    | 0,2965        | 0,2742         | 0,2512       | 0,2075            |
|          | 99     | 0,7074  | 0,4428 | 0,4216    | 0,3986        | 0,3608         | 0,3260       | 0,2907            |
| S/Sun    | 90     | 0,3001  | 0,2813 | 0,2568    | 0,2412        | 0,2143         | 0,1759       | 0,1714            |
|          | 95     | 0,3474  | 0,3287 | 0,2989    | 0,2741        | 0,2408         | 0,2177       | 0,1869            |
|          | 99     | 0,5075  | 0,3308 | 0,3133    | 0,2813        | 0,2589         | 0,2269       | 0,1930            |
| S/LC     | 90     | 0,3856  | 0,3791 | 0,3574    | 0,3411        | 0,3126         | 0,3012       | 0,2765            |
|          | 95     | 0,3933  | 0,4017 | 0,3593    | 0,3048        | 0,3153         | 0,2769       | 0,2281            |
|          | 99     | 0,4517  | 0,4396 | 0,3965    | 0,3436        | 0,3244         | 0,2996       | 0,2573            |
| S/HC     | 90     | 0,4485  | 0,4296 | 0,3826    | 0,3566        | 0,3278         | 0,2987       | 0,1988            |
|          | 95     | 0,5043  | 0,4642 | 0,4199    | 0,4024        | 0,3961         | 0,3408       | 0,2986            |
|          | 99     | 0,8261  | 0,4719 | 0,4573    | 0,4126        | 0,4055         | 0,3802       | 0,3574            |

Όπως προκύπτει από τους Πίνακες 6.2 - 6.5, το προτεινόμενο μοντέλο ξεπερνά τα μοντέλα σύγκρισης όσον αφορά την ελαχιστοποίηση της συνάρτησης CWC. Λαμβάνοντας υπόψη την εφαρμογή του αλγορίθμου θηράματος-θηρευτή, διαπιστώνεται ότι βελτιώνει τα αποτελέσματα της ελαχιστοποίησης της συνάρτησης CWC στην πλειονότητα των περιπτώσεων. Επιπλέον, μπορεί να φανεί ότι σε περιπτώσεις συνεφιασμένων ημερών (ελαφρών ή βαριών), η βελτίωση των αποτελεσμάτων της CWC είναι σημαντικά καλύτερη από ότι σε περιπτώσεις ηλιόλουστων ημερών όπου η βελτίωση είναι ελαφρώς μικρότερη. Αυτό είναι αναμενόμενο καθώς είναι πολύ πιο εύκολο να προβλεφθεί η φωτοβολταϊκή ισχύς τις ηλιόλουστες ημέρες και, ως εκ τούτου, οι απλές μέθοδοι θα δίνουν ήδη αρκετά καλά αποτελέσματα, χωρίς βαθιά βελτιστοποίηση.


Επιπλέον, ενώ δεν επικεντρώνεται στο αιτιοκρατικό στάδιο της προτεινόμενης μεθοδολογίας, μια αναπαράσταση του σταδίου αιτιοκρατικής πρόβλεψης θα πρέπει να αποδεικνύει περαιτέρω την εγκυρότητα των δεδομένων εισόδου του πιθανοτικού μοντέλου πρόβλεψης καθώς και την ποιότητα των αιτιοκρατικών προβλέψεων συνολικά. Το Σχήμα 6.4 παρουσιάζει διαφορετικά γραφήματα παλινδρόμησης των αιτιοκρατικών προβλέψεων για έξι διαφορετικές περιπτώσεις, μία για μια ηλιόλουστη ημέρα, μία για μια ελαφριά συνεφιασμένη

**Πίνακας 6.5** Σύγκριση του CWC έξι μοντέλων, σε σχέση με το CWC του προτεινόμενου μοντέλου Boot-LSTM-ICSO-PP, για το ΦΒ Πάρκο 2.

| Test day | CL (%) | CWC (%) |      |           |               |                |              |
|----------|--------|---------|------|-----------|---------------|----------------|--------------|
|          |        | BELM    | LSTM | Boot-LSTM | Boot-LSTM-CSO | Boot-LSTM-ICSO | BELM-ICSO-PP |
| W/Sun    | 90     | 120%    | 81%  | 21%       | 19%           | 1%             | -3%          |
|          | 95     | 193%    | 72%  | 50%       | 36%           | 29%            | 6%           |
|          | 99     | 166%    | 91%  | 72%       | 60%           | 43%            | 23%          |
| W/LC     | 90     | 46%     | 38%  | 33%       | 28%           | 23%            | 13%          |
|          | 95     | 153%    | 58%  | 42%       | 32%           | 21%            | 13%          |
|          | 99     | 812%    | 82%  | 66%       | 53%           | 36%            | 21%          |
| W/HC     | 90     | 18%     | 6%   | 4%        | 0%            | 0%             | 1%           |
|          | 95     | 126%    | 95%  | 55%       | 43%           | 32%            | 21%          |
|          | 99     | 143%    | 52%  | 45%       | 37%           | 24%            | 12%          |
| S/Sun    | 90     | 75%     | 64%  | 50%       | 41%           | 25%            | 3%           |
|          | 95     | 86%     | 76%  | 60%       | 47%           | 29%            | 16%          |
|          | 99     | 163%    | 71%  | 62%       | 46%           | 34%            | 18%          |
| S/LC     | 90     | 39%     | 37%  | 29%       | 23%           | 13%            | 9%           |
|          | 95     | 72%     | 76%  | 58%       | 34%           | 38%            | 21%          |
|          | 99     | 76%     | 71%  | 54%       | 34%           | 26%            | 16%          |
| S/HC     | 90     | 126%    | 116% | 92%       | 79%           | 65%            | 50%          |
|          | 95     | 69%     | 55%  | 41%       | 35%           | 33%            | 14%          |
|          | 99     | 131%    | 32%  | 28%       | 15%           | 13%            | 6%           |

ημέρα και μία για μια βαριά συννεφιασμένη ημέρα για το Πάρκο1 και το Πάρκο2. Φαίνεται ότι οι προβλεπόμενες αιτιοκρατικές τιμές παρουσιάζουν υψηλή συσχέτιση με τις πραγματικές τιμές, γεγονός που εκτός από τις διαγραμματικές απεικονίσεις επιβεβαιώνεται και από τις μετρικές τιμές MAE (<5%) και RMSE (<7%) για το Πάρκο1 ενώ οι αντίστοιχες τιμές για το Πάρκο2 είναι <6.5% και <7.5%. Ελαφρώς καλύτερα αποτελέσματα αναμένονται για το ΦΒ Πάρκο1, καθώς ο μεγαλύτερος όγκος πληροφοριών που παρέχει, λόγω του χρονικού βήματος του ενός λεπτού, προσφέρει καλύτερες δυνατότητες εκπαίδευσης στο μοντέλο πρόβλεψης. Επίσης, συμπεραίνεται ότι οι συσχετιζόμενες τιμές ευθυγραμμίζονται καλύτερα στην περίπτωση ηλιόλουστων ημερών από ότι στην περίπτωση συννεφιασμένων ημερών.

Επιπλέον, στην περίπτωση ημερών με ελαφριά συννεφιά, οι συσχετιζόμενες τιμές δείχνουν χαμηλότερη διασπορά για τιμές πλησιέστερες στη μηδενική φωτοβολταϊκή παραγωγή, καθώς και την ονομαστική τιμή παραγωγής ισχύος και υψηλότερη διασπορά για ενδιάμεσες τιμές· ενώ για τις ημέρες με έντονη συννεφιά οι συσχετισμένες τιμές δείχνουν χαμηλότερη διασπορά για τιμές πιο κοντά στη μηδενική φωτοβολταϊκή παραγωγή. Τα παραπάνω είναι αναμενόμενα



**Σχήμα 6.4** Αναπαράστασης παλινδρόμησης αιτιοκρατικής πρόβλεψης για: (α) μια ηλιόλουστη ημέρα, (β) μια ημέρα με ελαφριά συννεφιά και (γ) μια βαριά συννεφιασμένη ημέρα, για το ΦΒ Πάρκο1 και (δ) μια ηλιόλουστη ημέρα, (ε) μια ημέρα με ελαφριά συννεφιά και (στ) μια βαριά συννεφιασμένη ημέρα, για το ΦΒ Πάρκο2.

λαμβάνοντας υπόψη την επίδραση της μεταβλητότητας των νεφών κατά τη διάρκεια της ημέρας, καθώς οι προβλέψεις τείνουν να είναι πιο ακριβείς σε περιπτώσεις παραγωγής πιο κοντά στην ονομαστική τιμή παραγωγής (καθαρός ουρανός) ή περιπτώσεις πολύ χαμηλής ή ακόμη και καθόλου παραγωγής (νύχτα ή ώρα πιο κοντά στη δύση ή την αυγή). Αυτό επιβεβαιώνεται περαιτέρω από το διάγραμμα παλινδρόμησης ηλιόλουστης ημέρας όπου οι συσχετισμένες τιμές δείχνουν ελάχιστη διασπορά. Τα παραπάνω συμπεράσματα μπορούν να φανούν καλύτερα στα Σχήματα 6.4α, 6.4β και 6.4γ, δεδομένου ότι το ΦΒ Πάρκο1 έχει ένα χρονικό βήμα ενός λεπτού και επομένως τα διαγράμματα αντιπροσωπεύουν μεγαλύτερο αριθμό δεδομένων παλινδρόμησης. Ωστόσο, στην περίπτωση του ΦΒ Πάρκου2, παρατηρείται παρόμοια εικόνα, αν και σε μικρότερη κλίμακα. Τα δεδομένα παλινδρόμησης που απεικονίζονται στη διασπορά είναι καλύτερα ευθυγραμμισμένα στην περίπτωση της ηλιόλουστης ημέρας, ενώ για τις συννεφιασμένες ημέρες, οι συσχετιζόμενες τιμές δείχνουν χαμηλότερη διασπορά για τιμές πιο κοντά στη μηδενική φωτοβολταϊκή παραγωγή και την ονομαστική παραγωγή και υψηλότερη διασπορά για τις ενδιάμεσες τιμές.

Από τους Πίνακες 6.2 - 6.5 επίσης διαπιστώνεται ότι το προτεινόμενο μοντέλο λειτουργεί καλύτερα σε περιπτώσεις ημερών με ελαφριά και βαριά συννεφιά. Το προτεινόμενο μοντέλο, όντας βασισμένο στο LSTM, είναι σε θέση να καταγράψει τις διαδοχικές εξαρτήσεις στα δεδομένα. Επιπλέον, χάρη στην ικανότητα αναδειγματοληψίας και τη διαδοχική αρχιτεκτονική, είναι σε θέση να εντοπίσει και να εκμεταλλευτεί τη σχέση μεταξύ των δεδομένων εισόδου και των δεδομένων ηλιακής ενέργειας που είναι φαινόμενα εξαιρετικά μη γραμμικά και πολύπλοκα. Επιπλέον, υπάρχουν περιπτώσεις όπου το μοντέλο BELM-ICSO-PP είναι ίσο ή ελαφρώς καλύτερο από το προτεινόμενο μοντέλο, όπως φαίνεται στους Πίνακες 6.2 - 6.5 για την καλοκαιρινή ηλιόλουστη ημέρα και σαφέστερα και στις δύο περιπτώσεις ηλιόλουστης ημέρας

**Πίνακας 6.6** Συγκριτικά αποτελέσματα κατασκευής διαστημάτων πρόβλεψης.

| Πάρκο | PINC | Μετρητικό σφάλματος | Μοντέλο Πρόβλεψης |        |           |               |                |              |                   |
|-------|------|---------------------|-------------------|--------|-----------|---------------|----------------|--------------|-------------------|
|       |      |                     | BELM              | LSTM   | Boot-LSTM | Boot-LSTM-CSO | Boot-LSTM-ICSO | BELM-ICSO-PP | Boot-LSTM-ICSO-PP |
| 1     | 0,90 | PICP                | 0,9672            | 0,9203 | 0,9431    | 0,9395        | 0,9141         | 0,9132       | 0,9089            |
|       | 0,95 |                     | 0,9701            | 0,9662 | 0,9739    | 0,9702        | 0,9685         | 0,9602       | 0,9514            |
|       | 0,99 |                     | 0,9987            | 0,9953 | 0,9968    | 0,9927        | 0,9936         | 0,9927       | 0,9935            |
|       | 0,90 | PINAW               | 0,5094            | 0,3909 | 0,2014    | 0,1659        | 0,1762         | 0,1627       | 0,1237            |
|       | 0,95 |                     | 0,4970            | 0,4282 | 0,2751    | 0,2203        | 0,2156         | 0,2093       | 0,1948            |
|       | 0,99 |                     | 0,6207            | 0,4603 | 0,3636    | 0,3394        | 0,3461         | 0,2890       | 0,2671            |
| 2     | 0,90 | PICP                | 0,9364            | 0,9087 | 0,9217    | 0,9199        | 0,9123         | 0,8813       | 0,9067            |
|       | 0,95 |                     | 0,9762            | 0,9598 | 0,9731    | 0,9688        | 0,9714         | 0,9610       | 0,9533            |
|       | 0,99 |                     | 1,0000            | 0,9962 | 1,0000    | 1,0000        | 1,0000         | 1,0000       | 1,0000            |
|       | 0,90 | PINAW               | 0,4398            | 0,3862 | 0,3233    | 0,2945        | 0,2682         | 0,2547       | 0,2317            |
|       | 0,95 |                     | 0,4871            | 0,4028 | 0,3479    | 0,3428        | 0,2987         | 0,2901       | 0,2763            |
|       | 0,99 |                     | 0,6351            | 0,4412 | 0,4123    | 0,3962        | 0,4018         | 0,3218       | 0,3132            |

στους Πίνακες 6.3 και 6.5. Τέτοιες περιπτώσεις παρατηρούνται κυρίως σε παραδείγματα καλοκαιρινών ημερών όπου τα δεδομένα εκπαίδευσης είναι πιο σταθερά και παρουσιάζουν χαμηλή μεταβλητότητα. Θα πρέπει επίσης να σημειωθεί ότι το Boot-LSTM είναι σε θέση να επωφεληθεί από τις ενδοημερήσιες σημειακές προβλέψεις του προτεινόμενου μοντέλου. Σε περιπτώσεις όπου οι ενδοημερήσιες σημειακές προβλέψεις δεν ακολουθούν την αναμενόμενη καμπύλη φωτοβολταϊκής παραγωγής (όπως περιπτώσεις κακοκαιρίας), το προτεινόμενο μοντέλο είναι ικανό να τις αξιοποιήσει με αποδοτικότερο τρόπο, προκειμένου να αξιολογήσει καλύτερα τις διακυμάνσεις της επόμενης ημέρας. Αυτό παρουσιάζεται σαφώς στους Πίνακες 6.2 - 6.5, όπου τα αποτελέσματα για τη συνάρτηση CWC του προτεινόμενου μοντέλου είναι σημαντικά καλύτερα από τα συγκρίσιμα μοντέλα. Από την άλλη, το BELM δεν λαμβάνει υπόψη προηγούμενες τιμές στην τελική εκτίμηση και, ως εκ τούτου, δεν εκμεταλλεύεται τις προβλέψεις εντός της ώρας για να βελτιώσει περαιτέρω το τελικό σφάλμα πρόβλεψης.

Το προτεινόμενο μοντέλο φαίνεται να ανταποκρίνεται καλύτερα σε ημέρες με βαριά σύννεφα παρά σε ημέρες ελαφριάς νέφωσης. Αυτό θα μπορούσε να είναι το αποτέλεσμα της υψηλής διακύμανσης των ημερών ελαφρών σύννεφων, σε σύγκριση με τις ημέρες βαριάς συννεφιάς, και της επίδρασης στην εξάρτηση των φωτοβολταϊκών συλλεκτών από τις συνεχείς αλλαγές θερμοκρασίας κατά τη διάρκεια των ημερών ελαφριάς συννεφιάς.


Τα αποτελέσματα που παρουσιάζονται στους Πίνακες 6.6 και 6.7 δείχνουν την υπεροχή του προτεινόμενου μοντέλου όσον αφορά την ακρίβεια κατασκευής διαστημάτων πρόβλεψης. Ενώ τα αποτελέσματα για τα άλλα μοντέλα είναι κοντά στο PINC, στην περίπτωση του προτεινόμενου μοντέλου, μπορεί να διαπιστωθεί ότι οι τιμές PICP είναι εξαιρετικά κοντά στις

**Πίνακας 6.7** Σύγκριση των τιμών τεσσάρων μετρητικών σφάλματος για την κατασκευή των διαστημάτων πρόβλεψης που υπολογίζονται από έξι διαφορετικές μεθόδους, σε σχέση με τις τιμές αυτών των τεσσάρων μετρητικών σφάλματος που υπολογίζονται από το προτεινόμενο μοντέλο Boot-LSTM-ICSO-PP.

| Πάρκο | PINC | Μετρητικό σφάλματος | Μοντέλο Πρόβλεψης |      |           |                |                |              |
|-------|------|---------------------|-------------------|------|-----------|----------------|----------------|--------------|
|       |      |                     | BELM              | LSTM | Boot-LSTM | Boot-LSTM-ICSO | Boot-LSTM-ICSO | BELM-ICSO-PP |
| 1     | 0,90 | PICP                | 6%                | 1%   | 4%        | 3%             | 1%             | 0%           |
|       | 0,95 |                     | 2%                | 2%   | 2%        | 2%             | 2%             | 1%           |
|       | 0,99 |                     | 1%                | 0%   | 0%        | 0%             | 0%             | 0%           |
|       | 0,90 | PINAW               | 312%              | 216% | 63%       | 34%            | 42%            | 32%          |
|       | 0,95 |                     | 155%              | 120% | 41%       | 13%            | 11%            | 7%           |
|       | 0,99 |                     | 132%              | 72%  | 36%       | 27%            | 30%            | 8%           |
| 2     | 0,90 | PICP                | 3%                | 0%   | 2%        | 1%             | 1%             | -3%          |
|       | 0,95 |                     | 2%                | 1%   | 2%        | 2%             | 2%             | 1%           |
|       | 0,99 |                     | 0%                | 0%   | 0%        | 0%             | 0%             | 0%           |
|       | 0,90 | PINAW               | 90%               | 67%  | 40%       | 27%            | 16%            | 10%          |
|       | 0,95 |                     | 76%               | 46%  | 26%       | 24%            | 8%             | 5%           |
|       | 0,99 |                     | 103%              | 41%  | 32%       | 27%            | 28%            | 3%           |

τιμές PINC τόσο για χειμερινές όσο και για θερινές περιπτώσεις και για όλα τα επίπεδα εμπιστοσύνης. Επιπλέον, τα καλύτερα αποτελέσματα PINAW για το προτεινόμενο μοντέλο σε όλες τις περιπτώσεις δοκιμής που παρουσιάζονται δείχνουν την υπεροχή του προτεινόμενου μοντέλου όσον αφορά την ακρίβεια.

Μια οπτικοποίηση των αποτελεσμάτων που περιλαμβάνουν τα κατασκευασμένα διαστήματα πρόβλεψης καθώς και μια ενδοωριαία εκτιμώμενη απόδοση ισχύος για διαφορετικές μετεωρολογικές περιπτώσεις τόσο για το Πάρκο1 όσο και για το Πάρκο2 παρουσιάζεται στο Σχήμα 6.5. Η αιτιοκρατική πρόβλεψη είναι πολύτιμη για τον βραχυπρόθεσμο επιχειρησιακό σχεδιασμό, ενώ η πιθανοτική πρόβλεψη είναι σε θέση να καλύψει περιπτώσεις δυναμικού και αβέβαιου πλαισίου. Τα διαστήματα πρόβλεψης είναι απλά στην ερμηνεία και προσφέρουν ποιοτικές πληροφορίες αβεβαιότητας στους υπεύθυνους λήψης αποφάσεων. Επιπλέον, η δημιουργία διαστημάτων πρόβλεψης επόμενης ημέρας επιτρέπει τη βελτιστοποίηση εργασιών στα συστήματα ηλεκτρικής ενέργειας, όπως η οικονομική κατανομή επόμενης ημέρας ή η δέσμευση μονάδων, οδηγώντας σε μεγαλύτερη ευελιξία. Τέλος, η εξέταση αιτιοκρατικών εκτιμήσεων εντός της ώρας θα μπορούσε να διευκολύνει περαιτέρω τους υπεύθυνους λήψης αποφάσεων, όχι μόνο στο να έχουν μια πιο εμπεριστατωμένη εικόνα της εξέλιξης των αποτελεσμάτων του μοντέλου πρόβλεψης, αλλά και στην κατανόηση και αυτοεπικύρωση της ακρίβειας των διαστημάτων πρόβλεψης που κατασκευάζονται από τις πιθανοτικές εκτιμήσεις.



**Σχήμα 6.5** Απεικόνιση κατασκευασμένων διαστημάτων πρόβλεψης και προβλεπόμενης απόδοσης ισχύος επόμενης ημέρας για: (α) μια ηλιόλουστη ημέρα, (β) μια ημέρα με ελαφριά συννεφιά και (γ) μια βαριά συννεφιασμένη ημέρα, για το φωτοβολταϊκό πάρκο1 και (δ) μια ηλιόλουστη ημέρα, (ε) μια ημέρα με ελαφριά συννεφιά και (στ) μια βαριά συννεφιασμένη ημέρα, για το ΦΒ πάρκο2. Σύγκριση με πραγματικές καμπύλες ισχύος.

Το Σχήμα 6.5 αποτυπώνει αποτελεσματικά τη σταθερότητα και την προσαρμοστικότητα του προτεινόμενου μοντέλου. Είναι σαφές ότι οι περιπτώσεις 6.5 (α), 6.5 (β) και 6.5 (γ) περιέχουν μεγαλύτερο όγκο δεδομένων από τις περιπτώσεις 6.5 (δ), 6.5 (ε) και 6.5 (στ), δεδομένου ότι το προγνωστικό αποτέλεσμα για το ΦΒ Πάρκο1 έχει χρονικό βήμα ενός λεπτού, ενώ για το ΦΒ Πάρκο2 έχει χρονικό βήμα 15 λεπτών. Ωστόσο, είναι προφανές ότι τα κατασκευασμένα διαστήματα πρόβλεψης περιλαμβάνουν αποτελεσματικά τις προβλεπόμενες χρονοσειρές καθώς και την πραγματική. Επιπλέον, από τις γραμμές πρόβλεψης στο Σχήμα 6.5

**Πίνακας 6.8** Πολυπλοκότητα μοντέλου πρόβλεψης και βελτιστοποίηση των υπερπαραμέτρων και του υπολογιστικού κόστους του μοντέλου.


| ΦΒ Πάρκο1                |                        | ΦΒ Πάρκο2                |                        |                | Παράμετροι βελτιστοποίησης |            | Συνολικές παράμετροι εκπαίδευσης |
|--------------------------|------------------------|--------------------------|------------------------|----------------|----------------------------|------------|----------------------------------|
| Χρόνος εκπαίδευσης (sec) | Χρόνος εκτέλεσης (sec) | Χρόνος εκπαίδευσης (sec) | Χρόνος εκτέλεσης (sec) | Κρυφές μονάδες | Βάρη                       | Μεροληψίες |                                  |
| 949                      |                        | 742                      |                        | 5              | 280                        | 20         | 12000                            |
| 1514                     |                        | 1067                     |                        | 10             | 760                        | 40         | 32000                            |
| 2839                     |                        | 1958                     |                        | 20             | 2320                       | 80         | 96000                            |
| 3934                     | 10.2                   | 3019                     | 8.6                    | 30             | 4680                       | 120        | 192000                           |
| 6109                     |                        | 5318                     |                        | 50             | 11800                      | 200        | 480000                           |
| 8613                     |                        | 7427                     |                        | 70             | 22240                      | 280        | 900800                           |
| 11785                    |                        | 9823                     |                        | 100            | 43600                      | 400        | 1760000                          |

προκύπτει ότι το μοντέλο είναι σε θέση να αποτυπώσει και να εκτιμήσει αποτελεσματικά τις μεταβολές στην κλίση της καμπύλης παραγόμενης ισχύος, σε περιπτώσεις ηλιόλουστου καιρού (κανονικές συνθήκες, εύκολο να προβλεφθούν), καθώς και σε περιπτώσεις νεφελώδους καιρού (υψηλή διακύμανση, πιο δύσκολο να προβλεφθεί).

Όπως απεικονίζεται στον Πίνακα 6.8, από την άποψη της χρονικής απόδοσης, το προτεινόμενο μοντέλο είναι σε θέση να αποδώσει σε αποτελεσματικά χρονικά όρια όσον αφορά την εκπαίδευση καθώς και τον χρόνο εκτέλεσης πρόβλεψης. Λαμβάνοντας υπόψη την εφαρμογή τους σε δεδομένα πραγματικού χρόνου, ο χρόνος εκπαίδευσης των μοντέλων πρόβλεψης ποικίλλει ανάλογα με το μήκος του συνόλου δεδομένων, τον αριθμό των μεταβλητών εισόδου και την πολυπλοκότητα της αρχιτεκτονικής του μοντέλου.

Για να δημιουργηθεί μια βέλτιστη αρχιτεκτονική για το προτεινόμενο μοντέλο όσον αφορά την προγνωστική ακρίβεια και το χαμηλό υπολογιστικό κόστος, η πολυπλοκότητα του μοντέλου αξιολογήθηκε από την απόκριση του μοντέλου σε διαφορετικές κρυφές μονάδες. Όπως φαίνεται στο Σχήμα 6.6, και για τα δύο φωτοβολταϊκά πάρκα, με την αύξηση των κρυφών στρωμάτων του LSTM, ο χρόνος εκπαίδευσης αυξάνεται σημαντικά. Αυτό είναι αναμενόμενο δεδομένου ότι, όπως παρουσιάζεται στον Πίνακα 6.8, με την αύξηση των κρυφών μονάδων, οι παράμετροι του LSTM αυξάνονται αναλογικά, για περισσότερο από 50%. Ως εκ τούτου, μια σημαντική αύξηση του χρόνου εκπαίδευσης είναι αναπόφευκτη. Ωστόσο, είναι προφανές από τα γραφήματα στο Σχήμα 6.6, ότι το προτεινόμενο μοντέλο καταφέρνει να συγκλίνει αποτελεσματικά στη βέλτιστη τιμή CWC πολύ γρήγορα, σε 20 κρυφά στρώματα, αποφεύγοντας την προσφυγή σε υψηλότερους χρόνους εκπαίδευσης και ως εκ τούτου, σε αυξημένο υπολογιστικό κόστος.

Το προτεινόμενο μοντέλο, βελτιστοποιημένο να λειτουργεί σε 20 κρυφά στρώματα LSTM, εκπαιδεύεται σε μέσο χρόνο 47 λεπτών και 19 δευτερολέπτων (2839 sec) για το ΦΒ Πάρκο1 και 32 λεπτών και 38 δευτερολέπτων (1958 sec) για το ΦΒ Πάρκο2, όπως φαίνεται στον Πίνακα 6.8. Θα πρέπει να σημειωθεί ότι μεταξύ 20 και 30 κρυφών στρωμάτων, μια



**Σχήμα 6.6** Απεικόνιση της διαμόρφωσης του χρόνου εκπαίδευσης όσον αφορά την υπολογιστική απόδοση και την ελαχιστοποίηση της CWC για: (α) ΦΒ Πάρκο 1 και (β) ΦΒ Πάρκο 2.

αύξηση 50% στις παραμέτρους εκπαίδευσης οδηγεί σε αύξηση 38,54% του χρόνου εκπαίδευσης για το Πάρκο1 και 52,1% για το Πάρκο2, χωρίς να επιτυγχάνεται σημαντική βελτίωση στην ελαχιστοποίηση της συνάρτησης CWC. Η διαφορά στον χρόνο εκπαίδευσης είναι αναμενόμενη, δεδομένου ότι το σύνολο δεδομένων του ΦΒ Πάρκου1 έχει χρονικό βήμα 1 λεπτό, ενώ το σύνολο δεδομένων του ΦΒ Πάρκου2 έχει χρονικό βήμα 15 λεπτών. Σε γενικές γραμμές, αν και εξαιρετικά ακριβές, το μοντέλο φαίνεται υπολογιστικά εντατικό, λαμβάνοντας υπόψη την εφαρμογή του προηγμένου ICSO κάτω από ένα πιθανοτικό φάσμα. Ωστόσο, εξακολουθεί να παραμένει σε επιτρεπόμενα όρια λειτουργίας, χάρη στη συμβολή του μηχανισμού PP.



# Κεφάλαιο 7

## ΣΥΜΠΕΡΑΣΜΑΤΑ

### 7.1 Σύνοψη της διδακτορικής διατριβής

Στη σύγχρονη εποχή, η συνεχής αύξηση των ενεργειακών αναγκών σε παγκόσμιο επίπεδο αλλά και η ανάγκη αξιοποίησης των Ανανεώσιμων Πηγών Ενέργειας για την παραγωγή ενέργειας κάτω από ένα φιλικό προς το περιβάλλον πλαίσιο, αποτελούν πραγματικό πρόβλημα. Η συνεχώς αυξανόμενη διείσδυση ΑΠΕ στο ηλεκτρικό δίκτυο απαιτεί τη συνεχή ανάπτυξη και εξέλιξη μεθόδων ικανών να εξασφαλίζουν την ευστάθεια και τον έλεγχο του ηλεκτρικού δικτύου. Η πρόβλεψη παραγωγής ενέργειας από ΑΠΕ είναι ένα από πιο αξιόπιστα εργαλεία που επιτρέπουν την εκτίμηση της παραγόμενης ενέργειας από τις επιλεγμένες ΑΠΕ ώστε η διείσδυση στο δίκτυο να επιτυγχάνεται με τον ασφαλέστερο και καλύτερα ελεγχόμενο τρόπο.

Πέραν των κλασικών μοντέλων αιτιοκρατικής πρόβλεψης που χρησιμοποιούνται τα τελευταία χρόνια σε μεγάλο βαθμό, το ερευνητικό ενδιαφέρον έχει κινήσει η κατανόηση και η εκτίμηση της αβεβαιότητας που υπάρχει σε μια διαδικασία πρόβλεψης. Τα μοντέλα πιθανοτικής πρόβλεψης, επιτρέπουν την εκτίμηση της εξέλιξης της αβεβαιότητας της πρόβλεψης σε αντίθεση με τις σημειακές προβλέψεις των αιτιοκρατικών μοντέλων. Αντικείμενο της παρούσας διδακτορικής διατριβής είναι:

- 1) η ανάπτυξη καινοτόμων μοντέλων και μεθοδολογιών πρόβλεψης παραγωγής ενέργειας από ΑΠΕ, και συγκεκριμένα αιολικής και φωτοβολταϊκής παραγωγής
- 2) η αξιολόγηση των προτεινόμενων μοντέλων πρόβλεψης με στόχο τη δυνατότητα αξιοποίησής τους σε πραγματικά προβλήματα πρόβλεψης από ΑΠΕ

Στο πλαίσιο της παρούσας διδακτορικής διατριβής προτείνονται δύο καινοτόμες μέθοδοι βραχυπρόθεσμης, πιθανοτικής πρόβλεψης παραγωγής από αιολικά και φωτοβολταϊκά συστήματα με δύο υβριδικές μεθόδους που συνδυάζουν προηγμένες τεχνικές μηχανικής μάθησης. Επιπλέον εξετάζεται η αξιοποίηση μεταερευνητικών αλγορίθμων βελτιστοποίησης στην εξέλιξη της δυνατότητας των μοντέλων που βασίζονται σε νευρωνικά δίκτυα, να εξελίσσουν και να βελτιώνουν τα προβλεπόμενα αποτελέσματα σε ένα πιθανοτικό πλαίσιο. Ουσιαστικό πρόβλημα που κλήθηκε να αντιμετωπιστεί στην παρούσα διδακτορική διατριβή ήταν η ανάπτυξη μοντέλων πρόβλεψης ικανών να συνδυάζουν υψηλής ποιότητας προβλέψεις παραγόμενης ισχύος, διατηρώντας παράλληλα χαμηλά το υπολογιστικό κόστος του μοντέλου.

Στην παρούσα διδακτορική διατριβή αναπτύσσεται ένα καινοτόμο υβριδικό μοντέλο πρόβλεψης αιολικής παραγωγής ενέργειας βασισμένο στη μέθοδο LUBE προκειμένου να παρέχει αποτελεσματικά και ακριβή διαστήματα πρόβλεψης αιολικής ενέργειας. Ο αλγόριθμος PSO προτάθηκε για τη διαδικασία βελτιστοποίησης, ενώ ο μετασχηματισμός κυματιδίων υιοθετήθηκε για την εκτέλεση της προεπεξεργασίας των δεδομένων εισόδου.

Για την αξιολόγηση του προτεινόμενου μοντέλου πρόβλεψης, γίνεται σύγκριση με την υπερσύγχρονη μέθοδο BELM η οποία αναπτύχθηκε και εφαρμόστηκε στο ίδιο σύνολο δεδομένων. Το προτεινόμενο μοντέλο WT-LUBE-PSO-CWC, κατάφερε να υπερτερήσει του μοντέλου σύγκρισης στην πλειονότητα των δοκιμών. Τα μεμονωμένα αποτελέσματα του προτεινόμενου μοντέλου καθώς και οι χρόνοι εκτέλεσης του μοντέλου αποδεικνύουν ότι μπορεί να εφαρμοστεί με επιτυχία σε πραγματικά προβλήματα πρόβλεψης αιολικής παραγωγής, ανεξάρτητα του μεγέθους των δεδομένων εισόδου ή της τοποθεσίας του αιολικού πάρκου.

Επιπλέον, στην παρούσα διδακτορική διατριβή αναπτύσσεται ένα καινοτόμο, υβριδικό, πιθανοτικό μοντέλο πρόβλεψης φωτοβολταϊκής παραγωγής βασισμένο στο μοντέλο LSTM προκειμένου να κατασκευαστούν αποτελεσματικά, ακριβή διαστήματα πρόβλεψης. Η ικανότητα αναδειγματοληψίας του μηχανισμού Bootstrap αλλά και το πλεονέκτημα του LSTM να συλλαμβάνει τις διαδοχικές εξαρτήσεις αξιοποιήθηκαν με επιτυχία για την κατασκευή ακριβών διαστημάτων πρόβλεψης. Το μοντέλο εκπαιδεύτηκε και βελτιστοποιήθηκε περαιτέρω μέσω μιας βελτιωμένης έκδοσης του αλγορίθμου CSO. Η συμπερίληψη του ICSO επέτρεψε την ταχύτερη και ακριβέστερη σύγκλιση του μοντέλου και, ως εκ τούτου, την υψηλότερη ακρίβεια συνολικά.

Ένας μηχανισμός θηράματος-θηρευτή συμπεριλήφθηκε και προσαρμόστηκε στην αρχιτεκτονική του μοντέλου, προκειμένου να διευκολυνθεί η ικανότητα αναζήτησης των σωματιδίων ICSO και να βελτιωθεί η προγνωστική ακρίβεια και να μειωθεί το υπολογιστικό κόστος.

Δύο διαφορετικά σύνολα δεδομένων χρησιμοποιήθηκαν για να αποδείξουν την ανωτερότητα του προτεινόμενου μοντέλου σε σύγκριση με έξι μοντέλα τελευταίας τεχνολογίας. Τα αποτελέσματα επιβεβαιώνουν της ανωτερότητα του προτεινόμενου μοντέλου στην πλειονότητα των περιπτώσεων όσον αφορά τα μετρητικά αξιολόγησης. Η ενσωμάτωση του ICSO στην προτεινόμενη bootstrapped έκδοση του μοντέλου LSTM και η περαιτέρω εφαρμογή του μηχανισμού θηράματος-θηρευτή, αποδεικνύονται απαραίτητα όσον αφορά τη βελτίωση της ακρίβειας πρόβλεψης, ειδικά σε περιπτώσεις δύσκολων προβλεπόμενων ημερών (ημέρες ελαφριάς και βαριάς συννεφιάς). Ως αποτέλεσμα, το προτεινόμενο μοντέλο θα μπορούσε να συμβάλει στη βέλτιστη ενσωμάτωση της ηλιακής ενέργειας στα συστήματα ηλεκτρικής ενέργειας και στην εφαρμογή της σε πραγματικά προβλήματα.

## 7.2 Συμβολή της διδακτορικής διατριβής

Η παρούσα διδακτορική διατριβή, αναπτύσσοντας πρωτότυπα μοντέλα πρόβλεψης της αιολικής και φωτοβολταϊκής παραγωγής, συμβάλλει σημαντικά στη διείσδυση της αιολικής και φωτοβολταϊκής παραγωγής στα συστήματα ηλεκτρικής ενέργειας.

Τα σημαντικότερα σημεία στα οποία συμβάλλει η παρούσα διδακτορική διατριβή στην περιοχή του αντικειμένου της, περιγράφονται συνοπτικά ως εξής:

- Στον τομέα της πρόβλεψης παραγωγής ενέργειας από αιολικά συστήματα:
  - Εισάγει μια καινοτόμο μεθοδολογία πρόβλεψης αιολικής παραγωγής βασισμένη σε σύγχρονες τεχνικές μηχανικής μάθησης, ικανή να δίνει υψηλής ποιότητας εκτιμήσεις παραγόμενης ισχύος υπό μορφή διαστημάτων πρόβλεψης, κάτω από ένα πιθανοτικό πλαίσιο.
  - Καταφέρνει να εμπλουτίσει το παραπάνω μοντέλο με έναν βελτιωμένο μεταερευτικό αλγόριθμο βελτιστοποίησης διατηρώντας σε ρεαλιστικά πλαίσια τους χρόνους εκτέλεσης του μοντέλου, ενώ παράλληλα βελτιώνει σημαντικά τα σφάλματα πρόβλεψης.
  - Προτείνει ένα έξυπνο εργαλείο πρόβλεψης, ικανό να εφαρμοστεί σε πραγματικά προβλήματα πρόβλεψης αιολικής ισχύος.
- Στον τομέα της πρόβλεψης παραγωγής ενέργειας από φωτοβολταϊκά συστήματα:
  - Προτείνει ένα καινοτόμο, υβριδικό μοντέλο πιθανοτικής πρόβλεψης φωτοβολταϊκής παραγωγής βασισμένη σε σύγχρονες τεχνικές μηχανικής μάθησης. Το μοντέλο είναι ικανό να κατασκευάσει υψηλής ποιότητας διαστήματα πρόβλεψης, εφαρμοσμένο σε σύνολο δεδομένων πραγματικών φωτοβολταϊκών πάρκων.
  - Καταφέρνει να ενσωματώσει με επιτυχία έναν υψηλής πολυπλοκότητας μεταερευτικό αλγόριθμο βελτιστοποίησης, χωρίς να αυξάνει το υπολογιστικό κόστος καθώς και έναν έξυπνο μηχανισμό διεύρυνσης της δυνατότητας αναζήτησης της βέλτιστης πρόβλεψης.

### 7.3 Μελλοντικές επεκτάσεις

Η παρούσα διδακτορική διατριβή μπορεί να αποτελέσει τη βάση για περαιτέρω έρευνα στο αντικείμενο της βραχυπρόθεσμης πρόβλεψης παραγωγής ενέργειας από συστήματα ανανεώσιμων πηγών ενέργειας.

Ενδεικτικά, αναφέρονται οι ακόλουθες, ιδιαίτερα ενδιαφέρουσες, κατευθύνσεις επέκτασης της παρούσας διδακτορικής διατριβής:

- Επέκταση του προτεινόμενου μοντέλου πρόβλεψης αιολικής παραγωγής, προκειμένου να αναδειχθεί περαιτέρω η αποτελεσματικότητά του σε προβλήματα πραγματικής ζωής, ώστε να αναπτυχθεί μια μεθοδολογία βελτιστοποίησης πολλαπλών στόχων. Η εστίαση στην επεξεργασία πολυκριτηριακών προβλημάτων βελτιστοποίησης από διαφορετικά ερευνητικά πεδία και η προσαρμογή τους για την αντιμετώπιση προβλημάτων πρόβλεψης αιολικής ενέργειας, θα μπορούσε να αποτελέσει επέκταση της προτεινόμενης μεθοδολογίας.

- Η εφαρμογή του μοντέλου πρόβλεψης φωτοβολταϊκής παραγωγής σε ένα πληρέστερο σύστημα ηλεκτρικής ενέργειας θα μπορούσε να αξιολογήσει περαιτέρω την απόδοσή του σε συστήματα μεγαλύτερης κλίμακας και επίσης να διερευνήσει τη χρησιμότητα της ταυτόχρονης παραγωγής αιτιοκρατικών και πιθανοτικών προβλέψεων.
- Η εφαρμογή του μοντέλου πρόβλεψης φωτοβολταϊκής παραγωγής σε ένα σύνολο δεδομένων που περιλαμβάνει δεδομένα από δορυφορικές εικόνες θα μπορούσε να βελτιώσει περαιτέρω τη συνολική ακρίβεια του προτεινόμενου μοντέλου.
- Σύγχρονες έρευνες έχουν αναδείξει τη σημασία της χωροχρονικής συσχέτισης μεταξύ διαφορετικών συνόλων δεδομένων, τόσο στην περίπτωση των αιολικών πάρκων όσο και στην περίπτωση φωτοβολταϊκών πάρκων, προκειμένου να παρέχονται πιο αποτελεσματικά μοντέλα πρόβλεψης. Η αξιοποίηση διαφορετικών ιστορικών ή μετεωρολογικών δεδομένων από διαφορετικά αιολικά ή φωτοβολταϊκά πάρκα θα μπορούσε να αυξήσει τον αριθμό των δεδομένων και, κατά συνέπεια, να βελτιώσει την ακρίβεια του προτεινόμενου μοντέλου.
- Λαμβάνοντας υπόψη ότι η «πράσινη πληροφορική» γίνεται όλο και πιο σημαντική, η διερεύνηση μεθόδων για τη μείωση της πολυπλοκότητας των μοντέλων πρόβλεψης, διατηρώντας παράλληλα τα υψηλά πρότυπα ακρίβειάς τους, θα είχε επίσης ερευνητικό ενδιαφέρον.

## Δημοσιεύσεις του Συγγραφέα

### A. Δημοσιεύσεις σχετικές με τη διδακτορική διατριβή

#### A1. Σε διεθνή επιστημονικά περιοδικά με κριτές

[Π1] **I. K. Bazionis**, M. A. Kousounadis-Knousen, V. E. Katsigiannis, F. Catthoor and P. S. Georgilakis, “An Advanced Hybrid Boot-LSTM-ICSO-PP Approach for Day-Ahead Probabilistic PV Power Yield Forecasting and Intra-hour Power Fluctuation Estimation,” *IEEE Access*, vol. 12, pp. 43704–43720, Mar. 2024. DOI: <https://doi.org/10.1109/ACCESS.2024.3381049>.

- Impact Factor = 3,4
- Citations (2 Nov. 2024) = 2

[Π2] **I. K. Bazionis**, M. A. Kousounadis-Knousen, T. Konstantinou and P. S. Georgilakis, “A WT-LUBE-PSO-CWC Wind Power Probabilistic Forecasting Model for Prediction Interval Construction and Seasonality Analysis,” *Energies*, vol. 14, no. 18, Sept. 2021. DOI: <https://doi.org/10.3390/en14185942>

- Impact Factor = 3,0
- Citations (2 Nov. 2024) = 3

[Π3] **I. K. Bazionis** and P. S. Georgilakis, “Review of Deterministic and Probabilistic Wind Power Forecasting: Models, Methods, and Future Research,” *Electricity*, vol. 2, no. 1, pp. 13–47, Jan. 2021. DOI: <https://doi.org/10.3390/electricity2010002>

- Tracked for Impact Factor.
- Citations (2 Nov. 2024) = 94

[Π4] **I. K. Bazionis**, P. A. Karafotis, and P. S. Georgilakis, “A review of short-term wind power probabilistic forecasting and a taxonomy focused on input data,” *IET Renewable Power Generation*, vol. 16, no. 1, pp. 77–91, Jan. 2022. DOI: <https://doi.org/10.1049/rpg2.12330>

- Impact Factor = 2,6
- Citations (2 Nov. 2024) = 19

[Π5] **I. K. Bazionis**, M. A. Kousounadis-Knousen, P. S. Georgilakis, E. Shirazi, D. Soudris, and F. Catthoor “A taxonomy of short-term solar power forecasting: Classifications focused on climatic conditions and input data,” *IET Renewable Power Generation*, vol. 17, no. 9, pp. 2411–2432, Jul. 2023. DOI: <https://doi.org/10.1049/rpg2.12736>

- Impact Factor = 2,6
- Citations (2 Nov. 2024) = 7

**A2. Σε διεθνή επιστημονικά συνέδρια με κριτές**

- [Σ1] **I. K. Bazionis**, P. A. Karafotis, and P. S. Georgilakis, “A comprehensive review in wind power probabilistic forecasting,” in *2020 IET MEDPOWER*, Paphos, Cyprus, Nov. 2020. DOI: <https://doi.org/10.1049/icp.2021.1263>
- [Σ2] **I. K. Bazionis**, M. A. Kousounadis-Knousen, A. P. Georgilaki, and P. S. Georgilakis, “LSTM-based hybrid approaches for short-term photovoltaic power forecasting,” in *2024 IET MEDPOWER*, Athens, Greece, Nov. 2024.

**B. Δημοσιεύσεις εκτός πλαισίου διδακτορικής διατριβής****B1. Σε διεθνή επιστημονικά περιοδικά με κριτές**

- [Π6] M. A. Kousounadis-Knousen, **I. K. Bazionis**, D. Soudris, F. Catthoor, and P. S. Georgilakis, “A New Co-Optimized Hybrid Model Based on Multi-Objective Optimization for Probabilistic Wind Power Forecasting in a Spatio-Temporal Framework,” *IEEE Access*, vol. 11, pp. 84885–84899, Aug. 2023. DOI: <https://doi.org/10.1109/ACCESS.2023.3302701>
- Impact Factor = 3,4
  - Citations (2 Nov. 2024) = 3
- [Π7] M. A. Kousounadis-Knousen, **I. K. Bazionis**, A. P. Georgilaki, F. Catthoor, and P. S. Georgilakis, “A Review of Solar Power Scenario Generation Methods with Focus on Weather Classifications, Temporal Horizons, and Deep Generative Models,” *Energies*, vol. 14, no. 18, Sept. 2021. DOI: <https://doi.org/10.3390/en16155600>
- Impact Factor = 3,0
  - Citations (2 Nov. 2024) = 4

**B2. Σε διεθνή επιστημονικά συνέδρια με κριτές**

- [Σ3] P. A. Karafotis, **I. K. Bazionis**, and P. S. Georgilakis, “Optimal Distribution Network Reconfiguration for Reliability Improvement in Presence of DG,” in *2020 IET MEDPOWER*, Paphos, Cyprus, Nov. 2020. DOI: <https://doi.org/10.1049/icp.2021.1255>
- [Σ4] M. A. Kousounadis-Knousen, **I. K. Bazionis**, A. P. Georgilaki and P. S. Georgilakis, “A fully co-optimized hybrid approach for short-term PV power forecasting that addresses the challenges of diurnal trends and residuals,” in *2024 IET MEDPOWER*, Athens, Greece, Nov. 2024.

## Βιβλιογραφία

- [1] EUR-Lex, Access to European Union Law, <https://eur-lex.europa.eu/eli/dir/2009/28/oj>, © European Union, 1998-2023.
- [2] International Energy Agency, Renewable Energy Market Update - June 2023, <https://www.iea.org/reports/renewable-energy-market-update-june-2023>, License: CC BY 4.0, Paris: IEA, 2023.
- [3] EUR-Lex, Access to European Union Law, <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A32018L2001>, © European Union, 1998-2023.
- [4] EUR-Lex, Access to European Union Law, <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A52021PC0557>, © European Union, 1998-2023.
- [5] International Energy Agency, RePowerEU Plan: Joint European action on renewable energy and energy efficiency, <https://www.iea.org/policies/15691-repowereu-plan-joint-european-action-on-renewable-energy-and-energy-efficiency>.
- [6] IRENA, *Renewable energy statistics 2023*, International Renewable Energy Agency, Abu Dhabi, 2023.
- [7] M. Z. Jacobson and M. A. Delucchi, “Providing all global energy with wind, water, and solar power, Part I: Technologies, energy resources, quantities and areas of infrastructure, and materials,” *Energy Policy*, vol. 39, no. 39, pp. 1154–1169, Mar. 2011.
- [8] P. S. Georgilakis, “Technical challenges associated with the integration of wind power into power systems,” *Renewable and Sustainable Energy Reviews*, vol. 12, no. 3, pp. 852–863, Apr. 2008.
- [9] I. K. Bazionis and P. S. Georgilakis, “Review of deterministic and probabilistic wind power forecasting: Models, methods, and future research,” *Electricity*, vol. 2, no. 1, pp. 13-47, Jan. 2021.
- [10] I. K. Bazionis, P. A. Karafotis and P. S. Georgilakis, “A review of short-term wind power probabilistic forecasting and a taxonomy focused on input data,” *IET Renewable Power Generation*, vol. 16, no. 1, pp. 77-91, Jan. 2022.
- [11] H. Liu, C. Chen, X. Lv and X. Wu, “Deterministic wind energy forecasting: A review of intelligent predictors and auxiliary methods,” *Energy Conversion and Management*, vol. 195, pp. 328-345, Sept. 2019.
- [12] S. Hanifi, X. Liu, Z. Lin and S. Lotfian, “A critical review of wind power forecasting methods-past, present and future,” *Energies*, vol. 13, no. 15, pp. 3764, Jul. 2020.
- [13] H. Quan, A. Khosravi, D. Yang and D. Srinivasan, “A survey of computational intelligence techniques for wind power uncertainty quantification in smart grids,” *IEEE Transactions on Neural Networks and Learning Systems*, vol. 31, no. 11, pp. 4582-4599, Dec. 2019.

- [14] S. A. Vargas, G. R. T. Esteves, P. M. Macaira and B. Q. Bastos, "Wind power generation: a review and a research agenda," *Journal of Cleaner Production*, vol. 218, pp. 850-870, May 2019.
- [15] C. G. Castillo, A. C. Tejero and O. L. Garcia, "A review on the recent history of wind power ramp forecasting," *Renewable and Sustainable Energy Reviews*, vol. 52, pp. 1148-1157, Dec. 2015.
- [16] H. Liu and C. Chen, "Data processing strategies in wind energy forecasting models and application: a comprehensive review," *Applied Energy*, vol. 249, pp. 392-408, Sept. 2019.
- [17] J. Yan, Y. Liu, S. Han, and Y. Wang, "Reviews on uncertainty analysis of wind power forecasting," *Renewable and Sustainable Energy Reviews*, vol. 52, pp. 1322-1330, Dec. 2015.
- [18] J. Jung and R. P. Broadwater, "Current status and future advances for wind speed and power forecasting," *Renewable and Sustainable Energy Reviews*, vol. 31 pp. 762-777, Mar. 2014.
- [19] M. N. Akhter, S. Mekhilef, H. Mokhlis and N. M. Shah, "Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques," *IET Renewable Power Generation*, vol. 13, no. 7, pp. 1009-1023, Mar. 2019.
- [20] U. K. Das, K. S. Tey, M. Seyedmahmoudian, S. Mekhilef, M. Y. I. Idris, W. Van Deventer, B. Horan and A. Stojcevski, "Forecasting of photovoltaic power generation and model optimization: a review," *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 912-928, Jan. 2018.
- [21] F. Barbieri, S. Rajakaruna and A. Ghosh, "Very short-term photovoltaic power forecasting with cloud modelling: a review," *Renewable and Sustainable Energy Reviews*, vol. 75, pp. 242-263, Aug. 2017.
- [22] 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.
- [23] M. Q. Raza, M. Nadarajah and C. Ekanayake, "On recent advances in PV output power forecast," *Solar Energy*, vol. 136, pp. 125-144, Oct. 2016.
- [24] D. W. Van der Meer, J. Widen and J. Munkhammar, "Review on probabilistic forecasting of photovoltaic power production and electricity consumption," *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 1484-1512, Jan. 2018.
- [25] B. Li and J. Zhang, "A review on the integration of probabilistic solar forecasting in power systems," *Solar Energy*, vol. 210, pp. 68-86, Nov. 2020.
- [26] T. Ma, H. Yang and L. Lu, "Solar photovoltaic system modelling and performance prediction," *Renewable and Sustainable Energy Reviews*, vol. 36, pp. 304-315, Aug. 2014.

- [27] Ahmed, R., Sreeram, V., Mishra, Y., Arif, M.D.: A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization. *Renewable and Sustainable Energy Reviews*, 124, 109792 (2020)
- [28] R. Ahmed, V. Sreeram, Y. Mishra and M. D. Arif, "A review and evaluation of the state-of-the-art in PV solar power forecasting: techniques and optimization" *Renewable and Sustainable Energy Reviews*, vol. 124, pp. 109792, May 2020.
- [29] E. Vladislavleva, T. Friedrich, F. Neumann and M. Wagner, "Predicting the energy output of wind farms based on weather data: Important variables and their correlation", *Renewable Energy*, vol. 50, pp. 236-243, Feb. 2013.
- [30] N. Chen, Z. Qian, I. T. Nabney and X. Meng, "Wind power forecasts using Gaussian processes and numerical weather prediction," *IEEE Transactions on Power Systems*, vol. 29, no. 2, pp. 656–665, Mar. 2014.
- [31] S.S. Soman, H. Zareipour, O. Malik and P. Mandal, "A review of wind power and wind speed forecasting methods with different time horizons," In Proceedings of the North American Power Symposium, Arlington, TX, USA, pp. 26–28, Sept. 2010.
- [32] H. Sharadga, S. Hajimirza and R. S. Balog, "Time series forecasting of solar power generation for large-scale photovoltaic plants," *Renewable Energy*, vol. 150, pp. 797-807, May 2020.
- [33] H. Nazaripouya, B. Wang, Y. Wang, P. Chu, H. R. Pota and R. Gadh, "Univariate time series prediction of solar power using a hybrid wavelet-ARMA-NARX prediction method," in Proceedings of the IEEE/PES Transmission and Distribution Conference and Exposition (T&D), Dallas, TX, USA, May 2016.
- [34] G.E.P. Box, G.M. Jenkins and G.C. Reinsel, "Time Series Analysis: Forecasting and Control," 4th ed. New York: John Wiley & Sons, Inc., 2008.
- [35] J. Boland, M. David and P. Lauret, "Short term solar radiation forecasting: Island versus continental sites," *Energy*, vol. 113, pp. 186–192, Oct. 2016.
- [36] A. Shadab, S. Ahmad and S. Said, "Spatial forecasting of solar radiation using ARIMA model," *Remote Sensing Applications: Society and Environment*, vol. 20, pp. 100427, Nov. 2020.
- [37] S. Atique, S. Noureen, V. Roy, V. Subburaj, S. Bayne and J. Macfie, "Forecasting of total daily solar energy generation using ARIMA: A case study," in Proceedings of the IEEE 9th Annual Computing and Communication Workshop and Conference (CCWC), Las Vegas, NV, USA, Jan. 2019.
- [38] V. Kushwaha and N. M. Pindoriya, "A SARIMA-RVFL hybrid model assisted by wavelet decomposition for very short-term solar PV power generation forecast," *Renewable Energy*, vol. 140, pp. 124-139, Sept. 2019.
- [39] L. Cai, J. Gu, J. Ma and Z. Jin, "Probabilistic wind power forecasting approach via instance-based transfer learning embedded gradient boosting decision trees," *Energies*, vol. 12, no. 1, pp. 159, Jan. 2019.
- [40] A. Lahouar and J. B. H. Slama, "Hour-ahead wind power forecast based on random forests", *Renewable Energy*, vol. 109, pp. 529-541, Aug. 2017.

- [41] J. H. Tato and M. C. Brito, "Using Smart Persistence and Random Forests to Predict Photovoltaic Energy Production," *Energies*, vol. 12, no. 1, pp. 100, Dec. 2018.
- [42] D. Niu, K. Wang, L. Sun, J. Wu and X. Xu, "Short-term photovoltaic power generation forecasting based on random forest feature selection and CEEMD: A case study," *Applied Soft Computing*, vol. 93, pp. 106389, Aug. 2020.
- [43] C. Cortes and V. Vapnik, "Support vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273–297, Sept. 1995.
- [44] W. VanDeventer, E. Jamei, G. S. Thirunavukkarasu, M. Seyedmahmoudian, T. K. Soon, B. Horan, S. Mekhilef and A. Stojcevski, "Short-term PV power forecasting using hybrid GASVM technique," *Renewable Energy*, vol. 140, pp. 367-379, Sept. 2019.
- [45] J. G. Fonseca, Y. Udagawa, T. Oozeki and K. Ogimoto, "Characteristics of day-ahead residual demand, PV power and demand forecasts in a scenario of large penetration of PV," in Proceedings of the 37th European Photovoltaic Solar Energy Conference and Exhibition (EU PVSEC), Lisbon, Portugal, Sept. 2020.
- [46] J. G. Fonseca, F. Uno, T. Oozeki and K. Ogimoto, "Intra-day forecasts of PV power with numerical weather prediction data and machine learning in Kyushu, Japan," in Proceedings of the 33rd European Photovoltaic Solar Energy Conference and Exhibition (EU PVSEC), Lisbon, Portugal, Sept. 2020.
- [47] T. Demirdelen, I. Ozge Aksu, B. Esenboga, K. Aygul, F. Ekinici and M. Bilgili, "A new method for generating short-term power forecasting based on artificial neural networks and optimization methods for solar photovoltaic power plants," *Solar Photovoltaic Power Plants*, pp. 165–189, Feb. 2019.
- [48] M. Talaat, T. Said, M. A. Essa and A. Y. Hatata, "Integrated MFFNN-MVO approach for PV solar power forecasting considering thermal effects and environmental conditions," *International Journal of Electrical Power & Energy Systems*, vol. 135, pp. 107570, Feb. 2022.
- [49] H. Aprillia, H.-T. Yang and C.-M. Huang, "Short-term photovoltaic power forecasting using a convolutional neural network–salp swarm algorithm," *Energies*, vol. 13, no. 8, pp. 1879, Apr. 2020.
- [50] H. Zang, L. Cheng, T. Ding, K. W. Cheung, Z. Wei and G. Sun, "Day-ahead photovoltaic power forecasting approach based on deep convolutional neural networks and meta learning," *International Journal of Electrical Power & Energy Systems*, vol. 118, pp. 105790, Jun. 2020.
- [51] D. Korkmaz, H. Acikgoz and C. Yildiz, "A novel short-term photovoltaic power forecasting approach based on deep convolutional neural network," *International Journal of Green Energy*, vol. 18, no. 5, pp. 525-539, Feb. 2021.
- [52] D. Korkmaz, "SolarNet: A hybrid reliable model based on convolutional neural network and variational mode decomposition for hourly photovoltaic power forecasting," *Applied Energy*, vol. 300, pp. 117410, Oct. 2021.

- [53] M. Abdel-Nasser and K. Mahmoud, "Accurate photovoltaic power forecasting models using deep LSTM-RNN," *Neural Computing and Applications*, vol. 31, pp. 2727-2740, 2019.
- [54] D. Lee and K. Kim, "Recurrent Neural Network-Based Hourly Prediction of Photovoltaic Power Output Using Meteorological Information," *Energies*, vol. 12, no. 2, pp. 215, Jan. 2019.
- [55] G. Li, H. Wang, S. Zhang, J. Xin and H. Liu, "Recurrent Neural Networks Based Photovoltaic Power Forecasting Approach," *Energies*, vol. 12, no. 13, pp. 2538, Jul. 2019.
- [56] M. Gao, J. Li, F. Hong and D. Long, "Day-ahead power forecasting in a large-scale photovoltaic plant based on weather classification using LSTM," *Energy*, vol. 187, pp. 115838, Nov. 2019.
- [57] Y. Zhang, C. Qin, A. K. Srivastava, C. Jin and R. Sharma, "Data-Driven Day-Ahead PV Estimation Using Autoencoder-LSTM and Persistence Model," *IEEE Transactions on Industry Applications*, vol. 56, no. 6, pp. 7185-7192, Dec. 2020.
- [58] L. Liu, M. Zhan and Y. Bai, "A recursive ensemble model for forecasting the power output of photovoltaic systems," *Solar Energy*, vol. 189, pp. 291–298, Sept. 2019.
- [59] P. Li, K. Zhou, X. Lu and S. Yang, "A hybrid deep learning model for short-term PV power forecasting," *Applied Energy*, vol. 259, pp. 114216, Feb. 2020.
- [60] G. Li, S. Xie, B. Wang, J. Xin, Y. Li and S. Du, "Photovoltaic power forecasting with a Hybrid Deep Learning Approach," *IEEE Access*, vol. 8, pp. 175871–175880, Sept. 2020.
- [61] M. Massaoudi, S. S. Refaat, H. Abu-Rub, I. Chihi and F. S. Wesleti, "A hybrid bayesian ridge regression-CWT-Catboost model for PV power forecasting," in *Proceedings of the IEEE Kansas Power and Energy Conference (KPEC)*, Manhattan, KS, USA, Jul. 2020.
- [62] Y. Zhang, J. Wang and X. Wang, "Review on probabilistic forecasting of wind power generation," *Renewable and Sustainable Energy Reviews*, vol. 32, pp. 255-270, Apr. 2014
- [63] P. Pinson, "Estimation of the uncertainty in wind power forecasting," Ph.D. Thesis, Ecole des Mines de Paris, Paris, France, 2006.
- [64] X. G. Agoua, R. Girard and G. Kariniotakis, "Probabilistic model for spatio-temporal photovoltaic power forecasting," *IEEE Transactions on Sustainable Energy*, vol. 10, no. 2, pp. 780-789, Jun. 2018.
- [65] H. Wang, H. Yi, J. Peng, G. Wang, Y. Liu, H. Jiang and W. Liu, "Deterministic and probabilistic forecasting of photovoltaic power based on deep convolutional neural network," *Energy Conversion and Management*, vol. 153, pp. 409-422, Dec. 2017.
- [66] A. Lahouar, J. B. H. Slama, "Hour-ahead wind power forecast based on random forests," *Renewable Energy*, vol. 109, pp. 529-541, Aug. 2017.

- [67] C. Wan, J. Lin, J. Wang and Y. Song, "Direct quantile regression for nonparametric probabilistic forecasting of wind power generation," *IEEE Transactions on Power Systems*, 32, pp. 2767-2778, Nov. 2016.
- [68] Y. Wang, Q. Hu, D. Srinivasan, Z. Wang, "Wind power curve modeling and wind power forecasting with inconsistent data," *IEEE Transactions on Sustainable Energy*, vol. 10, no. 1, pp. 16-25, Mar. 2018.
- [69] C. Wan, J. Lin, J. Wang, Y. Song and Z. Y. Dong, "Direct quantile regression for nonparametric probabilistic forecasting of wind power generation", *IEEE Transactions on Power Systems*, vol. 32, no. 4, pp. 2767-2778, Jul. 2017.
- [70] R. J. Bessa, V. Miranda, A. Botterud, J. Wang and E. M. Constantinescu, "Time adaptive conditional kernel density estimation for wind power forecasting," *IEEE Transactions on Sustainable Energy*, vol. 3, no. 4, pp. 660-669, Oct. 2012.
- [71] Y. Wang, Q. Hu, D. Meng and P. Zhu, "Deterministic and probabilistic wind power forecasting using a variational Bayesian-based adaptive robust multi-kernel regression model," *Applied Energy*, vol. 208, pp. 1097-1112, Dec. 2017.
- [72] B. Khorramdel, C. Y. Chung, N. Safari and G. C. D. Price, "A fuzzy adaptive probabilistic wind power prediction framework using diffusion kernel density estimators," *IEEE Transactions on Power Systems*, vol. 33, no. 6, pp. 7109-7121, Jun. 2018.
- [73] Y. Ren, P. N. Suganthan and N. Srikanth, "Ensemble methods for wind and solar power forecasting-A state-of-the-art review," *Renewable and Sustainable Energy Reviews*, vol. 50, pp. 82-91, Oct. 2015.
- [74] H-Y. Su and C-R. Huang, "Enhanced wind generation forecast using robust ensemble learning," *IEEE Transactions on Smart Grid*, vol. 12, no. 1, pp. 912-915, Sept. 2020.
- [75] H-Z. Wang, G-Q. Li, G-B. Wang and J-C. Peng, "Deep learning based ensemble approach for probabilistic wind power forecasting," *Applied Energy*, vol. 188, pp. 56-70, Feb. 2017.
- [76] A. Khosravi and S. Nahavandi, D. Creighton and A. Atiya, "A lower upper bound estimation method for construction of neural network-based prediction intervals," *IEEE Transactions on Neural Networks*, vol. 22, no. 3, pp. 337-346, Mar. 2011.
- [77] Y-K. Wu, P-E. Su, T-Y. Wu, J-S. Hong and M. Y. Hassan, "Probabilistic wind power forecasting using weather ensemble models," in Proceedings of the 54<sup>th</sup> Ind. Comm. Pow. Sys. Tech. Conf., 2018
- [78] B. Efron, "Bootstrap methods: another look at the jackknife," *The Annals of Statistics*, vol. 7, no. 1, pp. 1-26, Jan. 1979.
- [79] C. Gilbert, J. Browell and D. McMillan, "Leveraging turbine-level data for improved probabilistic wind power forecasting," *IEEE Transactions on Sustainable Energy*, vol. 11, no. 3, pp. 1152-1160, Jul. 2020.
- [80] M. Afrasiabi, M. Mohammadi, M. Rastegar and M. Afrasiabi, "Advanced deep learning approach for probabilistic wind speed forecasting," *IEEE Transactions on Industrial Informatics*, vol. 17, no. 1, pp. 720-727, Jan. 2021.

- [81] C. Feng, M. Cui, B-M. Hodge and J. Zhang, "A data-driven multi-model methodology with deep feature selection for short-term wind forecasting," *Applied Energy*, vol. 190, pp. 1245-1257, Mar. 2017.
- [82] Y. Liu, H. Qin, Z. Zhang and S. Pei, "Probabilistic spatiotemporal wind speed forecasting based on a variational deep learning model," *Applied Energy*, vol. 260, pp. 114259, Feb. 2020.
- [83] Y. Zhang and J. Wang, "A distributed approach for wind power probabilistic forecasting considering spatio-temporal correlation without direct access to off-site information," *IEEE Transactions on Power Systems*, vol. 33, no. 5, pp. 5714-5726, Sept. 2018.
- [84] C. Wan, J. Wang, J. Lin and Y. Song, "Nonparametric prediction intervals of wind power via linear programming," *IEEE Transactions on Power Systems*, vol. 33, no. 1, pp. 1074-1076, Jan 2018.
- [85] M. Afshari, T. Niknam and M-H. Khooban, "Probabilistic wind power forecasting using a novel hybrid intelligent method," *Neural Computing and Applications*, vol. 30, pp. 473-485, 2018.
- [86] A. A. H. Lateko, H.-T. Yang and C.-M. Huang, "Short-term PV power forecasting using a regression-based ensemble method," *Energies*, vol. 15, no. 11, pp. 4171, Jun. 2022.
- [87] D. Lee and K. Kim, "Recurrent neural network-based hourly prediction of photovoltaic power output using meteorological information," *Energies*, vol. 12, no. 2, pp. 215, Jan. 2019.
- [88] S. Al-Dahidi, M. Louzazni and N. Omran, "A local training strategy-based artificial neural network for predicting the power production of solar photovoltaic systems," *IEEE Access*, vol. 8, pp. 150262–150281, Aug. 2020.
- [89] Y. Ju, J. Li and G. Sun, "Ultra-short-term photovoltaic power prediction based on self-attention mechanism and multi-task learning," *IEEE Access*, vol. 8, pp. 44821–44829, Mar. 2020.
- [90] D. Korkmaz, "SolarNet: A hybrid reliable model based on convolutional neural network and variational mode decomposition for hourly photovoltaic power forecasting," *Applied Energy*, vol. 300, pp. 117410, Oct. 2021.
- [91] M. N. Akhter, S. Mekhilef, H. Mokhlis, Z. M. Almohaimeed, M. A. Muhammad, A. S. M. Khairuddin, R. Akram and M. M. Hussain, "An hour-ahead PV power forecasting method based on an RNN-LSTM model for three different PV plants," *Energies*, vol. 15, no. 6, pp. 2243, Mar. 2022.
- [92] J. Zhang, R. Verschae, S. Nobuhara and J.-F. Lalonde, "Deep photovoltaic nowcasting," *Solar Energy*, vol. 176, pp. 267–276, Dec. 2018.
- [93] A. N. - L. Huynh, R. C. Deo, M. Ali, S. Abdulla and N. Raj, "Novel short-term solar radiation hybrid model: Long short-term memory network integrated with robust local mean decomposition," *Applied Energy*, vol. 298, pp. 117193, Sept. 2021.

- [94] W. VanDeventer, E. Jamei, G. S. Thirunavukkarasu, M. Seyedmahmoudian, T. K. Soon, B. Horan, S. Mekhilef and A. Stojcevski, "Short-term PV power forecasting using hybrid GASVM technique," *Renewable Energy*, vol. 140, pp. 367–379, Sept. 2019.
- [95] Y. Li, R. Wang, Y. Li, M. Zhang and C. Long, "Wind power forecasting considering data privacy protection: A federated deep reinforcement learning approach," *Applied Energy*, vol. 329, pp. 120291, Jan. 2023.
- [96] Y. Li, W. Xinhao, L. Yuanzheng, D. Zhaoyang and S. Mohammad, "Detection of false data injection attacks in smart grid: A secure federated deep learning approach," *IEEE Transactions on Smart Grid*, vol. 13, no. 6, pp. 4862–4872, Sept. 2022.
- [97] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain", *Psychological Review*, vol. 65, no. 6, pp. 386-408, Nov. 1958.
- [98] D. Anderson and G. McNeill, "Artificial neural networks technology", (Kaman Sciences Corporation), vol. 258, pp. 1-83, 1992.
- [99] G. E. Hinton, "How neural networks learn from experience," *Scientific American*, vol. 267, no. 3, pp. 144-151, 1992.
- [100] G. N. Kariniotakis, G. S. Stavrakakis and E. F. Nogaret, "Wind power forecasting using advanced neural network models," *IEEE Transactions on Energy Conversion*, vol. 11, no. 4, pp. 762-767, Dec. 1996.
- [101] T. G. Barbounis, J. B. Theocharis, M. C. Alexiadis and P. S. Dokopoulos, "Long-term wind speed and power forecasting using local recurrent neural network models," *IEEE Transactions on Energy Conversion*, vol. 21, no.1, pp. 273-284, Mar. 2006.
- [102] B. M. Wilamowski, "Neural network architectures and learning algorithms," *IEEE Industrial Electronics Magazine*, vol. 3, no. 4, pp. 56-63, Dec. 2009.
- [103] I. Shafi, J. Ahmad, S. I. Shah and F. M. Kashif, "Impact of varying neurons and hidden layers in neural network architecture for a time frequency application," in *Proceedings of the 2006 IEEE International Multitopic Conference*, Islamabad, Pakistan, Dec. 2006.
- [104] J. Singh and R. Banerjee, "A study on single and multi-layer perceptron neural network," in *Proceedings of the 2019 3rd International Conference on Computing Methodologies and Communication (ICCMC)*, Erode, India, Mar. 2019.
- [105] R. Muhammad Ehsan, S. P. Simon and P. R. Venkateswaran, "Day-ahead forecasting of solar photovoltaic output power using multilayer perceptron," *Neural Computing and Applications*, vol 28, no. 12, pp. 3981-3992, Apr. 2016.
- [106] L. Gangqiang, H. Wang, S. Zhang, J. Xin and H. Liu, "Recurrent neural networks based photovoltaic power forecasting approach," *Energies*, vol. 12, no. 13, pp. 2538, Jul. 2019.
- [107] S. Sharma, S. Sharma and A. Athaiya, "Activation functions in neural networks," *International Journal of Engineering Applied Sciences and Technology*, vol. 4, no. 12, pp. 310-316, Apr. 2020.

- [108] A. A. Minai and R. D. Williams, "On the derivatives of the sigmoid," *Neural Networks*, vol. 6, no. 6, pp. 845-853, 1993.
- [109] X. Glorot and Y. Bengio, "Understanding the difficulty of training deep feedforward neural networks," *Journal of Machine Learning Research*, vol. 9, pp. 249-256, Jan. 2010.
- [110] X. Liang and J. Xu, "Biased ReLU neural networks," *Neurocomputing*, vol. 423, pp. 71-79, Jan. 2021.
- [111] A. D. Dongare, R. R. Kharde and A. D. Kachare, "Introduction to artificial neural network," *International journal of engineering and innovative technology*, vol. 2, no. 1, Jul. 2012.
- [112] G. Montavon, "Introduction to neural networks," *Machine Learning Meets Quantum Physics*, pp. 37-62, Jun. 2020.
- [113] A. A. H. Lateko, H. T. Yang and C. M. Huang, "Short-term PV power forecasting using a regression-based ensemble method," *Energies*, vol. 15, no. 11, pp. 4171, Jun. 2022.
- [114] E. R. Heras, C. A. Camacho and E. C. Calderón, "Short-term forecasting of energy production for a photovoltaic system using a NARX-CVM hybrid model," *Energies*, vol. 15, no. 8, pp.2842, Apr. 2022.
- [115] G. Sideratos and N. D. Hatziaargyriou, "Probabilistic wind power forecasting using radial basis function neural networks," *IEEE Transactions on Power Systems*, vol. 27, no. 4, pp. 1788–1796, Jul. 2012.
- [116] H. Quan, D. Srinivasan and A. Khosravi, "Short-term load and wind power forecasting using neural network-based prediction intervals," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 25, no. 2, pp. 303-315, Feb. 2014.
- [117] C. Wan, Z. Xu, P. Pinson, Z. Y. Dong and K. P. Wong, "Probabilistic forecasting of wind power generation using extreme learning machine," *IEEE Transactions on Power Systems*, vol. 29, no. 3, pp. 1033-1044, Nov. 2013.
- [118] C. Li, G. Tang, X. Xue, A. Saeed and X. Hu, "Short-term Wind Speed Interval Prediction based on Ensemble GRU model," *IEEE Transactions on Sustainable Energy*, vol. 1, no.1, Jul. 2019.
- [119] I. K. Bazionis, M. A. Kousounadis-Knousen, A. P. Georgilaki and P. S. Georgilakis, "LSTM-based hybrid approaches for short-term photovoltaic power forecasting," in *2024 IET MEDPOWER*, Athens, Greece, Nov. 2024.
- [120] I. K. Bazionis, M. A. Kousounadis-Knousen, P. S. Georgilakis, E. Shirazi, D. Soudris and F. Catthoor "A taxonomy of short-term solar power forecasting: Classifications focused on climatic conditions and input data," *IET Renewable Power Generation*, vol. 17, no. 9, pp. 2411-2432, Jul. 2023.
- [121] E. W. Law, A. A. Prasad, M. Kay and R. A. Taylor, "Direct normal irradiance forecasting and its application to concentrated solar thermal output forecasting – a review," *Solar Energy*, vol. 108, pp. 287–307, Oct. 2014.

- [122] R. Tapakis and A. G. Charalambides, "Equipment and methodologies for cloud detection and classification: A review," *Solar Energy*, vol. 95, pp. 392–430, Sept. 2013.
- [123] W.-Y. Chang, "A literature review of wind forecasting methods," *Journal of Power and Energy Engineering*, vol. 2, no. 4, pp. 161–168, Jan. 2014.
- [124] S. Wang, Y. Sun, S. Zhai and S. Hou, "Ultra-short-term wind power forecasting based on deep belief network." in *Proceedings of the Chinese Control Conference*, Guangzhou, China (2019)
- [125] A.M. Foley, P.G. Leahy, A. Marvuglia and E.J. McKeogh, "Current methods and advances in forecasting of wind power generation." *Renewable Energy*, vol. 37, no. 1, pp. 1–8. Jan. 2012.
- [126] T.G. Barbounis, J.B. Theocharis, M.C. Alexiadis and P.S. Dokopoulos, "Longterm wind speed and power forecasting using local recurrent neural network models," *IEEE Transactions on Energy Conversion*, vol. 21, no. 1, pp. 273–284 Mar. 2006.
- [127] M. C. Peel, B. L. Finlayson and T. A. McMahon, "Updated world map of the Köppen-Geiger climate classification," *Hydrology and Earth System Sciences*, vol. 11, pp. 1633-1644, Oct. 2007.
- [128] I. Bazionis, M. Kousounadis-Knousen, P. Georgilakis, E. Shirazi, D. Soudris and F. Catthoor, "A taxonomy of short-term solar power forecasting: Classifications focused on climatic conditions and input data," *IET Renewable Power Generation*, vol. 17, pp. 2411-2432, 2023
- [129] M. L. Minsky and S. Papert, "*Perceptrons*." Amsterdam University Press, 1972.
- [130] P. S. Georgilakis, "Spotlight on Modern Transformer Design," *Power Systems*, vol. 38. Springer, 2009.
- [131] G. Montavon, "Introduction to neural networks," *Machine Learning Meets Quantum Physics*, pp. 37-62, Jun. 2020.
- [132] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by backpropagating errors," *Nature*, vol. 323, no. 6088, pp. 533–536, Oct. 1986.
- [133] X. S. Yang, "Nature-inspired Metaheuristic Algorithms," Amsterdam University Press, 2010.
- [134] D. Whitley, "A genetic algorithm tutorial," *Statistics and Computing*, vol. 4, no. 2, pp. 65–85, 1994.
- [135] L.J. Fogel, A.J. Owens and M.J. Walsh, "Artificial Intelligence through Simulated Evolution," John Wiley, NY, 1966
- [136] R. Storn, K. Price, "Differential evolution-a simple and efficient adaptive scheme for global optimization over continuous spaces," ICSI, Berkeley, 1995.
- [137] E. Rashedi and H. Nezamabadi, "A comprehensive survey on gravitational search algorithm," *Swarm and Evolutionary Computation*, vol. 41, pp. 141-158, Aug. 2018.
- [138] E. Aarts and J. Korst, "Chapter 2 Simulated annealing 2.1 Introduction of the algorithm," *Simulated Annealing Theory Applications*, p. 7, 1987.

- [139] S. Mirjalili, "SCA: a sine cosine algorithm for solving optimization problems," *Knowledge-Based Systems*, vol. 96, pp. 120–133, Mar. 2016.
- [140] R.V. Rao, V.J. Savsani and D.P. Vakharia, "Teaching-learning-based optimization: a novel method for constrained mechanical design optimization problems." *Computer-Aided Design*, vol. 43, no. 3, pp. 303–315, Mar. 2011.
- [141] X.-S. Yang, "Harmony Search as a Metaheuristic Algorithm", in: *Music-Inspired Harmony Search Algorithm: Theory and Applications*, Studies in Computational Intelligence, Springer Berlin, vol. 191, pp. 1-14, 2009.
- [142] S. He, Q. H. Wu and J. Saunders, "Group search optimizer: and optimization algorithm inspired by animal searching behavior," *IEEE Transactions on Evolutionary Computation*, vol. 13, no. 5, pp. 973-990, Oct. 2009.
- [143] Kennedy, J.; Eberhart, R. Particle swarm optimization. Proc. IEEE International Conference on Neural Networks, Perth, WA, Australia, Nov 1995.
- [144] S. Mirjalili and A. Lewis, "The whale optimization algorithm," *Advances in engineering software*, vol. 95, pp. 51-67, May 2016.
- [145] X. S. Yang, "A new metaheuristic Bat-inspired Algorithm," *Studies in Computational Intelligence*, vol. 284, pp. 65–74, 2010.
- [146] S. Mirjalili, S. M. Mirjalili and A. Lewis, "Grey wolf optimizer," *Advances in Engineering Software*, vol. 69, pp. 46-61, Mar. 2014.
- [147] X.-S. Yang, "Nature-inspired metaheuristic algorithms," Luniver Press, UK, 2010.
- [148] T. Hong, P. Pinson, S. Fan, H. Zareipour, A. Troccoli and R. J. Hyndman, "Probabilistic energy forecasting: global energy forecasting competition and beyond," *International Journal of Forecasting*, vol. 32, no. 3, pp. 896-913, Sept. 2016.
- [149] L. Li, Y. Chang, M. Tseng, J. Liu and M. Lim, "Wind power prediction using a novel model on wavelet decomposition-support vector machines-improved atomic search algorithm," *Journal of Cleaner Production*, vol. 270, pp. 121817, Oct. 2020.
- [150] J. Catalao, H. Pousinho and V. Mendes, "Short-term wind power forecasting in Portugal by neural networks and wavelet transform," *Renewable Energy*, vol. 36, no. 4, pp. 1245-1251, Apr. 2011.
- [151] Y. Liu, L. Guan, C. Hou, H. Han, Z. Liu, Y. Sun and M. Zheng, "Wind power short-term prediction based on LSTM and discrete wavelet transform," *Applied Sciences*, vol. 9, no. 6, pp. 1108, Mar. 2019.
- [152] P. Addison, "The illustrated wavelet transform handbook," 2002
- [153] S. Mallat, "A theory for multiresolution signal decomposition-the wavelet representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 674-693, Jul. 1989.
- [154] A. Khosravi, S. Nahavandi, D. Creighton, and A. F. Atiya, "Lower upper bound estimation method for construction of neural network-based prediction intervals," *IEEE Transactions on Neural Networks*, vol. 22, no. 3, pp. 337–346, Mar. 2011.

- [155] H. Quan, D. Srinivasan, and A. Khosravi, "Particle swarm optimization for construction of neural network-based prediction intervals," *Neurocomputing*, vol. 127, pp. 172–180, Mar. 2014.
- [156] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proceedings of the IEEE International Conference on Neural Networks*, Perth, WA, Australia, Nov 1995.
- [157] J. Wright and M. Manic, "Neural network architecture selection analysis with application to cryptography location," in *Proceedings of the 2010 IJCNN, Barcelona, Spain*, July 2010.
- [158] J. Yam and T. Chow, "A weight initialization method for improving training speed in feedforward neural network," *Neurocomputing*, vol. 30, no. 1-4, pp. 219-232, Jan. 2000.
- [159] P. Andrews, "An investigation into mutation operators for particle swarm optimization," in *Proceedings of the IEEE Congress on Evolutionary Computation*, Vancouver, BC, Canada, Jul. 2006.
- [160] Y. Grushka-Cockayne, R. Richmond and V. Jose, "Combining prediction intervals in the M4 competition," *International Journal of Forecasting*, vol. 36, no. 1, pp. 178-185, Mar. 2020.
- [161] M. Chai, F. Xia, S. Hao, D. Peng, C. Cui and W. Liu, "PV power prediction based on LSTM with adaptive hyperparameter adjustment," *IEEE Access*, vol. 7, pp. 115473-115486, Aug. 2019.
- [162] M. Gao, J. Li, F. Hong and D. Long, "Day-ahead power forecasting in a large-scale photovoltaic plant based on weather classification using LSTM," *Energy*, vol. 187, pp. 115838, Nov. 2019.
- [163] X. Luo, D. Zhang and X. Zhu, "Deep learning based forecasting of photovoltaic power generation by incorporating domain knowledge," *Energy*, vol. 225, pp. 120240, Jun. 2021.
- [164] B. Efron, "Bootstrap methods: Another look at the jackknife," *The Annals of Statistics*, vol. 7, no. 1, pp. 1–26, Jan. 1979.
- [165] R. Tibshirani, "A comparison of some error estimates for neural network models," *Neural Computation*, vol. 8, no. 1, pp. 152–163, Jan. 1996.
- [166] X. B. Meng, Y. Liu, X. Z. Gao and H. Z. Zhang, "A new bio-inspired algorithm: chicken swarm optimization," *Advances in Swarm Intelligence*, vol. 8794, pp. 86-94, 2014.
- [167] W. G. Shi, Y. Guo, S. X. Yan, Y. Yu, P. Luo and J. X. Li, "Optimizing directional reader antennas deployment in Uhf rfid localization system by using a mpcso algorithm," *IEEE Sensors Journal*, vol. 18, no. 12, pp. 5035-5048, May 2018.
- [168] C. Fu, G.-O. Li, K.-P. Lin and H.-J. Zhang, "Short-term wind power prediction based on improved chicken algorithm optimization support vector machine," *Sustainability*, vol. 11, no. 512, Jan. 2019.

- [169] H. Zhang, M. Yuan, Y. Liang and Q. Liao, "A novel particle swarm optimization based on prey-predator relationship," *Applied Soft Computing*, vol. 68, pp. 202-218, Jul. 2018.