



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

**ΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ
ΠΑΡΑΓΩΓΗΣ ΜΕ ΧΡΗΣΗ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ
ΔΙΚΤΥΩΝ**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Νικόλαος Β. Τριανταφύλλου

Επίβλεψη: Πάυλος Σ. Γεωργιλάκης, Αναπληρωτής Καθηγητής Ε.Μ.Π.
Ιωάννης Κ. Μπαζιώνης, Υποψήφιος Διδάκτωρ Ε.Μ.Π.

Αθήνα, Οκτώβριος 2022



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

ΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ ΜΕ ΧΡΗΣΗ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Νικόλαος Β. Τριανταφύλλου

Επίβλεψη: Πάυλος Σ. Γεωργιλάκης, Αναπληρωτής Καθηγητής Ε.Μ.Π.
Ιωάννης Κ. Μπαζιώνης, Υποψήφιος Διδάκτωρ Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 27^η Οκτωβρίου 2022.

.....
Πάυλος Γεωργιλάκης
Αν. Καθηγητής Ε.Μ.Π.

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

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

Αθήνα, Οκτώβριος 2022

.....
Νικόλαος Β. Τριανταφύλλου

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

Copyright © Νικόλαος Τριανταφύλλου, 2022.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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

*Αφιερώνεται στους γονείς μου, Βασίλη και Ειρήνη,
στον αδερφό μου, Γιάννη, και στον παππού μου,
Νικόλαο*

ΠΕΡΙΛΗΨΗ

Η συνεχώς αυξανόμενη διείσδυση Ανανεώσιμων Πηγών Ενέργειας στα συστήματα ηλεκτρικής ενέργειας δημιουργεί νέες προκλήσεις, οι οποίες αφορούν διαφορετικές πτυχές του εκάστοτε συστήματος. Οι προκλήσεις αυτές πηγάζουν από την εγγενή μεταβλητότητα της παραγωγής από ανανεώσιμες πηγές, όπως η αιολική και η ηλιακή φωτοβολταϊκή παραγωγή.

Τα τελευταία χρόνια, η φωτοβολταϊκή παραγωγή έχει παρουσιάσει σημαντική ανάπτυξη. Ωστόσο, η παραγωγή φωτοβολταϊκής ισχύος παραμένει μια στοχαστική διαδικασία, καθώς εξαρτάται σε μεγάλο βαθμό από την ηλιακή ακτινοβολία και άλλους ευμετάβλητους μετεωρολογικούς παράγοντες. Επομένως, η ακριβής πρόβλεψη της φωτοβολταϊκής παραγωγής αποτελεί ζήτημα ύψιστης σημασίας, καθώς είναι απαραίτητη για τη μαζική ενσωμάτωση της φωτοβολταϊκής παραγωγής.

Το αντικείμενο της παρούσας διπλωματικής εργασίας είναι η βραχυπρόθεσμη και η πολύ βραχυπρόθεσμη πρόβλεψη της φωτοβολταϊκής παραγωγής με χρήση τεχνητών νευρωνικών δικτύων. Η πρόβλεψη της φωτοβολταϊκής παραγωγής πραγματοποιείται μέσω της κατασκευής και της εκπαίδευσης δύο διακριτών μοντέλων πρόβλεψης: κάθε μοντέλο πρόβλεψης αποτελείται από ένα νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης. Το πρώτο μοντέλο πρόβλεψης είναι ένα στατικό πολυστρωματικό perceptron, το οποίο εκπαιδεύεται με τον αλγόριθμο της προς τα πίσω διάδοσης του σφάλματος, ενώ το δεύτερο μοντέλο εκπαιδεύεται με τον αλγόριθμο που εφαρμόζεται στις Μηχανές Ακραίας Μάθησης.

Η διαδικασία εκπαίδευσης και αξιολόγησης των συγκεκριμένων μοντέλων απαιτεί κατάλληλα ιστορικά δεδομένα. Τα ιστορικά δεδομένα που χρησιμοποιούνται στην παρούσα διπλωματική εργασία περιλαμβάνουν μετρήσεις ισχύος καθώς και μετρήσεις διάφορων μετεωρολογικών παραγόντων. Οι μετρήσεις αυτές αφορούν δύο διαφορετικούς φωτοβολταϊκούς σταθμούς παραγωγής, ενώ δίνονται και για διαφορετική χρονική ανάλυση.

Τα μοντέλα πρόβλεψης που υλοποιούνται διαθέτουν πληθώρα υπερπαραμέτρων, οι οποίες καθορίζουν σε μεγάλο βαθμό την απόδοσή τους. Για να βελτιωθεί η ακρίβεια των μοντέλων πρόβλεψης, αυτές οι υπερπαραμέτροι πρέπει να ρυθμιστούν, καθώς η επιλογή της βέλτιστης διαμόρφωσης υπερπαραμέτρων επηρεάζει άμεσα την απόδοση των μοντέλων. Η αναζήτηση της βέλτιστης αυτής διαμόρφωσης πραγματοποιείται μέσω της διενέργειας δοκιμών για διαφορετικές διαμορφώσεις.

Η απόδοση των βελτιστοποιημένων μοντέλων πρόβλεψης αξιολογείται με τη χρήση κατάλληλων δεικτών αξιολόγησης. Οι επιλεγμένοι δείκτες αξιολόγησης χρησιμοποιούνται, επίσης, για τη σύγκριση των αποτελεσμάτων που παράγονται από τα μοντέλα πρόβλεψης. Τα αποτελέσματα αυτά συγκρίνονται με βάση το χρησιμοποιούμενο μοντέλο πρόβλεψης, αλλά και βάσει του χρονικού ορίζοντα της παραγόμενης πρόβλεψης, ώστε να εξαχθούν συμπεράσματα αναφορικά με την απόδοση των μοντέλων και την επίδραση του χρονικού ορίζοντα στην ακρίβεια της πρόβλεψης. Τέλος, προτείνονται ορισμένες επεκτάσεις της παρούσας διπλωματικής εργασίας.

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ

Βραχυπρόθεσμη πρόβλεψη φωτοβολταϊκής παραγωγής, τεχνητά νευρωνικά δίκτυα, νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης, Μηχανές Ακραίας Μάθησης, βελτιστοποίηση υπερπαραμέτρων

ABSTRACT

The continuously increasing penetration of Renewable Energy Sources in electric power systems poses new challenges, regarding different aspects of each system. These challenges arise from the inherent variability of renewable production, such as wind and solar photovoltaic production.

In recent years, photovoltaic production has exhibited significant growth. However, photovoltaic power generation is still a stochastic process, which largely depends on solar irradiation and other volatile meteorological factors. Therefore, accurate forecasting of photovoltaic production is of utmost importance, since it is necessary for massive photovoltaic integration.

The scope of this diploma thesis is the short-term and very short-term forecasting of photovoltaic production using artificial neural networks. Photovoltaic production forecasting is conducted through the construction and training of two distinct forecasting models; each forecasting model consisting of a feedforward neural network. The first forecasting model is a static multilayer perceptron, trained with the backpropagation algorithm, whereas the second model is trained with the Extreme Learning Machine algorithm.

The process of training and evaluating these particular models requires appropriate historical data. The historical data that are used in this diploma thesis include power measurements as well as measurements of several meteorological factors. These measurements pertain to two different photovoltaic power plants and are given with different temporal resolutions.

The implemented forecasting models involve a plethora of hyperparameters, which largely define the performance of the models. In order to improve the accuracy of these forecasting models, their hyperparameters must be tuned, as the selection of the best hyperparameter configuration directly impacts the models' performance. The search for the best hyperparameter configuration is carried out by testing and evaluating different configurations.

The performance of the optimized forecasting models is evaluated with suitable performance metrics. The selected metrics are also used in order to compare the results that are generated by these forecasting models. These results are compared based on the forecasting model being used as well as on the forecast horizon, for the purpose of drawing conclusions with regard to the models' performance and the effect of the forecast horizon on forecasting accuracy. Finally, future research on the topic of this diploma thesis is proposed.

KEY WORDS

Short-term photovoltaic power forecasting, artificial neural networks, feedforward neural networks, Extreme Learning Machines, hyperparameter optimization

ΕΥΧΑΡΙΣΤΙΕΣ

Η παρούσα διπλωματική εργασία εκπονήθηκε κατά το ακαδημαϊκό έτος 2021-2022 υπό την επίβλεψη του κ. Παύλου Γεωργιλάκη, αναπληρωτή καθηγητή της Σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Ε.Μ.Π., και του υποψήφιου διδάκτορα Ε.Μ.Π., Γιάννη Μπαζιώνη.

Πρωτίστως, θα ήθελα να ευχαριστήσω θερμά τον κ. Γεωργιλάκη για την ανάθεση της παρούσας διπλωματικής εργασίας, καθώς μου έδωσε την ευκαιρία να ασχοληθώ με ένα τόσο ενδιαφέρον και επίκαιρο θέμα. Θα ήθελα, επίσης, να τον ευχαριστήσω για την υπομονή και την καθοδήγησή του σε όλη τη διάρκεια εκπόνησης της διπλωματικής μου εργασίας. Παράλληλα, θα ήθελα να ευχαριστήσω τον υποψήφιο διδάκτορα Γιάννη Μπαζιώνη για τον χρόνο που μου αφιέρωσε και για την πολύτιμη βοήθειά του, καθώς ήταν δίπλα μου σε οποιαδήποτε δυσκολία παρουσιάστηκε κατά την εκπόνηση της εργασίας.

Στη συνέχεια, θα ήθελα να ευχαριστήσω τους φίλους και συναδέλφους μου, Γιώργο, Κωστή, Θοδωρή και Κατερίνα, για την παρέα και τη στήριξή τους σε αυτή τη διαδρομή που διανύσαμε μαζί.

Θα ήθελα, επίσης, να ευχαριστήσω την ευρύτερη οικογένειά μου για την αμέριστη αγάπη και υποστήριξή τους· ιδιαίτερα τους γονείς μου, Βασίλη και Ειρήνη, οι οποίοι είναι πάντα στο πλευρό μου, βοηθώντας με να ξεπεράσω οποιαδήποτε δυσκολία. Τέλος, θα ήθελα να ευχαριστήσω τον αδερφό μου, Γιάννη, ο οποίος θυσίασε πολλά για να με στηρίξει σε όλη τη διάρκεια των σπουδών μου, καθώς και τον παππού μου, Νικόλαο Καρχιλάκη, που με τις συμβουλές του και το χαμόγελό του μου έδινε, και συνεχίζει να μου δίνει, τη δύναμη και το κουράγιο να συνεχίσω.

ΠΕΡΙΕΧΟΜΕΝΑ

ΚΕΦΑΛΑΙΟ 1: ΕΙΣΑΓΩΓΗ

1.1	Εισαγωγή στην πρόβλεψη φωτοβολταϊκής παραγωγής	1
1.2	Αντικείμενο της διπλωματικής εργασίας	2
1.3	Δομή της διπλωματικής εργασίας	3

ΚΕΦΑΛΑΙΟ 2: ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

2.1	Εισαγωγή	5
2.2	Ιστορική αναδρομή	7
2.3	Αρχιτεκτονική τεχνητών νευρωνικών δικτύων	8
2.4	Διαδικασία της εκπαίδευσης	12
2.4.1	Μάθηση με επίβλεψη	13
2.4.2	Μάθηση χωρίς επίβλεψη	14
2.5	Αντικειμενικές συναρτήσεις εκπαίδευσης	15
2.6	Υπερπαράμετροι τεχνητών νευρωνικών δικτύων	16
2.6.1	Υπερπαράμετροι σχεδίασης μοντέλου	17
2.6.2	Υπερπαράμετροι αλγορίθμου βελτιστοποίησης	19

ΚΕΦΑΛΑΙΟ 3: ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

3.1	Η σπουδαιότητα της πρόβλεψης	21
3.2	Χρονικός ορίζοντας της πρόβλεψης	26
3.3	Τεχνικές πρόβλεψης φωτοβολταϊκής παραγωγής	27
3.4	Δείκτες αξιολόγησης	29

ΚΕΦΑΛΑΙΟ 4: ΑΝΑΛΥΣΗ ΚΑΙ ΕΠΕΞΕΡΓΑΣΙΑ ΙΣΤΟΡΙΚΩΝ ΔΕΔΟΜΕΝΩΝ

4.1	Δεδομένα εισόδου μοντέλων πρόβλεψης φωτοβολταϊκής παραγωγής	31
4.2	Διαθέσιμα ιστορικά δεδομένα	32
4.2.1	Φωτοβολταϊκό πάρκο της «Περδικούλας»	32
4.2.2	Φωτοβολταϊκό πάρκο «Lampirini»	34
4.3	Προεπεξεργασία δεδομένων εισόδου	36

ΚΕΦΑΛΑΙΟ 5: ΜΟΝΤΕΛΑ ΠΡΟΒΛΕΨΗΣ ΤΗΣ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

5.1	Πρόβλεψη φωτοβολταϊκής παραγωγής με χρήση νευρωνικών δικτύων εμπρόσθιας τροφοδότησης	39
5.1.1	Εισαγωγή στα νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης	39
5.1.2	Κατασκευή του μοντέλου	40
5.1.3	Εκπαίδευση του μοντέλου	42
5.1.4	Αξιολόγηση του μοντέλου	46
5.1.5	Διαδικασία βελτιστοποίησης των υπερπαραμέτρων	48
5.1.6	Επαλήθευση της λειτουργίας του μοντέλου	50
5.2	Πρόβλεψη φωτοβολταϊκής παραγωγής με χρήση Extreme Learning Machines	51
5.2.1	Εισαγωγή στις Μηχανές Ακραίας Μάθησης	51
5.2.2	Κατασκευή του μοντέλου	52
5.2.3	Διαδικασία της εκπαίδευσης	53
5.2.4	Αξιολόγηση του μοντέλου	56
5.2.5	Βελτιστοποίηση του μοντέλου	56
5.2.6	Επαλήθευση της λειτουργίας του μοντέλου	57

ΚΕΦΑΛΑΙΟ 6: ΠΑΡΟΥΣΙΑΣΗ ΤΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ

6.1	Διαχωρισμός της βάσης γνώσης	59
6.2	Δοκιμές βελτιστοποίησης του μοντέλου MLP	68
6.2.1	Φωτοβολταϊκό πάρκο της «Περδικούλας»	69
6.2.2	Φωτοβολταϊκό πάρκο «Lamprini» – Πρόβλεψη ανά 15 λεπτά	79
6.2.3	Φωτοβολταϊκό πάρκο «Lamprini» – Πρόβλεψη ανά λεπτό	84
6.3	Βελτιστοποίηση του μοντέλου ELM	87
6.3.1	Φωτοβολταϊκό πάρκο της «Περδικούλας»	88
6.3.2	Φωτοβολταϊκό πάρκο «Lamprini» – Πρόβλεψη ανά 15 λεπτά	90
6.3.3	Φωτοβολταϊκό πάρκο «Lamprini» – Πρόβλεψη ανά λεπτό	92
6.4	Σύγκριση της απόδοσης των βέλτιστων νευρωνικών δικτύων	94
6.4.1	Σύγκριση βάσει του μοντέλου πρόβλεψης	95
6.4.2	Σύγκριση βάσει του χρονικού ορίζοντα πρόβλεψης	97

ΚΕΦΑΛΑΙΟ 7: ΕΠΙΛΟΓΟΣ

7.1	Σύνοψη της διπλωματικής εργασίας	101
7.2	Συμπεράσματα	102
7.3	Μελλοντικές επεκτάσεις	103

ΚΕΦΑΛΑΙΟ 8: ΒΙΒΛΙΟΓΡΑΦΙΑ

8.1	Βιβλιογραφία	105
-----	--------------	-----

ΣΧΗΜΑΤΑ

Σχήμα 2.1: Το μαθηματικό μοντέλο ενός τεχνητού νευρώνα	9
Σχήμα 2.2: Σιγμοειδής συνάρτηση ενεργοποίησης	10
Σχήμα 2.3: Συνάρτηση υπερβολικής εφαπτομένης	10
Σχήμα 2.4: Πλήρως διασυνδεδεμένο νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης 8-4-2	12
Σχήμα 2.5: Δομικό διάγραμμα της διαδικασίας μάθησης με επίβλεψη	14
Σχήμα 3.1: Η εξέλιξη της συνολικής εγκατεστημένης ισχύος ηλιακής ενέργειας στην Ευρωπαϊκή Ένωση [36]	24
Σχήμα 3.2: Ταξινόμηση της πρόβλεψης φωτοβολταϊκής παραγωγής με βάση τον χρονικό ορίζοντα της πρόβλεψης	27
Σχήμα 3.3: Οι σημαντικότερες τεχνικές πρόβλεψης φωτοβολταϊκής παραγωγής	28
Σχήμα 4.1: Μοτίβα φωτοβολταϊκής ισχύος εξόδου και συνολικής ηλιακής ακτινοβολίας	33
Σχήμα 4.2: Δεδομένα Ιανουαρίου 2021: Ευθεία γραμμικής παλινδρόμησης και συσχέτιση μεταξύ της ισχύος εξόδου και (a) του 1 ^{ου} συνόλου μετρήσεων ηλιακής ακτινοβολίας, (b) του 2 ^{ου} συνόλου μετρήσεων ηλιακής ακτινοβολίας, (c) του 1 ^{ου} συνόλου μετρήσεων της θερμοκρασίας των πλαισίων, (d) του 2 ^{ου} συνόλου μετρήσεων της θερμοκρασίας των πλαισίων	35
Σχήμα 4.3: Δεδομένα Μαΐου 2021: Ευθεία γραμμικής παλινδρόμησης και συσχέτιση μεταξύ της ισχύος εξόδου και (a) του 1 ^{ου} συνόλου μετρήσεων ηλιακής ακτινοβολίας, (b) του 2 ^{ου} συνόλου μετρήσεων ηλιακής ακτινοβολίας, (c) του 1 ^{ου} συνόλου μετρήσεων της θερμοκρασίας των πλαισίων, (d) του 2 ^{ου} συνόλου μετρήσεων της θερμοκρασίας των πλαισίων	36
Σχήμα 5.1: Η δομή του νευρωνικού δικτύου εμπρόσθιας τροφοδότησης που χρησιμοποιείται από το μοντέλο MLP	41
Σχήμα 5.2: Απεικόνιση της μεθόδου διασταυρούμενης επικύρωσης πολλαπλών τμημάτων για $k = 3$ σε κάθε δοκιμή, το υποσύνολο που σκιάζεται με μπλε χρώμα αποτελεί το σύνολο επικύρωσης, με βάση το οποίο αξιολογείται η απόδοση του μοντέλου	50
Σχήμα 6.1: Διαδικασία αναζήτησης της βέλτιστης τιμής υπερπαραμέτρου στο πλαίσιο της μεθόδου «Trial and Error»	69
Σχήμα 6.2: Η συνάρτηση ενεργοποίησης softsign	75
Σχήμα 6.3: Διαδικασία κατασκευής, εκπαίδευσης και αξιολόγησης του μοντέλου ELM	88
Σχήμα 6.4: Ευθεία γραμμικής παλινδρόμησης και συσχέτιση μεταξύ της φωτοβολταϊκής παραγωγής που μετρήθηκε και της προβλεπόμενης φωτοβολταϊκής παραγωγής ανά μοντέλο πρόβλεψης (φωτοβολταϊκό πάρκο «Lampirini»)	97
Σχήμα 6.5: Ευθεία γραμμικής παλινδρόμησης και συσχέτιση μεταξύ της φωτοβολταϊκής παραγωγής που μετρήθηκε και της προβλεπόμενης φωτοβολταϊκής παραγωγής ανά μοντέλο πρόβλεψης (φωτοβολταϊκό πάρκο «Περδικούλα»)	98

ΠΙΝΑΚΕΣ

Πίνακας 4.1: Συντελεστής συσχέτισης Pearson μεταξύ της φωτοβολταϊκής ισχύος εξόδου και των διαθέσιμων παραμέτρων εισόδου	35
Πίνακας 6.1: Επιμέρους σύνολα ελέγχου για την αξιολόγηση μοντέλων πρόβλεψης που αφορούν το φωτοβολταϊκό πάρκο της «Περδικούλας»	60
Πίνακας 6.2: Επιμέρους σύνολα ελέγχου για την αξιολόγηση μοντέλων πρόβλεψης που αφορούν το φωτοβολταϊκό πάρκο «Lamprini» (2020) και ορίζοντα πρόβλεψης 225 λεπτών	63
Πίνακας 6.3: Επιμέρους σύνολα ελέγχου για την αξιολόγηση μοντέλων πρόβλεψης που αφορούν το φωτοβολταϊκό πάρκο «Lamprini» (2020) και ορίζοντα πρόβλεψης 15 λεπτών	65
Πίνακας 6.4: Επιμέρους σύνολα ελέγχου για την αξιολόγηση μοντέλων πρόβλεψης που αφορούν το φωτοβολταϊκό πάρκο «Lamprini» (2020, 2021) και ορίζοντα πρόβλεψης 15 λεπτών	66
Πίνακας 6.5: Δεδομένα εισόδου νευρωνικού δικτύου για το φωτοβολταϊκό πάρκο της «Περδικούλας»	70
Πίνακας 6.6: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας»	71
Πίνακας 6.7: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων του κρυφού στρώματος του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας»	73
Πίνακας 6.8: Δοκιμές βελτιστοποίησης όσον αφορά τη συνάρτηση ενεργοποίησης των κρυφών νευρώνων του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας»	74
Πίνακας 6.9: Δοκιμές βελτιστοποίησης όσον αφορά τον αλγόριθμο βελτιστοποίησης του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας»	76
Πίνακας 6.10: Δοκιμές βελτιστοποίησης όσον αφορά τον ρυθμό μάθησης του αλγορίθμου βελτιστοποίησης του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας»	77
Πίνακας 6.11: Βέλτιστες τιμές υπερπαραμέτρων του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας», μέθοδος «Trial and Error»	77
Πίνακας 6.12: Δεδομένα εισόδου νευρωνικών δικτύων για το φωτοβολταϊκό πάρκο «Lamprini»	79
Πίνακας 6.13: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου MLP για το φωτοβολταϊκό πάρκο «Lamprini» και χρονικό ορίζοντα πρόβλεψης 225 λεπτά	80
Πίνακας 6.14: Βέλτιστη διαμόρφωση υπερπαραμέτρων του μοντέλου MLP για το φωτοβολταϊκό πάρκο «Lamprini» και χρονικό ορίζοντα πρόβλεψης 225 λεπτά, μέθοδος «Trial and Error»	82
Πίνακας 6.15: Μετρικά σφάλματος του μοντέλου MLP για το φωτοβολταϊκό πάρκο «Lamprini» και χρονικό ορίζοντα 225 λεπτά, μέθοδος Grid Search με διασταυρούμενη επικύρωση για $k = 4$	84
Πίνακας 6.16: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου MLP για το φωτοβολταϊκό πάρκο «Lamprini» και χρονικό ορίζοντα πρόβλεψης 15 λεπτά	85
Πίνακας 6.17: Βέλτιστη διαμόρφωση υπερπαραμέτρων του μοντέλου MLP για το φωτοβολταϊκό πάρκο «Lamprini» και χρονικό ορίζοντα πρόβλεψης 15 λεπτά	86
Πίνακας 6.18: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου ELM για το φωτοβολταϊκό πάρκο της «Περδικούλας»	89

Πίνακας 6.19: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου ELM για το φωτοβολταϊκό πάρκο «Lamprini» και χρονικό ορίζοντα πρόβλεψης 225 λεπτά	90
Πίνακας 6.20: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου ELM για το φωτοβολταϊκό πάρκο «Lamprini» και χρονικό ορίζοντα πρόβλεψης 15 λεπτά	92
Πίνακας 6.21: Βέλτιστες διαμορφώσεις ανά εξεταζόμενη περίπτωση και ανά μοντέλο πρόβλεψης	95
Πίνακας 6.22: Συντελεστής προσδιορισμού για το σύνολο ελέγχου ανά εξεταζόμενη περίπτωση και ανά μοντέλο πρόβλεψης	99

ΕΙΣΑΓΩΓΗ

1.1 ΕΙΣΑΓΩΓΗ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

Τα τελευταία χρόνια, καταβάλλονται σημαντικές προσπάθειες όσον αφορά τον μετριασμό του φαινομένου της ανθρωπογενούς κλιματικής αλλαγής και των επιπτώσεών της: επιπτώσεις οι οποίες έχουν ήδη αρχίσει να εμφανίζονται σε παγκόσμιο επίπεδο και, σε ορισμένες περιπτώσεις, ταχύτερα από ότι αναμενόταν. Η αξιοποίηση Ανανεώσιμων Πηγών Ενέργειας, όπως η ηλιακή και η αιολική ενέργεια, βρίσκεται στον πυρήνα των συγκεκριμένων προσπαθειών, οι οποίες στοχεύουν στη δραστική μείωση των ανθρωπογενών εκπομπών διοξειδίου του άνθρακα (CO₂) και άλλων αερίων του θερμοκηπίου. Στο πλαίσιο αυτό εντάσσεται και ο μετασχηματισμός του τομέα της ηλεκτρικής ενέργειας, καθώς επιχειρείται η σταδιακή αποδέσμευσή του από τα ορυκτά καύσιμα, ειδικά όσον αφορά την παραγωγή της.

Έτσι, το ποσοστό της ηλεκτρικής ενέργειας που παράγεται από ανανεώσιμες πηγές αυξάνεται συνεχώς τα τελευταία χρόνια. Η τάση αυτή φαίνεται πως θα συνεχιστεί και το 2022, για το οποίο αναμένεται εκ νέου αύξηση όσον αφορά τις καθαρές προσθήκες εγκατεστημένης ισχύος ανανεώσιμων πηγών. Η αύξηση αυτή θα βασιστεί στην ολοένα αυξανόμενη παραγωγή από φωτοβολταϊκά συστήματα, καθώς η αύξηση της εγκατεστημένης φωτοβολταϊκής ισχύος αναμένεται να προσεγγίσει το 60% της συνολικής [1]. Στην προβλεπόμενη αυτή ανάπτυξη των φωτοβολταϊκών συστημάτων συμβάλλει καταλυτικά η παρατηρούμενη μείωση του κόστους, καθώς το σταθμισμένο κόστος της ηλεκτρικής ενέργειας (levelized cost of electricity – LCOE) που παράγεται από φωτοβολταϊκές μονάδες μεγάλης κλίμακας (utility-scale) μειώθηκε κατά 82% μεταξύ του 2010 και του 2019· η τιμή αυτή αποτελεί σταθμισμένο μέσο όρο και υπολογίζεται σε παγκόσμιο επίπεδο (global weighted-average) [2].

Ωστόσο, πέρα από τα οφέλη που αποδίδει, η συνεχώς αυξανόμενη διείσδυση της ηλιακής (φωτοβολταϊκής) ενέργειας μπορεί, επίσης, να επιφέρει σημαντικά προβλήματα, εξαιτίας της στοχαστικής φύσης της. Το γεγονός ότι η παραγωγή φωτοβολταϊκής ισχύος εξαρτάται, κατά κύριο λόγο, από την ένταση της προσπίπτουσας ηλιακής ακτινοβολίας, αλλά και από άλλους μετεωρολογικούς παράγοντες που χαρακτηρίζονται από μεταβλητότητα, καθιστά τη φωτοβολταϊκή παραγωγή μια στοχαστική διαδικασία, η οποία, σε αντίθεση με τη λειτουργία των συμβατικών σταθμών ηλεκτροπαραγωγής, δεν μπορεί να ελεγχθεί πλήρως. Η εγγενής αυτή αβεβαιότητα της φωτοβολταϊκής παραγωγής εγείρει σημαντικά ζητήματα τα οποία αφορούν πολλές διαφορετικές πτυχές του συστήματος ηλεκτρικής ενέργειας, τόσο από την πλευρά του Διαχειριστή όσο και από την πλευρά των χρηστών του.

Η σπουδαιότητα της πρόβλεψης της παραγωγής φωτοβολταϊκής ισχύος έγκειται στη χρησιμότητά της όσον αφορά την αντιμετώπιση των προκλήσεων που πηγάζουν από την

ευμετάβλητη φύση της φωτοβολταϊκής παραγωγής. Η αντιμετώπιση των συγκεκριμένων προκλήσεων είναι απαραίτητη για την απρόσκοπτη ενσωμάτωση της φωτοβολταϊκής παραγωγής τόσο στα συστήματα ηλεκτρικής ενέργειας όσο και στις αντίστοιχες αγορές. Παράλληλα, το γεγονός ότι η αυξανόμενη διείσδυση της φωτοβολταϊκής παραγωγής μεγεθύνει την επίδραση μιας ενδεχόμενης εσφαλμένης πρόβλεψης καταδεικνύει την αναγκαιότητα παραγωγής προβλέψεων με τη μεγαλύτερη δυνατή ακρίβεια.

Τα μοντέλα που χρησιμοποιούνται για την παραγωγή της πρόβλεψης ταξινομούνται σε διάφορες κατηγορίες. Μία πρώτη διάκριση μπορεί να γίνει βάσει της τεχνικής που χρησιμοποιείται για την παραγωγή της εκάστοτε πρόβλεψης. Έτσι, τα μοντέλα πρόβλεψης διακρίνονται σε φυσικά, στατιστικά και υβριδικά. Τα φυσικά μοντέλα παράγουν προβλέψεις με έμμεσο τρόπο, χρησιμοποιώντας προβλέψεις της ηλιακής ακτινοβολίας και άλλων μετεωρολογικών παραγόντων καθώς και τα τεχνικά χαρακτηριστικά του εξεταζόμενου συστήματος φωτοβολταϊκής παραγωγής. Αντίθετα, τα στατιστικά μοντέλα χρησιμοποιούν διαθέσιμα ιστορικά δεδομένα με σκοπό να μοντελοποιήσουν το εξεταζόμενο σύστημα και να προβλέψουν, με άμεσο τρόπο, την απόκριση του σε νέα, άγνωστα δεδομένα. Τέλος, τα υβριδικά μοντέλα συνιστούν συνδυασμό επιμέρους τεχνικών πρόβλεψης.

Ταυτόχρονα, τα μοντέλα πρόβλεψης διακρίνονται ανάλογα με τον χρονικό ορίζοντα της παραγόμενης πρόβλεψης. Παρά το γεγονός ότι δεν υπάρχουν σαφώς καθορισμένα χρονικά όρια, η ταξινόμηση των μοντέλων πρόβλεψης συνήθως πραγματοποιείται σε τέσσερις κατηγορίες: μοντέλα τα οποία παράγουν (i) μακροπρόθεσμη, (ii) μεσοπρόθεσμη, (iii) βραχυπρόθεσμη και (iv) πολύ βραχυπρόθεσμη πρόβλεψη. Ο χρονικός ορίζοντας της πρόβλεψης σχετίζεται άμεσα με τα διαθέσιμα ιστορικά δεδομένα, εφόσον υπάρχουν, καθώς και με τον σκοπό για τον οποίο προορίζεται η παραγόμενη πρόβλεψη.

1.2 ΑΝΤΙΚΕΙΜΕΝΟ ΤΗΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία πραγματεύεται τη βραχυπρόθεσμη και την πολύ βραχυπρόθεσμη πρόβλεψη φωτοβολταϊκής παραγωγής με χρήση στατιστικών μοντέλων πρόβλεψης που βασίζονται στα τεχνητά νευρωνικά δίκτυα. Συγκεκριμένα, αναπτύσσονται δύο μοντέλα πρόβλεψης – κάθε μοντέλο πρόβλεψης βασίζει τη λειτουργία του σε ένα νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης (feedforward) – τα οποία παράγουν προβλέψεις της φωτοβολταϊκής παραγωγής σε χρονικό ορίζοντα 225 (βραχυπρόθεσμη πρόβλεψη) και 15 (πολύ βραχυπρόθεσμη πρόβλεψη) λεπτών.

Το πρώτο μοντέλο πρόβλεψης υλοποιείται με ένα συμβατικό feedforward νευρωνικό δίκτυο, το οποίο εκπαιδεύεται με τον κλασικό αλγόριθμο της προς τα πίσω διάδοσης του σφάλματος (backpropagation). Η εκπαίδευση του συγκεκριμένου νευρωνικού δικτύου έγκειται στην επαναληπτική αναπροσαρμογή των ελεύθερων παραμέτρων του, ώστε να ελαχιστοποιηθεί η αντικειμενική συνάρτηση της εκπαίδευσης ή συνάρτηση κόστους. Για προβλήματα που αφορούν την πρόβλεψη φωτοβολταϊκής παραγωγής, ως αντικειμενική συνάρτηση εκπαίδευσης επιλέγεται, συνήθως, κάποιο μετρικό του σφάλματος πρόβλεψης.

Το δεύτερο μοντέλο πρόβλεψης στηρίζεται, επίσης, σε ένα νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης, το οποίο, ωστόσο, εκπαιδεύεται με τον αλγόριθμο μάθησης Extreme Learning Machine. Ο αλγόριθμος αυτός δεν αναπροσαρμόζει επαναληπτικά τις

ελεύθερες παραμέτρους του χρησιμοποιούμενου νευρωνικού δικτύου, αλλά τις υπολογίζει αναλυτικά. Η συγκεκριμένη διαφοροποίηση όσον αφορά τη διαδικασία της εκπαίδευσης συνιστά και τη μεγαλύτερη διαφορά μεταξύ των δύο αναπτυσσόμενων μοντέλων.

Σε κάθε περίπτωση, η εκπαίδευση ενός νευρωνικού δικτύου στο πλαίσιο των παραπάνω μοντέλων πρόβλεψης απαιτεί την ύπαρξη πληθώρας ιστορικών δεδομένων. Τα ιστορικά δεδομένα χρησιμοποιούνται τόσο για την εκπαίδευση όσο και για την αξιολόγηση της απόδοσης των μοντέλων, η οποία μάλιστα εξαρτάται, μεταξύ άλλων, και από την ποσότητα και την ποιότητα των διαθέσιμων δεδομένων. Στο πλαίσιο της παρούσας διπλωματικής εργασίας, τα διαθέσιμα ιστορικά δεδομένα αφορούν δύο διακριτές φωτοβολταϊκές μονάδες: το φωτοβολταϊκό πάρκο της «Περδικούλας» και το φωτοβολταϊκό πάρκο «Lampirini».

Το σύνολο ιστορικών δεδομένων που χρησιμοποιείται, το οποίο αντιστοιχεί στο φωτοβολταϊκό πάρκο που εξετάζεται, καθώς και ο χρονικός ορίζοντας της παραγόμενης πρόβλεψης αποτελούν παράγοντες που επηρεάζουν την απόδοση του μοντέλου που χρησιμοποιείται. Επομένως, μία διαμόρφωση του μοντέλου πρόβλεψης που παρουσιάζει ικανοποιητικά αποτελέσματα για κάποια συγκεκριμένη περίπτωση μελέτης ενδέχεται να μην μπορεί να εφαρμοστεί αποδοτικά σε κάποια άλλη. Επομένως, για κάθε περίπτωση που μελετάται, επιχειρείται η βελτιστοποίηση του μοντέλου, δηλαδή η εύρεση της διαμόρφωσής του που αντιστοιχεί στο μικρότερο δυνατό σφάλμα πρόβλεψης για την εκάστοτε περίπτωση. Δεδομένου ότι τα τεχνητά νευρωνικά δίκτυα που χρησιμοποιούνται εκπαιδεύονται εμπειρικά, η διαδικασία της βελτιστοποίησης πραγματοποιείται με τη διενέργεια πληθώρας δοκιμών, με σκοπό την εύρεση της βέλτιστης αυτής διαμόρφωσης.

Τέλος, για κάθε περίπτωση που εξετάζεται, καταγράφονται τα βέλτιστα αποτελέσματα που προέκυψαν, δηλαδή τα αποτελέσματα που υπολογίστηκαν κατά την εφαρμογή ενός μοντέλου πρόβλεψης που κρίθηκε βέλτιστο μέσω των δοκιμών που πραγματοποιήθηκαν. Έτσι, καθίσταται δυνατή η σύγκριση της απόδοσης μεταξύ των δύο μοντέλων πρόβλεψης που αναπτύχθηκαν, καθώς και η σύγκριση της απόδοσης ενός μοντέλου για διαφορετικούς χρονικούς ορίζοντες πρόβλεψης.

1.3 ΔΟΜΗ ΤΗΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία οργανώνεται σε οκτώ κεφάλαια. Το παρόν Κεφάλαιο αποτελεί μια μικρή εισαγωγή στην πρόβλεψη της φωτοβολταϊκής παραγωγής, ενώ περιγράφεται συνοπτικά και το αντικείμενο της διπλωματικής εργασίας.

Το Κεφάλαιο 2 αποτελεί μια εισαγωγή στα τεχνητά νευρωνικά δίκτυα. Μετά από μια σύντομη ιστορική αναδρομή, παρουσιάζεται το βασικό δομικό στοιχείο των τεχνητών νευρωνικών δικτύων, ο νευρώνας. Παρουσιάζονται, επίσης, οι βασικές αρχιτεκτονικές στις οποίες συγκροτούνται οι μεμονωμένοι νευρώνες. Στη συνέχεια, περιγράφεται η διαδικασία της εκπαίδευσης ενός τεχνητού νευρωνικού δικτύου, ενώ εισάγεται η έννοια της αντικειμενικής συνάρτησης εκπαίδευσης. Τέλος, καταγράφονται και αναλύονται οι βασικές υπερπαραμέτροι ενός τεχνητού νευρωνικού δικτύου.

Στο Κεφάλαιο 3 τεκμηριώνεται η σπουδαιότητα της πρόβλεψης της φωτοβολταϊκής παραγωγής. Παρουσιάζονται αναλυτικά οι κατηγορίες στις οποίες διαχωρίζονται τα μοντέλα

πρόβλεψης βάσει του χρονικού ορίζοντα. Παρουσιάζονται, επίσης, διάφορες τεχνικές πρόβλεψης φωτοβολταϊκής παραγωγής. Τέλος, αναλύονται επιλεγμένοι δείκτες αξιολόγησης της απόδοσης των μοντέλων πρόβλεψης.

Στο Κεφάλαιο 4 αναλύονται τα δεδομένα των φωτοβολταϊκών πάρκων «Περδικούλα» και «Lampirini». Διερευνάται η συσχέτιση μεταξύ των παραμέτρων εισόδου και της παραγόμενης φωτοβολταϊκής ισχύος. Τέλος, περιγράφεται ο τρόπος προεπεξεργασίας των διαθέσιμων ιστορικών δεδομένων.

Στο Κεφάλαιο 5 παρουσιάζονται τα μοντέλα πρόβλεψης που αναπτύσσονται στην παρούσα διπλωματική εργασία. Περιγράφεται η αρχιτεκτονική των μοντέλων πρόβλεψης. Αναλύονται οι αλγόριθμοι που χρησιμοποιούνται για την εκπαίδευση των μοντέλων. Παρουσιάζεται η διαδικασία αξιολόγησης των μοντέλων. Παρουσιάζεται, επίσης, η διαδικασία που ακολουθείται με σκοπό τη βελτιστοποίηση των μοντέλων πρόβλεψης. Τέλος, περιγράφεται ο τρόπος επαλήθευσης της καλής λειτουργίας των μοντέλων.

Στο Κεφάλαιο 6 παρουσιάζονται τα αποτελέσματα των μοντέλων πρόβλεψης. Περιγράφεται ο τρόπος διαχωρισμού της βάσης γνώσης ανά εξεταζόμενη περίπτωση. Παρουσιάζονται τα αποτελέσματα των δοκιμών που αφορούν το πρώτο και το δεύτερο μοντέλο πρόβλεψης. Πραγματοποιείται σύγκριση των βέλτιστων αποτελεσμάτων βάσει του χρησιμοποιούμενου μοντέλου πρόβλεψης και του χρονικού ορίζοντα της πρόβλεψης.

Στο Κεφάλαιο 7 συνοψίζεται η παρούσα διπλωματική εργασία. Καταγράφονται τα συμπεράσματα που προέκυψαν, ενώ προτείνονται και μελλοντικές επεκτάσεις της διπλωματικής εργασίας.

Τέλος, στο Κεφάλαιο 8 καταγράφεται η βιβλιογραφία που χρησιμοποιήθηκε κατά την εκπόνηση της παρούσας διπλωματικής εργασίας.

ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

2.1 ΕΙΣΑΓΩΓΗ

Τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks – ANNs) είναι μαζικά παράλληλα, καταναμημένα συστήματα επεξεργασίας πληροφοριών, τα οποία είναι εμπνευσμένα από βιολογικά νευρικά συστήματα. Στην πιο γενική του μορφή, ένα τεχνητό νευρωνικό δίκτυο σχεδιάζεται με σκοπό να μοντελοποιήσει τον τρόπο με τον οποίο ο ανθρώπινος εγκέφαλος – ο οποίος είναι ένα εξαιρετικά περίπλοκο, μη γραμμικό και παράλληλο υπολογιστικό σύστημα – εκτελεί μια συγκεκριμένη εργασία ή λειτουργία [3].

Τα τεχνητά νευρωνικά δίκτυα αποτελούνται από απλά υπολογιστικά στοιχεία τα οποία είναι διασυνδεδεμένα μεταξύ τους και λειτουργούν παράλληλα. Τα στοιχεία αυτά καλούνται τεχνητοί νευρώνες ή απλά νευρώνες (neurons). Σε αναλογία με ένα βιολογικό νευρωνικό δίκτυο, η λειτουργία ενός τεχνητού νευρωνικού δικτύου καθορίζεται σε μεγάλο βαθμό από τις συνδέσεις μεταξύ των νευρώνων του [4]. Οι συνδέσεις αυτές χαρακτηρίζονται από τιμές γνωστές ως συναπτικά βάρη (synaptic weights), τα οποία καθορίζουν πόσο ισχυρή είναι η σύνδεση μεταξύ των νευρώνων. Μέσω της διαδικασίας της μάθησης οι τιμές των συναπτικών βαρών προσαρμόζονται, ώστε το τεχνητό νευρωνικό δίκτυο να επιτελεί μια συγκεκριμένη λειτουργία. Έτσι, στα συναπτικά βάρη αποθηκεύεται η γνώση που αποκτά το τεχνητό νευρωνικό δίκτυο από το περιβάλλον του κατά την παραπάνω διαδικασία [3].

Ο τρόπος με τον οποίο δομούνται τα τεχνητά νευρωνικά δίκτυα καθώς και η ικανότητά τους να εκπαιδεύονται εμπειρικά χρησιμοποιώντας υπάρχοντα δεδομένα προσφέρουν σημαντικά πλεονεκτήματα. Συγκεκριμένα:

- Τα τεχνητά νευρωνικά δίκτυα είναι προσαρμοστικά, καθώς έχουν τη δυνατότητα να προσαρμόζουν τα συναπτικά τους βάρη ανάλογα με τα εκάστοτε δεδομένα που τους παρουσιάζονται. Έτσι, οδηγούνται σε λύσεις που βασίζονται στα δεδομένα αυτά, πολλές φορές συλλαμβάνοντας ανεπαίσθητες σχέσεις [5].
- Τα τεχνητά νευρωνικά δίκτυα έχουν την ικανότητα της γενίκευσης (generalization), δηλαδή την ικανότητα να παράγουν εύλογα αποτελέσματα χρησιμοποιώντας τιμές εισόδων που δεν συνάντησαν κατά τη διαδικασία της εκπαίδευσης [3]. Έτσι, γεφυρώνεται το χάσμα ανάμεσα σε μεμονωμένα παραδείγματα και γενικές σχέσεις. Η ικανότητα γενίκευσης είναι επίσης χρήσιμη, επειδή τα πραγματικά δεδομένα με τα οποία εκπαιδεύεται ένα τεχνητό νευρωνικό δίκτυο περιλαμβάνουν θόρυβο, παραμορφώσεις και συχνά είναι ελλιπή [6].
- Τα τεχνητά νευρωνικά δίκτυα είναι μαζικά παράλληλα, καθώς οι πολυάριθμες πανομοιότυπες, ανεξάρτητες λειτουργίες τους μπορούν να εκτελεστούν ταυτόχρονα. Έτσι, η χρήση παράλληλου υλικού (hardware) μπορεί να οδηγήσει σε πολύ μικρότερους χρόνους εκτέλεσης [5].

- Τα τεχνητά νευρωνικά δίκτυα είναι μη γραμμικά, εφόσον αποτελούνται από μη γραμμικούς νευρώνες. Έτσι, μπορούν να επιλύσουν πολύπλοκα προβλήματα με μεγαλύτερη ακρίβεια συγκριτικά με γραμμικές τεχνικές. Παρά το γεγονός ότι πολλά πραγματικά συστήματα είναι μη γραμμικά, η μη γραμμική συμπεριφορά είναι συχνά δύσκολο να αντιμετωπιστεί μαθηματικά [6], επομένως η συγκεκριμένη ιδιότητα των τεχνητών νευρωνικών δικτύων είναι ιδιαίτερα σημαντική.

Οι παραπάνω δυνατότητες που διαθέτουν τα τεχνητά νευρωνικά δίκτυα ως συστήματα επεξεργασίας πληροφοριών τα καθιστούν ικανά να βρίσκουν καλές προσεγγιστικές λύσεις σε σύνθετα προβλήματα μεγάλης κλίμακας. Έτσι, έχουν χρησιμοποιηθεί με επιτυχία σε διάφορους τομείς των μαθηματικών, της μηχανικής, της ιατρικής, των οικονομικών, της μετεωρολογίας, της ψυχολογίας, της νευρολογίας και πολλών άλλων [7]. Τα επιμέρους προβλήματα που μπορούν να επιλυθούν με τη χρήση τεχνητών νευρωνικών δικτύων ανήκουν στις εξής κατηγορίες:

1. Ταξινόμηση μοτίβων (Pattern classification). Αφορά την ανάθεση ενός άγνωστου μοτίβου εισόδου σε μία από πολλές προκαθορισμένες κλάσεις βάσει ενός ή περισσότερων χαρακτηριστικών της συγκεκριμένης κλάσης. Γνωστές εφαρμογές περιλαμβάνουν την αναγνώριση χαρακτήρων, την αναγνώριση ομιλίας, την ταξινόμηση κυττάρων αίματος, την ταξινόμηση κυματομορφών ηλεκτροεγκεφαλογραφήματος και την επιθεώρηση τυπωμένων κυκλωμάτων [8].
2. Ομαδοποίηση (Clustering). Κατά τη διαδικασία της ομαδοποίησης σχηματίζονται συστάδες (clusters) διερευνώντας τις ομοιότητες ή τις ανομοιότητες μεταξύ των μοτίβων εισόδου [9]. Τα μοτίβα που παρουσιάζουν ομοιότητες τοποθετούνται στην ίδια συστάδα μέσω ενός αλγορίθμου ομαδοποίησης. Γνωστές εφαρμογές περιλαμβάνουν την εξόρυξη, τη συμπίεση και τη διερευνητική ανάλυση δεδομένων [8].
3. Προσέγγιση συνάρτησης (Function approximation). Αφορά την εκπαίδευση ενός τεχνητού νευρωνικού δικτύου χρησιμοποιώντας ως δεδομένα γνωστά ζεύγη εισόδου-εξόδου, με σκοπό την εκτίμηση της άγνωστης σχέσης που τα διέπει. Εφαρμόζεται είτε σε προβλήματα για τα οποία δεν υπάρχει διαθέσιμο θεωρητικό μοντέλο είτε υποκαθιστώντας θεωρητικά μοντέλα που είναι δύσκολο να υπολογιστούν αναλυτικά [9].
4. Βελτιστοποίηση (Optimization). Αφορά την εύρεση λύσης, ώστε να μεγιστοποιείται ή να ελαχιστοποιείται μια αντικειμενική συνάρτηση. Πληθώρα προβλημάτων των μαθηματικών, της στατιστικής, της μηχανικής, της ιατρικής και των οικονομικών μπορούν να θεωρηθούν προβλήματα βελτιστοποίησης [8].
5. Συσχέτιση μοτίβων (Pattern association). Αφορά τη χρησιμοποίηση ενός τεχνητού νευρωνικού δικτύου που έχει εκπαιδευτεί με ιδανικά, χωρίς θόρυβο δεδομένα, για την ταξινόμηση ή και τη διόρθωση παραμορφωμένων από τον θόρυβο δεδομένων [9].

6. Έλεγχος (Control). Αφορά τη σχεδίαση ενός τεχνητού νευρωνικού δικτύου το οποίο παράγει τις απαιτούμενες εισόδους ελέγχου, ώστε ένα προσαρμοστικό σύστημα ελέγχου να λειτουργεί με τον τρόπο που έχει καθορίσει το μοντέλο αναφοράς [8].
7. Πρόβλεψη (Prediction/Forecasting). Αφορά την εκπαίδευση ενός τεχνητού νευρωνικού δικτύου χρησιμοποιώντας δεδομένα από χρονοσειρές που περιγράφουν ένα συγκεκριμένο φαινόμενο για κάποιο δεδομένο χρονικό διάστημα, με σκοπό την πρόβλεψη της συμπεριφοράς του φαινομένου για μεταγενέστερες χρονικές στιγμές. Τυπικές εφαρμογές αποτελούν οι προβλέψεις του χρηματιστηρίου και η πρόγνωση του καιρού [8].

Τα τεχνητά νευρωνικά δίκτυα βρίσκουν εφαρμογή σε ενεργειακά συστήματα, ιδιαίτερα σε συστήματα που αξιοποιούν Ανανεώσιμες Πηγές Ενέργειας (Renewable Energy Sources), για σκοπούς μοντελοποίησης και πρόβλεψης. Συγκεκριμένα, έχουν χρησιμοποιηθεί σε ηλιακά συστήματα θέρμανσης νερού, σε φωτοβολταϊκά συστήματα, για την πρόβλεψη της ηλιακής ακτινοβολίας και της ταχύτητας του ανέμου καθώς και για την πρόβλεψη φορτίου [7].

2.2 ΙΣΤΟΡΙΚΗ ΑΝΑΔΡΟΜΗ

Ο πρώτος σταθμός στην ιστορική εξέλιξη των τεχνητών νευρωνικών δικτύων είναι το 1943, όταν οι McCulloch και Pitts [10] εισήγαγαν την ιδέα των νευρωνικών δικτύων ως υπολογιστικών μηχανών. Οι McCulloch και Pitts παρουσίασαν ένα μοντέλο του βιολογικού νευρώνα, γνωστό ως μοντέλο νευρώνα McCulloch-Pitts, το οποίο αργότερα χρησιμοποιήθηκε ως δομικό στοιχείο άλλων νευρωνικών δικτύων.

Το επόμενο μεγάλο βήμα στην εξέλιξη των τεχνητών νευρωνικών δικτύων έγινε το 1949, όταν ο Hebb [11] διατύπωσε για πρώτη φορά έναν κανόνα μάθησης που βασίζεται στην τροποποίηση των συναπτικών βαρών. Σύμφωνα με τον παραπάνω κανόνα, όταν ένα νευρικό κύτταρο συμμετέχει επανειλημμένα και επίμονα στη διέγερση ενός άλλου κυττάρου, τότε συμβαίνει κάποια διαδικασία ανάπτυξης ή κάποια μεταβολική αλλαγή, ώστε να αυξηθεί η ισχύς της σύναψης μεταξύ των δύο κυττάρων.

Το 1958 ο Rosenblatt [12] παρουσίασε το Perceptron, το οποίο αποτέλεσε το πρώτο νευρωνικό δίκτυο που περιγραφόταν αλγοριθμικά καθώς και το πρώτο μοντέλο που έκανε χρήση της μάθησης με επίβλεψη (supervised learning). Το Perceptron είναι το απλούστερο νευρωνικό δίκτυο που χρησιμοποιείται για την ταξινόμηση γραμμικά διαχωρίσιμων προτύπων, καθώς αποτελείται από έναν νευρώνα με προσαρμόσιμα συναπτικά βάρη και πόλωση (bias) [3]. Παράλληλα, ο Rosenblatt διατύπωσε και απέδειξε το θεώρημα σύγκλισης του Perceptron, δηλαδή το θεώρημα σύγκλισης του αλγορίθμου μάθησης που ανέπτυξε για την προσαρμογή των ελεύθερων παραμέτρων του παραπάνω νευρωνικού δικτύου.

Το 1960 οι Widrow και Hoff [13] ανέπτυξαν τον αλγόριθμο των Ελαχίστων Μέσων Τετραγώνων (Least-Mean-Squares algorithm), τον πρώτο αλγόριθμο γραμμικού προσαρμοστικού φιλτραρίσματος. Η απλότητα, η αποδοτικότητα και η σταθερότητα του συγκεκριμένου αλγορίθμου τον έχουν καταστήσει σημείο αναφοράς για τις εφαρμογές

προσαρμοστικού φιλτραρίσματος καθώς και για την αξιολόγηση αντίστοιχων αλγορίθμων [3].

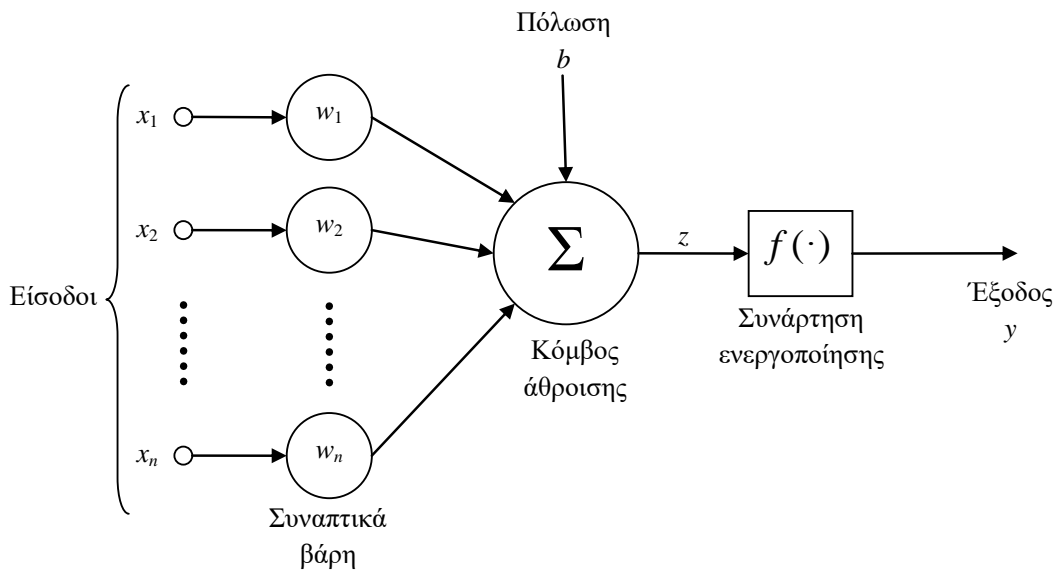
Τα επόμενα σημαντικά βήματα όσον αφορά την ανάλυση και τη σχεδίαση των τεχνητών νευρωνικών δικτύων έγιναν τη δεκαετία του 1980. Το 1982 η εργασία [14] του Hopfield συνέβαλε καταλυτικά στην αναβίωση του ενδιαφέροντος για τα νευρωνικά δίκτυα. Συγκεκριμένα, ο Hopfield μελέτησε ένα αναδρομικό (recurrent) νευρωνικό δίκτυο χρησιμοποιώντας μία ενεργειακή συνάρτηση για την ανάλυσή του, καταφέροντας να δείξει ότι είναι δυνατόν να προκύψει μια απλή, δομημένη συμπεριφορά από την εξέλιξη ενός σύνθετου, μη γραμμικού δυναμικού συστήματος [3]. Λίγο αργότερα, το 1986, οι Rumelhart, Hinton και Williams θεμελίωσαν τον αλγόριθμο εκπαίδευσης με προς τα πίσω διάδοση του σφάλματος (backpropagation training algorithm) [15], ο οποίος παραμένει μέχρι και σήμερα ο πιο διαδεδομένος αλγόριθμος εκπαίδευσης των τεχνητών νευρωνικών δικτύων. Ο αλγόριθμος της προς τα πίσω διάδοσης του σφάλματος – που αναπτύχθηκε και δημοσιεύθηκε για πρώτη φορά στη διδακτορική διατριβή του Werbos το 1974 [16], χωρίς ωστόσο να λάβει αντίστοιχη αναγνώριση – είναι μία πολύ αποδοτική υπολογιστική μέθοδος που χρησιμοποιείται κατά την προσαρμογή των συναπτικών βαρών.

Από τότε μέχρι σήμερα, η ανάπτυξη στο πεδίο των τεχνητών νευρωνικών δικτύων είναι συνεχής, συμβαδίζοντας με την πρόοδο που παρατηρείται στην τεχνολογία του υλικού και του λογισμικού των ηλεκτρονικών υπολογιστών, η οποία διευκολύνει την προσομοίωση και την εκτέλεσή τους.

2.3 ΑΡΧΙΤΕΚΤΟΝΙΚΗ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Το βασικό δομικό στοιχείο ενός τεχνητού νευρωνικού δικτύου είναι ο νευρώνας, ο οποίος αποτελεί μία μονάδα επεξεργασίας πληροφοριών που είναι θεμελιώδης για τη λειτουργία του νευρωνικού δικτύου [3]. Το Σχήμα 2.1 απεικονίζει το βασικό μαθηματικό μοντέλο ενός τέτοιου νευρώνα, το οποίο αποτελείται από τρία κύρια στοιχεία:

- Ένα σύνολο συνάψεων. Κάθε σύναψη χαρακτηρίζεται από μία αντίστοιχη τιμή βάρους (συναπτικό βάρος), η οποία ρυθμίζεται κατά την εκπαίδευση του τεχνητού νευρωνικού δικτύου. Η τιμή αυτή πολλαπλασιάζεται με το σήμα εισόδου x_i στην είσοδο της αντίστοιχης σύναψης, ενώ, σε αντίθεση με το βάρος μιας σύναψης του εγκεφάλου, μπορεί να λάβει τόσο θετικές όσο και αρνητικές τιμές [3].
- Έναν κόμβο άθροισης, στον οποίο υπολογίζεται το άθροισμα των σταθμισμένων σημάτων εισόδου του νευρώνα και της πόλωσης b .
- Μία συνάρτηση ενεργοποίησης (activation function), η οποία περιορίζει την τιμή του σήματος εξόδου του νευρώνα σε ένα πεπερασμένο εύρος τιμών [3]. Η συνάρτηση ενεργοποίησης, η οποία αναφέρεται και ως συνάρτηση μεταφοράς (transfer function), είναι επίσης αυτή που εισάγει τη μη γραμμικότητα στο μοντέλο του νευρώνα.



Σχήμα 2.1: Το μαθηματικό μοντέλο ενός τεχνητού νευρώνα

Όπως φαίνεται στο Σχήμα 2.1, ένας νευρώνας έχει τη δυνατότητα να δεχθεί ένα πλήθος n σημάτων εισόδου x_1, x_2, \dots, x_n και μία είσοδο για την πόλωση b παράγοντας ένα σήμα εξόδου y . Σε κάθε είσοδο x_1, x_2, \dots, x_n αντιστοιχεί ένα συναπτικό βάρος w_1, w_2, \dots, w_n , ενώ η πόλωση b εφαρμόζεται εξωτερικά μετατοπίζοντας την έξοδο z που προκύπτει από τον κόμβο άθροισης. Έτσι, η συνολική είσοδος του νευρώνα υπολογίζεται από την ακόλουθη εξίσωση:

$$z = w_1 \cdot x_1 + w_2 \cdot x_2 + \dots + w_n \cdot x_n + b = \sum_{i=1}^n w_i \cdot x_i + b \quad (2.1)$$


Η έξοδος z του κόμβου άθροισης αποτελεί την είσοδο της συνάρτησης ενεργοποίησης. Η έξοδος του νευρώνα υπολογίζεται ως εξής:

$$y = f(z) = f\left(\sum_{i=1}^n w_i \cdot x_i + b\right) \quad (2.2)$$

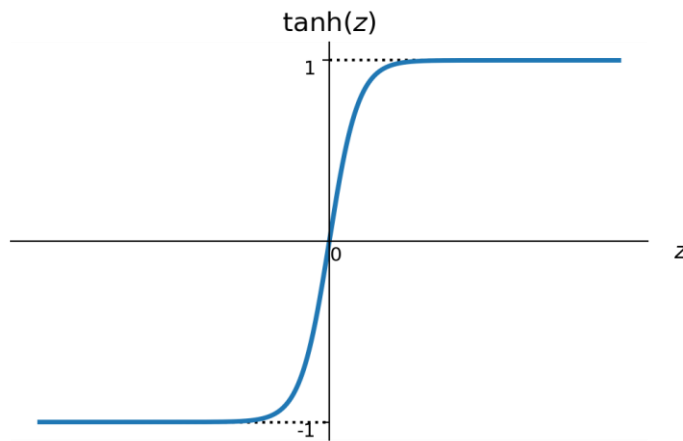
όπου f είναι η συνάρτηση ενεργοποίησης που έχει επιλεγθεί. Η πιο διαδεδομένη συνάρτηση ενεργοποίησης όσον αφορά τη σχεδίαση και την κατασκευή τεχνητών νευρωνικών δικτύων είναι η σιγμοειδής συνάρτηση (Σχήμα 2.2), η οποία ορίζεται ως εξής:

$$f(z) = \frac{1}{1 + e^{-z}} \quad (2.3)$$

Η σιγμοειδής συνάρτηση, όπως ορίζεται στην εξίσωση (2.3), είναι μια γνησίως αύξουσα συνάρτηση που λαμβάνει τιμές μεταξύ του 0 και του 1, ισορροπώντας ανάμεσα στη γραμμική και τη μη γραμμική συμπεριφορά [3].



Σχήμα 2.2: Σιγμοειδής συνάρτηση ενεργοποίησης



Σχήμα 2.3: Συνάρτηση υπερβολικής εφαπτομένης

Σε περιπτώσεις όπου είναι επιθυμητό η συνάρτηση ενεργοποίησης να λαμβάνει και αρνητικές τιμές, μπορεί να χρησιμοποιηθεί η συνάρτηση της υπερβολικής εφαπτομένης (Σχήμα 2.3), η οποία ορίζεται ως εξής:

$$f(z) \equiv \tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (2.4)$$

Η συνάρτηση της υπερβολικής εφαπτομένης παρουσιάζει το χαρακτηριστικό σχήμα S της σιγμοειδούς συνάρτησης, λαμβάνοντας ωστόσο τιμές μεταξύ του -1 και του 1 . Ταυτόχρονα, η μη γραμμικότητα που εισάγουν οι παραπάνω συναρτήσεις στο μοντέλο του νευρώνα ενισχύει περαιτέρω την ικανότητα ενός τεχνητού νευρωνικού δικτύου να μοντελοποιεί σύνθετες συναρτήσεις [4].

Ένα τεχνητό νευρωνικό δίκτυο δομείται συνδυάζοντας ένα πλήθος νευρώνων σειριακά και παράλληλα [4]. Οι νευρώνες που συνδυάζονται παράλληλα συγκροτούν

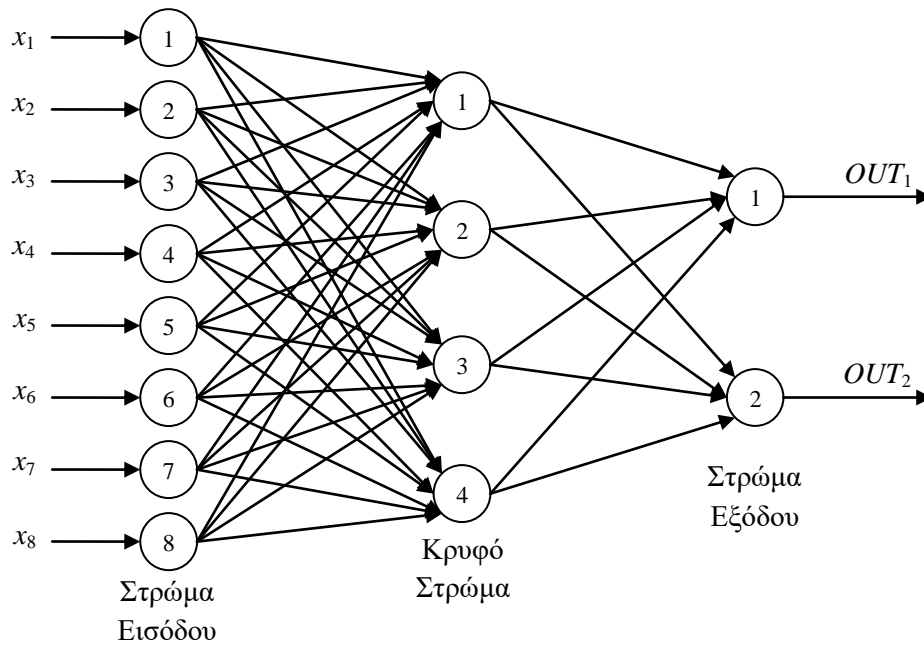
διακριτά στρώματα. Η πληροφορία εισέρχεται στο νευρωνικό δίκτυο μέσω του στρώματος εισόδου (input layer). Οι νευρώνες του στρώματος εισόδου είναι παθητικοί, καθώς δεν εκτελούν κάποιον υπολογισμό [6]. Η λειτουργία τους αφορά τη μετάδοση των δεδομένων εισόδου στο επόμενο στρώμα του νευρωνικού δικτύου μέσω των σταθμισμένων συνάψεών του. Συγκεκριμένα, κάθε νευρώνας του στρώματος εισόδου μεταδίδει μία μόνο τιμή δεδομένων που αντιστοιχεί σε ένα στοιχείο του διανύσματος εισόδου (input vector).

Το επόμενο στρώμα του νευρωνικού δικτύου είναι είτε το στρώμα εξόδου (output layer) είτε κάποιο κρυφό στρώμα (hidden layer). Ένα νευρωνικό δίκτυο μπορεί να περιέχει ένα ή περισσότερα κρυφά στρώματα, των οποίων οι νευρώνες καλούνται κρυφοί νευρώνες (hidden neurons). Ο όρος «hidden» αναφέρεται στο γεγονός ότι οι νευρώνες των κρυφών στρωμάτων δεν έρχονται σε άμεση επαφή με τις εισόδους και τις εξόδους του νευρωνικού δικτύου [3]. Ο ρόλος τους είναι να μεσολαβούν μεταξύ των εξωτερικών εισόδων και των εξόδων του δικτύου, συμβάλλοντας έτσι στην ικανότητά του να εξάγει περίπλοκες, μη γραμμικές σχέσεις ανάμεσα στις εισόδους και τις εξόδους του.

Το στρώμα εξόδου αποτελεί το τελευταίο επίπεδο του τεχνητού νευρωνικού δικτύου. Οι νευρώνες του, όπως και οι νευρώνες των κρυφών στρωμάτων, επεξεργάζονται τις εισόδους τους σύμφωνα με το μαθηματικό μοντέλο του Σχήματος 2.1 παράγοντας ένα συγκεκριμένο αποτέλεσμα. Στην περίπτωση του στρώματος εξόδου, το αποτέλεσμα αυτό αποτελεί τη συνολική απόκριση του δικτύου στις παρεχόμενες εισόδους.

Βάσει της δομής του δικτύου και του τρόπου με τον οποίο συνδέονται οι νευρώνες του, διακρίνονται δύο κύριες κατηγορίες όσον αφορά την αρχιτεκτονική των τεχνητών νευρωνικών δικτύων:

1. Τα νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης (feedforward neural networks). Αποτελούνται από το στρώμα εισόδου, κανένα, ένα ή περισσότερα κρυφά στρώματα και το στρώμα εξόδου. Στα νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης η πληροφορία ρέει από το στρώμα εισόδου στα κρυφά στρώματα, εάν υπάρχουν, και τέλος στο στρώμα εξόδου χωρίς να σχηματίζονται βρόχοι. Στο Σχήμα 2.4 απεικονίζεται η διάταξη ενός feedforward νευρωνικού δικτύου με ένα κρυφό στρώμα, το οποίο έχει 8 νευρώνες στο στρώμα εισόδου, 4 κρυφούς νευρώνες και 2 νευρώνες εξόδου. Ως εκ τούτου, αναφέρεται ως νευρωνικό δίκτυο με αρχιτεκτονική 8–4–2. Οι νευρώνες του στρώματος εισόδου διοχετεύουν τις εξωτερικές εισόδους στους υπολογιστικούς νευρώνες του κρυφού στρώματος. Στη συνέχεια, οι εξοδοί των κρυφών νευρώνων διοχετεύονται στους νευρώνες του στρώματος εξόδου που υπολογίζουν τη συνολική απόκριση του δικτύου. Αξίζει να σημειωθεί ότι το νευρωνικό δίκτυο του Σχήματος 2.4 είναι πλήρως διασυνδεδεμένο, καθώς όλοι οι νευρώνες κάθε στρώματος συνδέονται με όλους τους νευρώνες των γειτονικών στρωμάτων.
2. Τα αναδρομικά νευρωνικά δίκτυα. Διαφέρουν από τα feedforward νευρωνικά δίκτυα, επειδή περιέχουν τουλάχιστον έναν βρόχο ανατροφοδότησης (feedback loop) [3]. Η ύπαρξη βρόχων ανατροφοδότησης καθιστά τα αναδρομικά δίκτυα δυναμικά συστήματα, καθώς οι εξοδοί ορισμένων νευρώνων που υπολογίζονται με βάση ένα δεδομένο πρότυπο εισόδου ανατροφοδοτούνται στις εισόδους άλλων ή και των ίδιων νευρώνων, οδηγώντας έτσι το δίκτυο σε μια νέα κατάσταση.



Σχήμα 2.4: Πλήρως διασυνδεδεμένο νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης 8–4–2

2.4 ΔΙΑΔΙΚΑΣΙΑ ΤΗΣ ΕΚΠΑΙΔΕΥΣΗΣ

Η διαδικασία της εκπαίδευσης (διαδικασία της μάθησης) είναι αυτή που προσδίδει σε ένα τεχνητό νευρωνικό δίκτυο την ικανότητα να διακρίνει ανεπαίσθητες σχέσεις σε σύνθετα σύνολα δεδομένων. Τα νευρωνικά δίκτυα μπορούν να διακρίνουν τις σχέσεις αυτές χωρίς να απαιτείται πρότερη γνώση του προβλήματος που καλούνται να επιλύσουν ή των δεδομένων που θα χρησιμοποιηθούν. Η ύπαρξη πρότερης γνώσης μπορεί να βελτιώσει την απόδοσή τους, χωρίς όμως να αποτελεί προαπαιτούμενο. Αντίθετα, είναι απαραίτητη η ύπαρξη δεδομένων αντιπροσωπευτικών του προβλήματος προς επίλυση [6].

Η εκπαίδευση ενός τεχνητού νευρωνικού δικτύου αφορά την προσαρμογή των ελεύθερων παραμέτρων του (συναπτικά βάρη και πολώσεις). Συγκεκριμένα, το νευρωνικό δίκτυο τροφοδοτείται επαναλαμβανόμενα με δεδομένα εκπαίδευσης και προσαρμόζει τα συναπτικά βάρη και τις πολώσεις των νευρώνων του, ώστε να παραχθεί το επιθυμητό αποτέλεσμα. Αυτή η ικανότητα των νευρωνικών δικτύων να μαθαίνουν αυτόματα χρησιμοποιώντας πραγματικά δεδομένα τα καθιστά πιο ελκυστικά έναντι άλλων συμβατικών μεθόδων [8].

Διαφορετικές αρχιτεκτονικές τεχνητών νευρωνικών δικτύων απαιτούν αντίστοιχες διαδικασίες εκπαίδευσης. Η επιλογή της κατάλληλης διαδικασίας εξαρτάται, επίσης, από τα δεδομένα τα οποία είναι διαθέσιμα για την εκπαίδευση του νευρωνικού δικτύου. Γενικά, οι διαδικασίες εκπαίδευσης διακρίνονται στις εξής κατηγορίες:

1. τη μάθηση με επίβλεψη και
2. τη μάθηση χωρίς επίβλεψη (unsupervised learning).

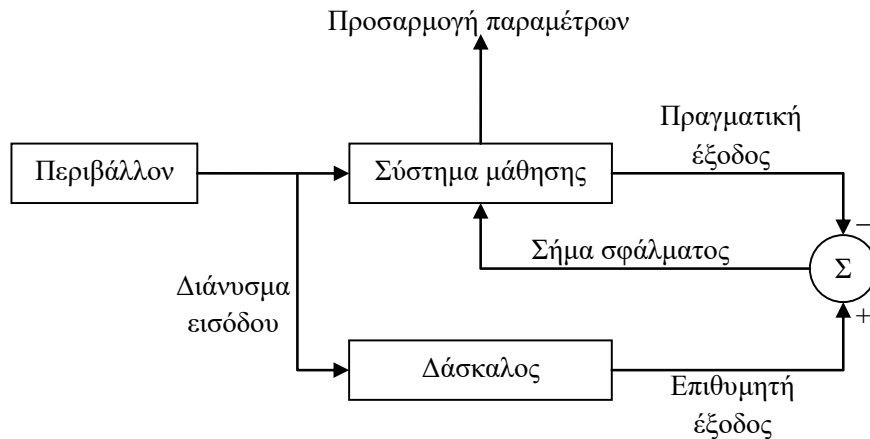
2.4.1 Μάθηση με επίβλεψη

Στη μάθηση με επίβλεψη, τα δεδομένα εκπαίδευσης με τα οποία τροφοδοτείται ένα τεχνητό νευρωνικό δίκτυο αποτελούνται από ζεύγη προτύπων εισόδου-εξόδου. Κάθε ζεύγος του συνόλου εκπαίδευσης (training set) αποτελείται από ένα πρότυπο εισόδου και την αντίστοιχη επιθυμητή έξοδο, με την οποία συγκρίνεται η πραγματική έξοδος του νευρωνικού δικτύου. Στη συνέχεια, τα συναπτικά βάρη και οι πολώσεις του τροποποιούνται με τέτοιο τρόπο, ώστε να ελαχιστοποιείται η απόκλιση μεταξύ της επιθυμητής και της πραγματικής απόκρισής του, δηλαδή το σήμα σφάλματος. Το νευρωνικό δίκτυο μπορεί να αξιοποιήσει επαναληπτικά τα δεδομένα του συνόλου εκπαίδευσης, αναπροσαρμόζοντας τα βάρη και τις πολώσεις του με σκοπό να προσεγγίσει όσο το δυνατόν καλύτερα την επιθυμητή έξοδο.

Η συγκεκριμένη διαδικασία εκπαίδευσης αναφέρεται, επίσης, ως μάθηση με δάσκαλο και περιγράφεται σχηματικά στο Σχήμα 2.5. Ο δάσκαλος, ο οποίος γνωρίζει την επιθυμητή έξοδο που αντιστοιχεί σε κάθε διάνυσμα εισόδου, μεταλαμπαδεύει την έμφυτη γνώση του στο τεχνητό νευρωνικό δίκτυο, το οποίο ρυθμίζει τις τιμές των ελεύθερων παραμέτρων του συναρτήσει των δεδομένων εισόδου και του σήματος σφάλματος. Έτσι, η παρεχόμενη γνώση αποθηκεύεται στις τιμές των συναπτικών βαρών και των πολώσεων των νευρώνων του δικτύου, οι οποίες παραμένουν σταθερές μετά το τέλος της διαδικασίας της εκπαίδευσης [3]. Το νευρωνικό δίκτυο που προκύπτει μπορεί πλέον να επεξεργαστεί παρεμφερή δεδομένα που του είναι άγνωστα, χωρίς να απαιτείται η επίβλεψη του δασκάλου.

Η ικανότητα γενίκευσης ενός τεχνητού νευρωνικού δικτύου μετράται από το πόσο καλά ανταποκρίνεται στα άγνωστα αυτά δεδομένα, ενώ η απόδοσή του πάνω στα δεδομένα εκπαίδευσης αφορά την ικανότητά του να απομνημονεύει τη σχέση μεταξύ των προτύπων εισόδου-εξόδου [17]. Δεδομένου ότι η ικανότητα γενίκευσης είναι ιδιαίτερα σημαντική, είναι απαραίτητη η αξιολόγηση της συμπεριφοράς του δικτύου πάνω σε δεδομένα που δεν ανήκουν στο σύνολο εκπαίδευσης. Για τον σκοπό αυτό, ένα μέρος των διαθέσιμων δεδομένων δεν χρησιμοποιείται κατά την εκπαίδευση του νευρωνικού δικτύου, αλλά δεσμεύεται για την αξιολόγησή του δημιουργώντας το σύνολο ελέγχου (test set). Το σύνολο ελέγχου, λοιπόν, περιλαμβάνει τα δεδομένα επιβεβαίωσης τα οποία, όπως και τα δεδομένα εκπαίδευσης, πρέπει να είναι αντιπροσωπευτικά της λειτουργίας που προσπαθεί να επιτελέσει το νευρωνικό δίκτυο. Η απόδοση του δικτύου θεωρείται ικανοποιητική εάν οι τιμές του μετρητικού σφάλματος που υπολογίζονται για τα δεδομένα εκπαίδευσης και για τα δεδομένα επιβεβαίωσης είναι ικανοποιητικά μικρές. Παράλληλα, πρέπει να είναι μικρή και η απόκλιση μεταξύ των δύο υπολογιζόμενων τιμών.

Η μάθηση με επίβλεψη χρησιμοποιείται ως διαδικασία εκπαίδευσης σε πολλές αρχιτεκτονικές τεχνητών νευρωνικών δικτύων, όπως το Perceptron και τα δίκτυα εμπρόσθιας τροφοδότησης πολλών στρωμάτων με προς τα πίσω διάδοση του σφάλματος [17]. Ωστόσο, υπάρχουν περιπτώσεις νευρωνικών δικτύων που δεν μπορούν να προσεγγίσουν ικανοποιητικά τη σχέση μεταξύ εισόδου και εξόδου. Η αδυναμία εκπαίδευσης ενός νευρωνικού δικτύου μπορεί να οφείλεται είτε στη χρησιμοποίηση ακατάλληλων ή ανεπαρκών δεδομένων εκπαίδευσης είτε σε προβλήματα που αφορούν τη σχεδίαση του τεχνητού νευρωνικού δικτύου.



Σχήμα 2.5: Δομικό διάγραμμα της διαδικασίας μάθησης με επίβλεψη

2.4.2 Μάθηση χωρίς επίβλεψη

Στη μάθηση χωρίς επίβλεψη, η οποία αναφέρεται και ως μάθηση χωρίς δάσκαλο, το τεχνητό νευρωνικό δίκτυο τροφοδοτείται με δεδομένα εκπαίδευσης τα οποία περιλαμβάνουν αποκλειστικά πρότυπα εισόδου. Το νευρωνικό δίκτυο εξερευνά την υποκείμενη δομή των δεδομένων εισόδου καθώς και συσχετίσεις μεταξύ μοτίβων που παρατηρούνται στα δεδομένα αυτά [8]. Στόχος του είναι να προσδιορίσει φυσικές ομάδες ή όμοια χαρακτηριστικά σε ένα συγκεκριμένο σύνολο προτύπων εισόδου [17] και να οργανώσει σε αντίστοιχες κατηγορίες τα πρότυπα αυτά.

Επομένως, τα νευρωνικά δίκτυα που μαθαίνουν χωρίς επίβλεψη δεν χρησιμοποιούν εξωτερική βοήθεια (δάσκαλο) για να προσαρμόσουν τις παραμέτρους τους. Αντίθετα, παρακολουθούν εσωτερικά την απόδοσή τους, όσον αφορά τη λειτουργία για την οποία εκπαιδεύονται, βάσει της τοπολογίας του νευρωνικού δικτύου και των εφαρμοζόμενων κανόνων μάθησης [18]. Το τελικό αποτέλεσμα του δικτύου αξιολογείται και από τον χρήστη του, ώστε να διαπιστωθεί εάν η ταξινόμηση που πραγματοποιεί έχει κάποια πρακτική σημασία [17].

Η μάθηση χωρίς επίβλεψη αποτελεί πιο γρήγορη διαδικασία εκπαίδευσης από τη μάθηση με επίβλεψη, αλλά είναι λιγότερο ακριβής. Χρησιμοποιείται σε αρχιτεκτονικές τεχνητών νευρωνικών δικτύων όπως τα δίκτυα Θεωρίας Προσαρμοστικού Συντονισμού (Adaptive Resonance Theory – ART) [19] και οι αυτοοργανωόμενοι χάρτες χαρακτηριστικών (Self-Organizing Feature Maps – SOM) ή δίκτυα Kohonen [20]. Τα νευρωνικά δίκτυα με μάθηση χωρίς επίβλεψη χρησιμοποιούνται για συμπίεση δεδομένων, ανακάλυψη χαρακτηριστικών, αναγνώριση προτύπων και clustering, ενώ συχνά χρησιμοποιούν κανόνες ανταγωνιστικής μάθησης κατά την εκπαίδευσή τους. Στην ανταγωνιστική μάθηση οι νευρώνες εξόδου ανταγωνίζονται μεταξύ τους για το ποιος θα ενεργοποιηθεί, με αποτέλεσμα να είναι ενεργός κάθε φορά μόνο ένας νευρώνας εξόδου [8].

2.5 ΑΝΤΙΚΕΙΜΕΝΙΚΕΣ ΣΥΝΑΡΤΗΣΕΙΣ ΕΚΠΑΙΔΕΥΣΗΣ

Στη μάθηση με επίβλεψη, η οποία χρησιμοποιείται για την εκπαίδευση όλων των τεχνητών νευρωνικών δικτύων που υλοποιούνται στην παρούσα διπλωματική εργασία, η επιθυμητή έξοδος παρέχεται στο νευρωνικό δίκτυο, ώστε να συγκριθεί με την αντίστοιχη πραγματική έξοδο που παράγεται από το δίκτυο. Στη συνέχεια, υπολογίζεται το αντίστοιχο σήμα σφάλματος βάσει του οποίου τροποποιούνται τα συναπτικά βάρη και οι νευρώνες του δικτύου με σκοπό τη σταδιακή ελαχιστοποίηση του σφάλματος. Ο συγκεκριμένος κανόνας μάθησης, ο οποίος χρησιμοποιείται σε πολλές αρχιτεκτονικές δικτύων μάθησης με επίβλεψη, αναφέρεται ως κανόνας διόρθωσης σφάλματος [8].

Το σήμα σφάλματος υπολογίζεται για κάθε ζεύγος προτύπων εισόδου-εξόδου του συνόλου εκπαίδευσης, ενώ στη συνέχεια υπολογίζεται η μέση τιμή όλων των σφαλμάτων για το σύνολο των δεδομένων εκπαίδευσης. Συνήθως, η συνάρτηση που υπολογίζει τη μέση τιμή των σφαλμάτων μετασχηματίζει, ταυτόχρονα, τα ανεπεξέργαστα σφάλματα ανάλογα με την αρχιτεκτονική του νευρωνικού δικτύου ή τον σκοπό της εφαρμογής στην οποία πρόκειται να χρησιμοποιηθεί [18]. Η συνάρτηση αυτή αποτελεί την αντικειμενική συνάρτηση εκπαίδευσης του τεχνητού νευρωνικού δικτύου.

Ως μέτρο της απόδοσης ενός νευρωνικού δικτύου, η αντικειμενική συνάρτηση εκπαίδευσης ορίζεται συναρτήσει των ελεύθερων παραμέτρων του, δηλαδή των συναπτικών βαρών και των πολώσεων των νευρώνων του. Η συνάρτηση αυτή θα μπορούσε να οπτικοποιηθεί ως μία πολυδιάστατη επιφάνεια σφάλματος (error surface) με τις ελεύθερες παραμέτρους ως συντεταγμένες [3]. Η επιτυχημένη εκπαίδευση του δικτύου έγκειται στην εύρεση ενός σημείου της επιφάνειας σφάλματος – δηλαδή ενός συγκεκριμένου συνόλου τιμών για τα βάρη και τις πολώσεις – στο οποίο το υπολογιζόμενο σφάλμα ελαχιστοποιείται. Ένα νευρωνικό δίκτυο μάθησης με επίβλεψη είναι ικανό να φτάσει σε ένα τέτοιο σημείο, είτε πρόκειται για τοπικό είτε για ολικό ελάχιστο, αξιοποιώντας τη γνώση που διαθέτει σχετικά με την κλίση της επιφάνειας σφάλματος και την αντίστοιχη επιθυμητή απόκριση του δικτύου [3].

Η επιλογή της κατάλληλης αντικειμενικής συνάρτησης είναι συνυφασμένη με τη φύση του προβλήματος που το νευρωνικό δίκτυο καλείται να επιλύσει. Για παράδειγμα, υπάρχουν προβλήματα για τα οποία απαιτείται η μεγιστοποίηση μιας αντικειμενικής συνάρτησης. Αντίθετα, στα νευρωνικά δίκτυα που σχεδιάζονται και κατασκευάζονται για πρόβλεψη απαιτείται η ελαχιστοποίηση της επιλεγμένης αντικειμενικής συνάρτησης, η οποία αναφέρεται και ως συνάρτηση κόστους (cost function). Ορισμένες συναρτήσεις κόστους που χρησιμοποιούνται συχνά είναι οι εξής:

- Μέσο Απόλυτο Σφάλμα (Mean Absolute Error – *MAE*)

$$MAE = \frac{1}{N} \cdot \sum_{i=1}^N |y_{des,i} - y_{act,i}| \quad (2.5)$$

- Μέσο Τετραγωνικό Σφάλμα (Mean Square Error – *MSE*)

$$MSE = \frac{1}{N} \cdot \sum_{i=1}^N (y_{des,i} - y_{act,i})^2 \quad (2.6)$$

- Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (Mean Absolute Percentage Error – *MAPE*)

$$MAPE = \frac{1}{N} \cdot \sum_{i=1}^N \left| \frac{y_{des,i} - y_{act,i}}{y_{act,i}} \right| \times 100\% \quad (2.7)$$

όπου N είναι το πλήθος των δεδομένων του συνόλου εκπαίδευσης, $y_{des,i}$ είναι η επιθυμητή έξοδος για το δεδομένο εκπαίδευσης i και $y_{act,i}$ είναι η πραγματική έξοδος που παράγει το τεχνητό νευρωνικό δίκτυο όταν δέχεται ως είσοδο το δεδομένο εκπαίδευσης i .

2.6 ΥΠΕΡΠΑΡΑΜΕΤΡΟΙ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Παρά τα σημαντικά πλεονεκτήματα που προσφέρει η χρησιμοποίηση των τεχνητών νευρωνικών δικτύων, η εκπαίδευσή τους συχνά παρουσιάζει δυσκολίες, καθώς η απόδοσή τους εξαρτάται από ένα μεγάλο πλήθος παραμέτρων. Οι παράμετροι αυτές σχετίζονται με την αρχιτεκτονική, τη συμπεριφορά των νευρώνων και τον αλγόριθμο εκπαίδευσης του νευρωνικού δικτύου καθώς και με τον τρόπο διαχείρισης των διαθέσιμων δεδομένων, και συνιστούν τις υπερπαραμέτρους που απαντώνται στα περισσότερα τεχνητά νευρωνικά δίκτυα.

Οι υπερπαραμέτροι ενός νευρωνικού δικτύου είναι μεταβλητές οι οποίες ορίζονται εξωγενώς, και όχι από το νευρωνικό δίκτυο καθαυτό, προτού αυτό τροφοδοτηθεί με τα δεδομένα εκπαίδευσης. Σε αντίθεση με τα συναπτικά βάρη και τις πολώσεις των νευρώνων που προσαρμόζονται κατά τη διαδικασία της εκπαίδευσης, οι υπερπαραμέτροι δεν μπορούν να εκτιμηθούν με χρήση των διαθέσιμων δεδομένων, αφού καθορίζουν το μοντέλο νευρωνικού δικτύου που εκπαιδεύεται. Οι τιμές που λαμβάνουν μπορούν να είναι διακριτές, συνεχείς ή και κατηγορήματα, ενώ επιλέγονται είτε χειροκίνητα είτε με τη βοήθεια αλγορίθμου [21].

Η κατάλληλη επιλογή των παραπάνω τιμών είναι ιδιαίτερα κρίσιμη, καθώς επηρεάζει άμεσα τη συμπεριφορά του νευρωνικού δικτύου. Επομένως, η βελτιστοποίηση των τιμών των υπερπαραμέτρων του αφορά την ελαχιστοποίηση (ή τη μεγιστοποίηση) της επιλεγμένης αντικειμενικής συνάρτησης. Ωστόσο, εξαιτίας του εμπειρικού τρόπου εκπαίδευσης των νευρωνικών δικτύων και της γενικότερης προσαρμοστικής φύσης τους, η βέλτιστη επιλογή των τιμών των υπερπαραμέτρων τους απαιτεί πειραματισμό, με τα αποτελέσματα να εξαρτώνται εν μέρει από την πειραματική τεχνική που χρησιμοποιείται [6]. Έτσι, η διαδικασία σχεδίασης ενός βέλτιστου μοντέλου, δηλαδή η διαδικασία ρύθμισης των υπερπαραμέτρων του με σκοπό την εύρεση της βέλτιστης διαμόρφωσης (hyperparameter

tuning), μπορεί να αποδειχθεί ιδιαίτερα σύνθετη και χρονοβόρα, ειδικά για μοντέλα που περιλαμβάνουν μεγάλο πλήθος υπερπαραμέτρων.

Η διαδικασία ρύθμισης των υπερπαραμέτρων είναι διαφορετική για τα διάφορα μοντέλα Μηχανικής Μάθησης (Machine Learning – ML), καθώς διαφέρουν τα σύνολα υπερπαραμέτρων που περιλαμβάνουν. Οι υπερπαραμέτροι των τεχνητών νευρωνικών δικτύων διακρίνονται στις εξής κατηγορίες [22]:

1. αυτές που σχετίζονται με τη σχεδίαση και την κατασκευή του μοντέλου του τεχνητού νευρωνικού δικτύου και
2. αυτές που σχετίζονται με τον αλγόριθμο βελτιστοποίησης (optimizer) που χρησιμοποιείται κατά τη διαδικασία της εκπαίδευσης του παραπάνω μοντέλου.

2.6.1 Υπερπαραμέτροι σχεδίασης μοντέλου

Οι υπερπαραμέτροι σχεδίασης μοντέλου αφορούν την αρχιτεκτονική του τεχνητού νευρωνικού δικτύου, τη συμπεριφορά των νευρώνων του καθώς και την επεξεργασία των διαθέσιμων δεδομένων. Οι κυριότερες από αυτές είναι οι ακόλουθες:

- **Ο αριθμός των κρυφών στρωμάτων.** Οι νευρώνες των κρυφών στρωμάτων είναι αυτοί που επιτρέπουν σε ένα νευρωνικό δίκτυο να αναγνωρίζει μοτίβα σε ένα σύνολο δεδομένων και να δημιουργεί σύνθετες, μη γραμμικές χαρτογραφήσεις εισόδου-εξόδου [23]. Έτσι, συχνά χρησιμοποιούνται πολυστρωματικά νευρωνικά δίκτυα (multilayer perceptrons), δηλαδή δίκτυα με ένα ή περισσότερα κρυφά στρώματα. Σύμφωνα με το θεώρημα καθολικής προσέγγισης (universal approximation theorem), η παρουσία ενός κρυφού στρώματος επαρκεί, ώστε ένα multilayer perceptron να προσεγγίσει ομοιόμορφα οποιαδήποτε συνάρτηση πληροί τις προϋποθέσεις του θεωρήματος [3], [24]. Παρά το γεγονός ότι το παραπάνω θεώρημα παρέχει μόνο την απαραίτητη μαθηματική αιτιολόγηση για την ύπαρξη ενός τέτοιου νευρωνικού δικτύου, χωρίς να διευκρινίζει τον τρόπο με τον οποίο αυτό προσδιορίζεται, η χρήση μόνο ενός κρυφού στρώματος είναι ιδιαίτερα διαδεδομένη. Ωστόσο, σε ορισμένες περιπτώσεις, η χρήση δύο κρυφών στρωμάτων μπορεί να οδηγήσει σε καλύτερα αποτελέσματα, ειδικά όταν μια αρχιτεκτονική ενός κρυφού στρώματος απαιτεί μεγάλο πλήθος κρυφών νευρώνων για την επίτευξη ικανοποιητικών αποτελεσμάτων [23].
- **Ο αριθμός των νευρώνων.** Το μέγεθος κάθε στρώματος ενός πολυστρωματικού νευρωνικού δικτύου μπορεί να οριστεί ελεύθερα από τον χρήστη του. Ο αριθμός των στρωμάτων και ο αριθμός των νευρώνων κάθε στρώματος ενός μοντέλου καθορίζουν την ικανότητά του να προσεγγίσει σύνθετες συναρτήσεις. Ένα νευρωνικό δίκτυο με πολύ λίγους νευρώνες ενδέχεται να μην διαθέτει την απαραίτητη ισχύ για να συλλάβει τις σχέσεις που διέπουν τα δεδομένα εκπαίδευσης (υποπροσαρμογή). Αντίθετα, ένα δίκτυο με υπερβολικά μεγάλο αριθμό νευρώνων μπορεί να καταλήξει στην απομνημόνευση του συνόλου

εκπαίδευσης, χάνοντας έτσι την ικανότητα της γενίκευσης (υπερπροσαρμογή). Επομένως, η εύρεση του βέλτιστου αριθμού νευρώνων είναι κρίσιμη όσον αφορά την αποτελεσματική χαρτογράφηση εισόδου-εξόδου. Δεδομένου ότι ο αριθμός των νευρώνων του στρώματος εξόδου συνδέεται άμεσα με το προς επίλυση πρόβλημα, η διαδικασία βελτιστοποίησης του αριθμού των νευρώνων αφορά κυρίως τους νευρώνες εισόδου και τους νευρώνες των κρυφών στρωμάτων. Όπως συμβαίνει και με άλλες υπερπαραμέτρους, ο αριθμός των κρυφών νευρώνων μπορεί να είναι διαφορετικός σε κάθε κρυφό στρώμα που χρησιμοποιείται [21].

- **Η διασύνδεση των νευρώνων.** Η αρχιτεκτονική ενός τεχνητού νευρωνικού δικτύου χαρακτηρίζεται και από τον τρόπο διασύνδεσης των νευρώνων του. Σε πολλές εφαρμογές πρόβλεψης, αλλά και σε άλλες εφαρμογές, τα νευρωνικά δίκτυα είναι πλήρως διασυνδεδεμένα [23], εφαρμόζοντας έναν τρόπο διασύνδεσης αντίστοιχο με αυτόν που απεικονίζεται στο Σχήμα 2.4.
- **Η αντικειμενική συνάρτηση εκπαίδευσης.** Η επιλογή της κατάλληλης αντικειμενικής συνάρτησης εκπαίδευσης βασίζεται κυρίως στη φύση του προβλήματος προς επίλυση. Οι διάφορες αντικειμενικές συναρτήσεις που χρησιμοποιούνται κατά τη διαδικασία της εκπαίδευσης μπορούν, επίσης, να χρησιμοποιηθούν ως συναρτήσεις αξιολόγησης (μετρικά σφάλματος) της απόδοσης του μοντέλου για διαφορετικές διαμορφώσεις υπερπαραμέτρων.
- **Η συνάρτηση ενεργοποίησης.** Η επιλογή της κατάλληλης συνάρτησης ενεργοποίησης αφορά αποκλειστικά τα κρυφά στρώματα και το στρώμα εξόδου. Σε ένα multilayer perceptron, η μοναδική απαίτηση που πρέπει να ικανοποιούν οι επιλεγμένες συναρτήσεις ενεργοποίησης είναι η διαφορισμότητα [3]. Δύο παραδείγματα συνεχώς διαφορισμών συναρτήσεων ενεργοποίησης είναι η σιγμοειδής και η υπερβολική εφαπτομένη, οι οποίες περιγράφονται στην Ενότητα 2.3. Οι συχνά χρησιμοποιούμενες συναρτήσεις ενεργοποίησης διαθέτουν ορισμένες επιπρόσθετες επιθυμητές ιδιότητες, όπως το ότι είναι φραγμένες και γνησίως αύξουσες [23].
- **Επεξεργασία δεδομένων.** Κατά τη διαδικασία της εκπαίδευσης, οι διαθέσιμες συναρτήσεις ενεργοποίησης συχνά περιορίζουν τις εξόδους των νευρώνων σε ένα πεπερασμένο εύρος τιμών, όπως από 0 έως 1 (σιγμοειδής) ή από -1 έως 1 (υπερβολική εφαπτομένη). Έτσι, συνήθως προηγείται μια διαδικασία κανονικοποίησης των διαθέσιμων δεδομένων σε ένα κατάλληλο εύρος τιμών.
- **Ο αλγόριθμος βελτιστοποίησης.** Ο αλγόριθμος βελτιστοποίησης αφορά τη διαδικασία εκπαίδευσης του νευρωνικού δικτύου. Συγκεκριμένα, καθορίζει τον τρόπο με τον οποίο αναπροσαρμόζονται επαναληπτικά τα συναπτικά βάρη και οι πολώσεις των νευρώνων του δικτύου, ώστε να ελαχιστοποιηθεί (ή να μεγιστοποιηθεί) η αντικειμενική συνάρτηση. Παρά την ύπαρξη πολλών αλγορίθμων βελτιστοποίησης, δεν είναι δεδομένο ότι η εκπαίδευση του δικτύου θα καταλήξει στην ολική βέλτιστη λύση. Έτσι, ο κατάλληλος αλγόριθμος βελτιστοποίησης είναι συχνά αυτός που οδηγεί στο καλύτερο τοπικό βέλτιστο [23].

2.6.2 Υπερπαράμετροι αλγορίθμου βελτιστοποίησης

Οι υπερπαράμετροι αλγορίθμου βελτιστοποίησης αφορούν τη διαδικασία της εκπαίδευσης του τεχνητού νευρωνικού δικτύου και τη μέθοδο με την οποία αυτή βελτιστοποιείται. Οι σημαντικότερες από αυτές είναι οι ακόλουθες:

- **Ο ρυθμός μάθησης (learning rate).** Ο ρυθμός μάθησης, ο οποίος αποτελεί μέρος όλων των διαθέσιμων αλγορίθμων βελτιστοποίησης, είναι μία από τις σημαντικότερες υπερπαραμέτρους ενός νευρωνικού δικτύου, καθώς σχετίζεται με την ικανότητα και την ταχύτητα σύγκλισης του αλγορίθμου στις βέλτιστες τιμές των ελεύθερων παραμέτρων. Ο ρυθμός μάθησης καθορίζει το μέγεθος της επιτρεπόμενης αλλαγής που υφίστανται οι ελεύθερες παράμετροι του δικτύου σε κάθε επανάληψη. Ένας μεγάλος ρυθμός μάθησης επιταχύνει τη διαδικασία της εκπαίδευσης, αλλά μπορεί να εγκλωβίσει τον αλγόριθμο σε κάποιο τοπικό βέλτιστο ή ακόμα και να καταστήσει αδύνατη τη σύγκλιση [22]. Αντίθετα, ένας μικρός ρυθμός μάθησης μπορεί να αυξήσει δραματικά τον χρόνο εκπαίδευσης που οδηγεί σε σύγκλιση. Αναφέρεται και ως αρχικός ρυθμός μάθησης, καθώς υπάρχουν αλγόριθμοι βελτιστοποίησης που τον προσαρμόζουν κατά τη διάρκεια της εκπαίδευσης.
- **Η ορμή (momentum).** Ο όρος της ορμής επιτρέπει την προσαρμογή των ελεύθερων παραμέτρων μίας επανάληψης χρησιμοποιώντας πληροφορίες που σχετίζονται με τις προσαρμογές της προηγούμενης επανάληψης. Έτσι, συμβάλλει στη μείωση του φαινομένου της ταλάντωσης γύρω από κάποιο τοπικό βέλτιστο εξαιτίας της επιλογής μεγάλου ρυθμού μάθησης [23].
- **Ο αριθμός των εποχών (number of epochs).** Για πεπερασμένα σύνολα εκπαίδευσης, μία εποχή εκπαίδευσης συνιστά την τροφοδότηση του νευρωνικού δικτύου με το σύνολο των δεδομένων εκπαίδευσης. Η εκπαίδευση ενός δικτύου συνήθως απαιτεί έναν μεγάλο αριθμό εποχών, δηλαδή πολλές διαδοχικές σαρώσεις ολόκληρου του συνόλου εκπαίδευσης. Ο αριθμός των εποχών εξαρτάται από το μέγεθος του συνόλου εκπαίδευσης και ρυθμίζεται αυξάνοντάς τον σταδιακά. Εφόσον επιτευχθεί η σύγκλιση του μοντέλου, η περαιτέρω εκπαίδευσή του για περισσότερες εποχές μπορεί να οδηγήσει σε άσκοπη αύξηση του χρόνου εκτέλεσης και υπερπροσαρμογή [22]. Αυτό μπορεί να αποφευχθεί χρησιμοποιώντας τη μέθοδο early stopping [21].
- **To mini-batch size.** Το mini-batch size (μέγεθος μίνι παρτίδας) αποτελεί τον αριθμό των δειγμάτων που επεξεργάζεται το νευρωνικό δίκτυο, προτού προχωρήσει σε αναπροσαρμογή των συναπτικών βαρών και των πολώσεων των νευρώνων του. Για mini-batch size ίσο με 1, οι ελεύθερες παράμετροι του δικτύου ανανεώνονται μετά από κάθε δείγμα που επεξεργάζεται (on-line learning). Η αύξηση του mini-batch size αποφέρει μεν πιο γρήγορους υπολογισμούς, αλλά απαιτεί περισσότερα δείγματα για την επίτευξη του ίδιου σφάλματος, καθώς πραγματοποιούνται λιγότερες ανανεώσεις παραμέτρων ανά εποχή [21]. Για mini-batch size ίσο με το μέγεθος του συνόλου εκπαίδευσης, οι ελεύθερες παράμετροι προσαρμόζονται αφού το νευρωνικό δίκτυο επεξεργαστεί

όλα τα δεδομένα εκπαίδευσης, δηλαδή πραγματοποιείται μόνο μία προσαρμογή παραμέτρων ανά εποχή (batch learning). Συνήθως, το mini-batch size επιλέγεται μεταξύ του ένα (1) και μερικών εκατοντάδων, με το 32 να αποτελεί μια πολύ συνηθισμένη προεπιλογή [21].

ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

3.1 Η ΣΠΟΥΔΑΙΟΤΗΤΑ ΤΗΣ ΠΡΟΒΛΕΨΗΣ

Από τα μέσα του 20^{ού} αιώνα, έχουν παρατηρηθεί αλλαγές στο κλίμα της Γης οι οποίες υποκινούνται από ανθρώπινες δραστηριότητες. Οι δραστηριότητες αυτές, και ιδιαίτερα η καύση ορυκτών καυσίμων, αυξάνουν τα επίπεδα αερίων του θερμοκηπίου στην ατμόσφαιρα της Γης, οδηγώντας σε αύξηση της μέσης θερμοκρασίας της επιφάνειάς της [25]. Συγκεκριμένα, οι ανθρωπογενείς εκπομπές αερίων του θερμοκηπίου – όπως το διοξείδιο του άνθρακα (CO₂), το μεθάνιο (CH₄), το υποξείδιο του αζώτου (N₂O) και οι χλωροφθοράνθρακες (CFCs) – παγιδεύουν μεγάλο μέρος της θερμότητας που εκπέμπεται από την επιφάνεια της Γης προς το διάστημα στην ατμόσφαιρα της Γης, επιβραδύνοντας την απώλεια θερμότητας στο διάστημα [26].

Η ανθρωπογενής αυτή επέκταση του «φαινομένου του θερμοκηπίου» είχε ως αποτέλεσμα τη μακροχρόνια αύξηση της θερμοκρασίας της επιφάνειας της Γης, η οποία εκφράζεται συγκριτικά με την προβιομηχανική περίοδο, δηλαδή την περίοδο μεταξύ 1850–1900. Συγκεκριμένα, από τα τέλη του 19^{ου} αιώνα, εκτιμάται ότι οι ανθρώπινες δραστηριότητες έχουν οδηγήσει σε αύξηση της μέσης θερμοκρασίας της επιφάνειας του πλανήτη κατά 1 βαθμό Κελσίου (°C), αριθμός που πλέον αυξάνεται κατά 0,2°C ανά δεκαετία [25]. Παρά το γεγονός ότι το κλίμα της Γης έχει υποστεί διάφορες αλλαγές, εξαιτίας φυσικών διαδικασιών, στο πέρασμα του χρόνου, η κλιματική αλλαγή που παρατηρείται από τα μέσα του 20^{ού} αιώνα εξελίσσεται σε παγκόσμιο επίπεδο με πολύ ταχύτερους ρυθμούς [27], καθώς τα αυξανόμενα επίπεδα αερίων του θερμοκηπίου παγιδεύουν επιπρόσθετη ενέργεια, η οποία θερμαίνει την ατμόσφαιρα, τους ωκεανούς και το έδαφος του πλανήτη.

Πέρα από την αύξηση της μέσης επιφανειακής θερμοκρασίας της Γης, ήδη παρατηρείται ένα ευρύ φάσμα επιδράσεων στο περιβάλλον του πλανήτη από τη ραγδαία αυτή κλιματική αλλαγή. Σε αυτές περιλαμβάνονται η αύξηση της θερμοκρασίας και η οξίνιση των ωκεανών, η συρρίκνωση των πάγων της Ανταρκτικής και άλλων περιοχών, η υποχώρηση πολλών παγετώνων, η αύξηση της στάθμης της θάλασσας και η αύξηση της συχνότητας εμφάνισης ακραίων καιρικών φαινομένων [28]. Παράλληλα, οι παραπάνω περιβαλλοντικές επιπτώσεις δημιουργούν επιπρόσθετες προκλήσεις σε πολλούς τομείς της ανθρώπινης ζωής, καθώς έχουν αντίκτυπο στην οικονομία, την κοινωνία, την ανθρώπινη υγεία, τις υποδομές και σε άλλα οικοσυστήματα.

Η σοβαρότητα των μελλοντικών επιδράσεων της κλιματικής αλλαγής θα εξαρτηθεί από την αντίστοιχη πορεία των ανθρώπινων δραστηριοτήτων που την προκαλούν, καθώς περαιτέρω αύξηση των εκπομπών αερίων του θερμοκηπίου θα οδηγήσει σε πιο ακραίες κλιματικές συνθήκες και εκτεταμένες επιβλαβείς επιπτώσεις, οι οποίες θα πλήξουν ολόκληρο τον πλανήτη [29]. Έτσι, τα τελευταία χρόνια διενεργούνται πολλές συζητήσεις και

καταγράφονται σημαντικές προσπάθειες όσον αφορά τον μετριασμό της κλιματικής αλλαγής και την αντιμετώπιση των συνεπειών της. Η Συμφωνία του Παρισιού (Paris Agreement), η οποία εγκρίθηκε στις 12 Δεκεμβρίου του 2015 στην 21^η Διάσκεψη των Μερών (Conference of the Parties – COP 21) στο Παρίσι και τέθηκε σε ισχύ στις 4 Νοεμβρίου του 2016, αποτελεί ορόσημο για αυτές τις προσπάθειες.

Με τη Συμφωνία του Παρισιού, τα Μέρη της Σύμβασης-Πλαισίου των Ηνωμένων Εθνών για την Κλιματική Αλλαγή (United Nations Framework Convention on Climate Change – UNFCCC) στοχεύουν, μεταξύ άλλων, στο να περιορίσουν την αύξηση της παγκόσμιας μέσης θερμοκρασίας πολύ χαμηλότερα από τους 2°C σε σχέση με τα προβιομηχανικά επίπεδα [30]. Παράλληλα, δεσμεύονται να καταβάλουν προσπάθειες, ώστε η παραπάνω αύξηση να περιοριστεί στον 1,5°C, αναγνωρίζοντας ότι αυτό θα ελάττωνε σημαντικά τους κινδύνους και την επίδραση της κλιματικής αλλαγής [30]. Η επίτευξη αυτού του μακροπρόθεσμου στόχου επιδιώκεται μέσω της μείωσης των εκπομπών αερίων του θερμοκηπίου, καθώς κάθε Μέρος της Συμφωνίας δεσμεύεται να προετοιμάσει, να επικοινωνήσει και να συντηρήσει διαδοχικά σχέδια κλιματικής δράσης, τα οποία περιλαμβάνουν μέτρα μείωσης των εκπομπών, ώστε να επιτευχθούν οι στόχοι της Συμφωνίας [31].

Σύμφωνα με την ειδική έκθεση για την υπερθέρμανση του πλανήτη κατά 1,5°C, η οποία δημοσιεύθηκε το 2018 από τη Διακυβερνητική Επιτροπή για την Κλιματική Αλλαγή (Intergovernmental Panel on Climate Change – IPCC), ο περιορισμός της αύξησης της θερμοκρασίας στον 1,5°C, σε σχέση με τα προβιομηχανικά επίπεδα, με μηδενική ή περιορισμένη υπέρβαση προϋποθέτει τη μείωση των καθαρών ανθρωπογενών εκπομπών CO₂ κατά 45%, σε σχέση με τα επίπεδα του 2010, έως το 2030 [32]. Προϋποθέτει, επίσης, την επίτευξη μηδενικών καθαρών εκπομπών CO₂, σε παγκόσμιο επίπεδο, γύρω στο 2050 και, ταυτόχρονα, τη δραστική μείωση των εκπομπών άλλων αερίων του θερμοκηπίου, ιδιαίτερα του μεθανίου [32]. Ο μετασχηματισμός του τομέα της ενέργειας, ο οποίος παραμένει σε μεγάλο βαθμό εξαρτημένος από τα ορυκτά καύσιμα, θα διαδραματίσει καταλυτικό ρόλο στην επίτευξη των παραπάνω απαιτούμενων μειώσεων. Στο πλαίσιο αυτού του μετασχηματισμού εντάσσεται και η απανθρακοποίηση (decarbonization) του τομέα της ηλεκτρικής ενέργειας, και ιδιαίτερα της παραγωγής της.

Η βιομηχανία παραγωγής ηλεκτρικής ενέργειας διατηρεί τη μεγάλη της εξάρτηση από τα ορυκτά καύσιμα, με αποτέλεσμα να συμβάλλει σημαντικά στις εκπομπές CO₂ και άλλων αερίων του θερμοκηπίου. Συγκεκριμένα, το 2019, η παγκόσμια παραγωγή ηλεκτρικής ενέργειας προήλθε σε ποσοστό 63,1% από ορυκτά καύσιμα, όπως το κάρβουνο, το φυσικό αέριο και το πετρέλαιο [33]. Στο πλαίσιο της αντιμετώπισης της κλιματικής αλλαγής, απαιτείται η περαιτέρω απανθρακοποίηση της βιομηχανίας παραγωγής ηλεκτρικής ενέργειας, δηλαδή η απεξάρτησή της από τα ορυκτά καύσιμα, τα οποία περιέχουν άνθρακα. Έτσι, καθίσταται αναγκαία η παραγωγή ηλεκτρικής ενέργειας από ανανεώσιμες πηγές, όπως η ηλιακή, η αιολική, η υδροηλεκτρική και η γεωθερμική ενέργεια.

Πέρα από την προσπάθεια μείωσης των εκπομπών αερίων του θερμοκηπίου, η μετάβαση στην παραγωγή ηλεκτρικής ενέργειας από ανανεώσιμες πηγές προωθείται, επίσης, από την αναγκαιότητα ικανοποίησης της αυξανόμενης ενεργειακής ζήτησης και διαφύλαξης της ασφάλειας του ενεργειακού εφοδιασμού [34]. Έτσι, το μερίδιο της ηλεκτρικής ενέργειας που παράγεται από ανανεώσιμες πηγές αυξάνεται συνεχώς τα τελευταία χρόνια. Παρά τις


επίμονες προκλήσεις όσον αφορά την εφοδιαστική αλυσίδα, τις καθυστερήσεις στην κατασκευή και τις πρωτοφανείς τιμές πρώτων υλών και άλλων εμπορευμάτων, οι καθαρές προσθήκες εγκατεστημένης ισχύος Ανανεώσιμων Πηγών Ενέργειας αυξήθηκαν κατά 6% το 2021, προσεγγίζοντας τα 295 GW [1]. Μάλιστα, οι προσθήκες αυτές αναμένεται να αυξηθούν ακόμα περισσότερο το 2022. Η νέα αυτή αύξηση θα στηριχθεί στην περαιτέρω ανάπτυξη των ηλιακών φωτοβολταϊκών συστημάτων (Solar Photovoltaic – Solar PV), καθώς προβλέπεται ότι η αύξηση στην εγκατεστημένη φωτοβολταϊκή ισχύ θα αποτελέσει το 60% της συνολικής παγκόσμιας αύξησης [1].

Το 2021, η Ευρωπαϊκή Ένωση αποτέλεσε τη δεύτερη μεγαλύτερη αγορά, μετά την Κίνα, όσον αφορά την αύξηση της εγκατεστημένης ισχύος ανανεώσιμων πηγών, με την πλειονότητα αυτής της αύξησης να οφείλεται στην εγκατάσταση νέων συστημάτων φωτοβολταϊκής παραγωγής [1]. Το γεγονός αυτό αποδίδεται στην προσπάθεια επίτευξης των φιλόδοξων στόχων που έχουν τεθεί, αναφορικά με τη μείωση των εκπομπών αερίων του θερμοκηπίου και την αύξηση της συμμετοχής των Ανανεώσιμων Πηγών Ενέργειας στο ενεργειακό μείγμα. Στην Ευρωπαϊκή Ένωση, η αύξηση του μεριδίου της ηλεκτρικής ενέργειας που παράγεται από ανανεώσιμες πηγές παρακινείται σε μεγάλο βαθμό από την αξιοποίηση της ηλιακής και της αιολικής ενέργειας [35].

Στο Σχήμα 3.1 απεικονίζεται η εξέλιξη της συνολικής εγκατεστημένης ισχύος ηλιακής ενέργειας στην Ευρωπαϊκή Ένωση για το χρονικό διάστημα 2010–2020. Τα στοιχεία του Σχήματος 3.1, τα οποία βασίζονται σε στοιχεία της Ευρωπαϊκής Στατιστικής Υπηρεσίας (Eurostat) [36], παρουσιάζονται σε GW και με στρογγυλοποίηση στο πρώτο δεκαδικό ψηφίο. Όπως φαίνεται στο Σχήμα 3.1, ενώ η εγκατεστημένη ισχύς των ηλιοθερμικών συστημάτων (Solar thermal) παραμένει σχεδόν σταθερή από το 2013 και μετά, η εγκατεστημένη φωτοβολταϊκή ισχύς αυξάνεται συνεχώς. Παράλληλα, αυξητική τάση παρουσιάζει και η εγκατεστημένη ισχύς ηλιακής ενέργειας στην Ελλάδα, στην οποία όμως συνεισφέρει αποκλειστικά η φωτοβολταϊκή παραγωγή ηλεκτρικής ενέργειας [36].

Το 2020, οι Ανανεώσιμες Πηγές Ενέργειας συνεισέφεραν το 37,5% της ακαθάριστης κατανάλωσης ηλεκτρικής ενέργειας στην Ευρωπαϊκή Ένωση, ενώ το αντίστοιχο ποσοστό για την Ελλάδα προσέγγισε το 35,9% [37]. Παρά το γεγονός ότι η συνεχής αύξηση της παραγωγής ηλεκτρικής ενέργειας από ανανεώσιμες πηγές συμβάλλει καταλυτικά στην επίτευξη των περιβαλλοντικών στόχων που έχουν τεθεί, δημιουργεί, ταυτόχρονα, νέες προκλήσεις για τα υφιστάμενα συστήματα ηλεκτρικής ενέργειας. Οι προκλήσεις αυτές πηγάζουν κατά κύριο λόγο από τη μεταβλητότητα που διέπει την παραγωγή ηλεκτρικής ενέργειας από ανανεώσιμες πηγές, όπως η ηλιακή και η αιολική ενέργεια.

Η παραγωγή φωτοβολταϊκής ισχύος βασίζεται στην άμεση μετατροπή της ηλιακής ακτινοβολίας σε ηλεκτρική ενέργεια χρησιμοποιώντας φωτοβολταϊκά (ηλιακά) στοιχεία (solar cells), τα οποία είναι κατασκευασμένα από ημιαγώγιμα υλικά στα οποία παρατηρείται το φωτοβολταϊκό φαινόμενο (photovoltaic effect). Επομένως, η φωτοβολταϊκή παραγωγή εξαρτάται κυρίως από την ένταση της ηλιακής ακτινοβολίας που προσπίπτει στα φωτοβολταϊκά πλαίσια (photovoltaic modules), τα οποία περιλαμβάνουν τα ηλιακά στοιχεία. Ωστόσο, η προσπίπτουσα ακτινοβολία δεν είναι ομοιόμορφη με την πάροδο του χρόνου, καθώς η έντασή της εμφανίζει αιτιοκρατικές, αλλά και μη αναμενόμενες διακυμάνσεις [38]. Το γεγονός αυτό καθιστά την παραγωγή φωτοβολταϊκής ισχύος μια διαδικασία που δεν μπορεί να ελεγχθεί πλήρως, σύμφωνα με τις επιθυμίες του εκάστοτε παραγωγού.



Σχήμα 3.1: Η εξέλιξη της συνολικής εγκατεστημένης ισχύος ηλιακής ενέργειας στην Ευρωπαϊκή Ένωση [36]

Παράλληλα, η αβεβαιότητα που σχετίζεται με τη φωτοβολταϊκή παραγωγή ενισχύεται και από άλλους μετεωρολογικούς παράγοντες, όπως η θερμοκρασία του περιβάλλοντος και του φωτοβολταϊκού πλαισίου, η ταχύτητα του ανέμου, η νεφοκάλυψη, τα επίπεδα αερολυμάτων (aerosols) στην ατμόσφαιρα και η υγρασία [39]. Η μεταβλητότητα της ηλιακής ακτινοβολίας και των παραπάνω περιβαλλοντικών παραγόντων προκαλεί συνεχείς και συχνά απρόσμενες αλλαγές στην παραγωγή φωτοβολταϊκής ισχύος. Έτσι, η ευμετάβλητη φύση της, καθώς και η συνεπαγόμενη υψηλή αβεβαιότητα που τη χαρακτηρίζει, καθιστούν τη φωτοβολταϊκή παραγωγή μια στοχαστική διαδικασία, η οποία είναι δύσκολο να προβλεφθεί εκ των προτέρων.

Η συνεχώς αυξανόμενη διείσδυση των μεταβλητών Ανανεώσιμων Πηγών Ενέργειας, στις οποίες συγκαταλέγεται και η φωτοβολταϊκή παραγωγή, έχει ως αποτέλεσμα την αύξηση της στοχαστικής φύσης των συστημάτων ηλεκτρικής ενέργειας [40]. Τα προβλήματα που δημιουργούνται εξαιτίας αυτής της στοχαστικότητας αφορούν, είτε άμεσα είτε έμμεσα, διάφορες πτυχές του συστήματος, όπως ο έλεγχος της κατανομής των μονάδων παραγωγής, η ποιότητα ισχύος, η ευστάθεια, η αξιοπιστία και η προστασία του. Οι Ανανεώσιμες Πηγές Ενέργειας έχουν, επίσης, σημαντικό αντίκτυπο στις αγορές ηλεκτρικής ενέργειας, καθώς το πολύ χαμηλό οριακό τους κόστος συνεπάγεται την κατά προτεραιότητα ένταξή τους στην καμπύλη προσφοράς, με αποτέλεσμα να προηγούνται έναντι των συμβατικών μονάδων παραγωγής. Έτσι, η μεταβλητή τους παραγωγή επηρεάζει άμεσα την οριακή τιμή του συστήματος (τιμή εκκαθάρισης της αγοράς), καθώς η προβλεπόμενη τιμή της μετατοπίζει ανάλογα τη συνολική καμπύλη προσφοράς επηρεάζοντας, έτσι, το σημείο τομής της με την καμπύλη ζήτησης (merit-order effect) [34]. Επιπρόσθετα, η εγγενής αβεβαιότητα των περισσότερων ανανεώσιμων πηγών – εξαιρούνται η υδροηλεκτρική ενέργεια και η βιομάζα – αυξάνει την ανάγκη για εφεδρική ισχύ, η οποία καλείται να καλύψει τις διακυμάνσεις στην

προβλεπόμενη παραγωγή, με τους παραγωγούς να επωμίζονται το επιπλέον κόστος εξισορρόπησης του συστήματος [34].

Η πρόβλεψη της παραγωγής φωτοβολταϊκής ισχύος είναι απαραίτητη για την ενσωμάτωσή της στα συστήματα και τις αγορές ηλεκτρικής ενέργειας, καθώς έχει αναδειχθεί ως ένας εξαιρετικός τρόπος αντιμετώπισης των παραπάνω προκλήσεων. Μία ακριβής πρόβλεψη της φωτοβολταϊκής παραγωγής μπορεί να μειώσει την επίδραση της αβεβαιότητάς της στο σύστημα, να διατηρήσει την ποιότητα ισχύος, να βελτιώσει την αξιοπιστία και να διασφαλίσει την ευστάθεια του συστήματος [41]. Ταυτόχρονα, η ικανότητα ακριβούς πρόβλεψης της παραγωγής των φωτοβολταϊκών συστημάτων είναι καθοριστικής σημασίας για τους διαχειριστές του ηλεκτρικού συστήματος, δεδομένου ότι οι αποκλίσεις μεταξύ της προβλεπόμενης και της παραγόμενης ισχύος πρέπει να εξισορροπηθούν από τις υπόλοιπες τεχνολογίες που συγκροτούν το ενεργειακό χαρτοφυλάκιο. Έτσι, μια ακριβής πρόβλεψη θα μπορούσε να μειώσει τον απαιτούμενο αριθμό λειτουργικών μονάδων εφεδρικής ισχύος και κατά συνέπεια το λειτουργικό κόστος του συστήματος [38], [42].

Η πρόβλεψη της φωτοβολταϊκής παραγωγής είναι, επίσης, εξαιρετικά χρήσιμη για τους διαχειριστές των φωτοβολταϊκών σταθμών παραγωγής, αφού η χρησιμοποίηση κατάλληλων προβλέψεων μπορεί να συμβάλει στον σχεδιασμό βέλτιστων στρατηγικών όσον αφορά την κατάθεση προσφορών στις αγορές ηλεκτρικής ενέργειας [43]. Επιπρόσθετα, η κατάθεση προσφορών που διακρίνονται από μεγαλύτερη ακρίβεια, αξιοποιώντας ακριβείς προβλέψεις, βοηθά τους παραγωγούς να αποφύγουν ενδεχόμενες κυρώσεις εξαιτίας μεγάλων αποκλίσεων μεταξύ της προβλεπόμενης και της παραγόμενης ισχύος [38]. Μέσω των παραπάνω, η ακριβέστερη πρόβλεψη της φωτοβολταϊκής παραγωγής συμβάλλει στη μεγιστοποίηση των εσόδων των παραγωγών, αφού μειώνει τις αβεβαιότητες που σχετίζονται με την παραγωγή φωτοβολταϊκής ισχύος και συνεπώς τους κινδύνους που σχετίζονται με τη συμμετοχή της στην αγορά ηλεκτρικής ενέργειας.

Επομένως, η ακριβέστερη πρόβλεψη της φωτοβολταϊκής παραγωγής συνεισφέρει καταλυτικά στη διεύθυνσή της στα συστήματα ηλεκτρικής ενέργειας, καθώς προσφέρει σημαντικά οφέλη τόσο στους διαχειριστές του συστήματος όσο και σε αυτούς των φωτοβολταϊκών σταθμών παραγωγής. Παράλληλα, με βάση το γεγονός ότι η αύξηση αυτής της διεύθυνσης μπορεί να μεγεθύνει την επίδραση μιας εσφαλμένης πρόβλεψης στο σύστημα, η περαιτέρω ενσωμάτωση της φωτοβολταϊκής παραγωγής καθιστά αναγκαία την παραγωγή προβλέψεων ακόμα μεγαλύτερης ακρίβειας. Έτσι, θεμελιώνεται η σπουδαιότητα της πρόβλεψης όσον αφορά τη μαζική ενσωμάτωση των φωτοβολταϊκών, η οποία μπορεί να συμβάλει καταλυτικά στην επίτευξη των φιλόδοξων περιβαλλοντικών στόχων που έχουν τεθεί. Η σπουδαιότητα της πρόβλεψης γίνεται, επίσης, αντιληπτή από τις μελέτες που διενεργούνται σε παγκόσμιο επίπεδο αναφορικά με την ακριβή πρόβλεψη της φωτοβολταϊκής παραγωγής.

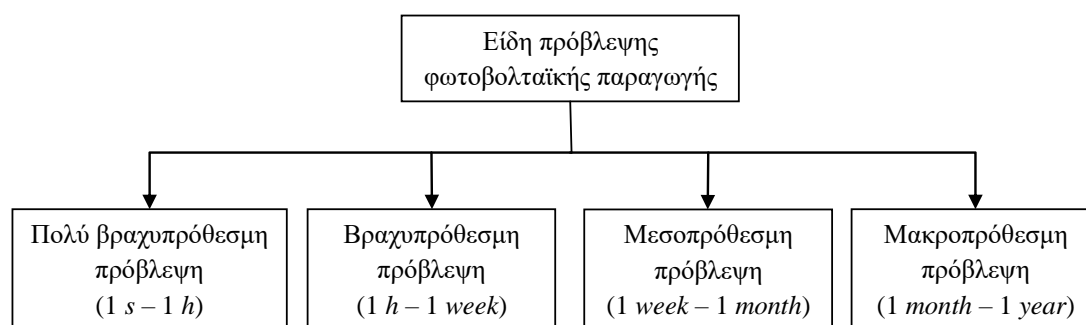
Ωστόσο, η στοχαστική φύση της φωτοβολταϊκής παραγωγής συνιστά πρόκληση όσον αφορά την ακριβή πρόβλεψή της. Συνεπώς, έχει διεξαχθεί μεγάλος αριθμός ερευνών, ώστε να αναπτυχθούν κατάλληλα μοντέλα πρόβλεψης, τα οποία στοχεύουν στην επίτευξη υψηλότερης ακρίβειας και στην ελαχιστοποίηση της υπολογιστικής πολυπλοκότητας [41]. Η ακρίβεια των χρησιμοποιούμενων μοντέλων πρόβλεψης της φωτοβολταϊκής παραγωγής επηρεάζεται από πληθώρα διαφορετικών παραγόντων, ένας εκ των οποίων είναι και ο χρονικός ορίζοντας της πρόβλεψης.

3.2 ΧΡΟΝΙΚΟΣ ΟΡΙΖΟΝΤΑΣ ΤΗΣ ΠΡΟΒΛΕΨΗΣ

Το μελλοντικό χρονικό διάστημα για το οποίο διενεργείται η πρόβλεψη της φωτοβολταϊκής παραγωγής αποτελεί τον χρονικό ορίζοντα της εκάστοτε πρόβλεψης (forecast horizon) [41]. Ταυτόχρονα, ορίζεται και το χρονικό βήμα της πρόβλεψης (forecast resolution), το οποίο αφορά τη συχνότητα με την οποία παράγονται οι επιμέρους προβλέψεις κατά τη διάρκεια του χρονικού ορίζοντα. Η κατάλληλη επιλογή του χρονικού ορίζοντα της πρόβλεψης πρέπει να πραγματοποιηθεί πριν από τη σχεδίαση του αντίστοιχου μοντέλου πρόβλεψης, ώστε η ακρίβειά του να διατηρηθεί σε αποδεκτά επίπεδα, καθώς η ακρίβεια της πρόβλεψης είναι εξαιρετικά ευαίσθητη σε αλλαγές του χρονικού ορίζοντα [44].

Ο χρονικός ορίζοντας της πρόβλεψης σχετίζεται, επίσης, με τον σκοπό για τον οποίο αυτή προορίζεται. Προβλέψεις που διενεργούνται για διαφορετικούς χρονικούς ορίζοντες είναι ιδιαίτερα σημαντικές για διαφορετικές πτυχές του συστήματος ηλεκτρικής ενέργειας. Έτσι, ένας βασικός τρόπος ταξινόμησης των προβλέψεων φωτοβολταϊκής παραγωγής είναι σύμφωνα με τον χρονικό ορίζοντα της πρόβλεψης. Παρά το γεγονός ότι δεν υπάρχουν σαφώς καθορισμένα κριτήρια ταξινόμησης, οι προβλέψεις συχνά διαχωρίζονται στις ακόλουθες τέσσερις κατηγορίες, όπως φαίνεται και στο Σχήμα 3.2:

1. Πολύ βραχυπρόθεσμη πρόβλεψη (Very short-term forecasting). Αφορά ορίζοντες πρόβλεψης από μερικά δευτερόλεπτα έως μία ώρα, ενώ συχνά αναφέρεται και ως *intra-hour forecasting* ή *nowcasting*. Είναι ιδιαίτερα σημαντική όσον αφορά την εξομάλυνση της ισχύος του δικτύου, τη διασφάλιση της ευστάθειας του συστήματος, τον βέλτιστο προγραμματισμό της στρεφόμενης εφεδρείας καθώς και την απόκριση του συστήματος στη ζήτηση σε πραγματικό χρόνο [38], [41].
2. Βραχυπρόθεσμη πρόβλεψη (Short-term forecasting). Αφορά χρονικούς ορίζοντες από μία ώρα έως και επτά ημέρες, ενώ συχνά η κατηγορία αυτή συμπεριλαμβάνει την πολύ βραχυπρόθεσμη πρόβλεψη. Οι ορίζοντες πρόβλεψης από μία έως έξι ώρες (*intra-day*) και από μία έως τρεις ημέρες (*day ahead*) περιλαμβάνονται, επίσης, στη συγκεκριμένη κατηγορία. Η βραχυπρόθεσμη πρόβλεψη είναι σημαντική για την ένταξη των μονάδων παραγωγής (*unit commitment*), την προσαρμογή της παραγωγής στο φορτίο (*load-following*) και την ενίσχυση της ασφάλειας λειτουργίας του δικτύου. Επομένως, είναι εξαιρετικά χρήσιμη όσον αφορά τον σχεδιασμό ενός συστήματος διαχείρισης ενέργειας με ενσωμάτωση φωτοβολταϊκής παραγωγής [41].
3. Μεσοπρόθεσμη πρόβλεψη (Medium-term forecasting). Καλύπτει χρονικούς ορίζοντες από μία εβδομάδα έως έναν μήνα, ενώ η χρησιμότητά της έγκειται κυρίως στην εξομάλυνση του προγραμματισμού του συστήματος ηλεκτρικής ενέργειας [41]. Είναι, επίσης, σημαντική όσον αφορά τον προγραμματισμό της συντήρησης των φωτοβολταϊκών σταθμών παραγωγής με οικονομικά αποδοτικό τρόπο, δηλαδή όταν αναμένεται χαμηλή φωτοβολταϊκή παραγωγή [38].
4. Μακροπρόθεσμη πρόβλεψη (Long-term forecasting). Πραγματοποιείται για ορίζοντες πρόβλεψης από έναν μήνα έως έναν χρόνο και συμβάλλει στον προγραμματισμό της παραγωγής, της μεταφοράς και της διανομής ηλεκτρικής ενέργειας από τους αντίστοιχους διαχειριστές [41].

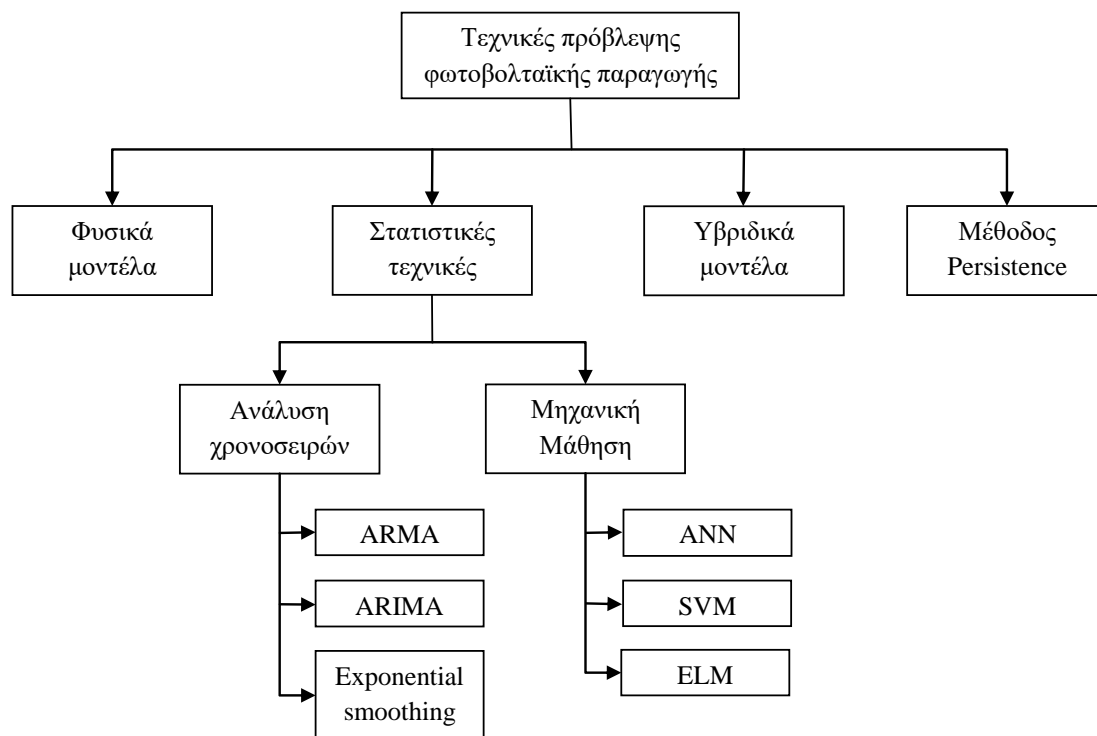


Σχήμα 3.2: Ταξινόμηση της πρόβλεψης φωτοβολταϊκής παραγωγής με βάση τον χρονικό ορίζοντα της πρόβλεψης

3.3 ΤΕΧΝΙΚΕΣ ΠΡΟΒΛΕΨΗΣ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

Η σπουδαιότητα της πρόβλεψης φωτοβολταϊκής παραγωγής ενίσχυσε σε παγκόσμιο επίπεδο το ενδιαφέρον για τη διεξαγωγή ερευνών πάνω στο συγκεκριμένο αντικείμενο. Έτσι, προτάθηκαν και αναπτύχθηκαν διάφορες τεχνικές με σκοπό την πρόβλεψη της παραγωγής φωτοβολταϊκής ισχύος, η οποία πραγματοποιείται είτε άμεσα είτε έμμεσα. Η άμεση προσέγγιση αφορά την παραγωγή προβλέψεων μέσω του άμεσου υπολογισμού της φωτοβολταϊκής ισχύος εξόδου. Αντίθετα, η έμμεση προσέγγιση του ζητήματος περιλαμβάνει αρχικά την πρόβλεψη της ηλιακής ακτινοβολίας, από την οποία εξάγεται στη συνέχεια η φωτοβολταϊκή ισχύς εξόδου μέσω ενός μοντέλου φωτοβολταϊκής απόδοσης της αντίστοιχης εγκατάστασης [38]. Οι σημαντικότερες τεχνικές πρόβλεψης (Σχήμα 3.3) είναι οι ακόλουθες:

- Φυσικά μοντέλα (Physical models) [38]. Τα φυσικά μοντέλα ή μοντέλα απόδοσης φωτοβολταϊκών (PV performance models) ακολουθούν την έμμεση προσέγγιση όσον αφορά την πρόβλεψη της φωτοβολταϊκής παραγωγής. Αρχικά, γίνονται προβλέψεις της ηλιακής ακτινοβολίας καθώς και άλλων απαραίτητων μεταβλητών. Η ηλιακή ακτινοβολία παρουσιάζει παρόμοια συμπεριφορά με την παραγόμενη φωτοβολταϊκή ισχύ, με αποτέλεσμα να χρησιμοποιούνται εφάμιλλες τεχνικές για την πρόβλεψή της, ενώ άλλες προβλέψεις – όπως αυτές που αφορούν τη θερμοκρασία και τον άνεμο – προέρχονται συνήθως από μοντέλα Αριθμητικών Προβλέψεων Καιρού (Numerical Weather Predictions – NWP). Ακολουθεί η φυσική μετατροπή των παραπάνω προβλέψεων στη ζητούμενη ισχύ εξόδου, καθώς το αντίστοιχο φωτοβολταϊκό σύστημα μοντελοποιείται με τη χρήση αναλυτικών εξισώσεων και αξιοποιούνται οι προβλέψεις που έχουν προηγηθεί. Το κύριο πλεονέκτημα των φυσικών μοντέλων έγκειται στο γεγονός ότι δεν απαιτούν την ύπαρξη ιστορικών δεδομένων. Έτσι, μπορεί να πραγματοποιηθεί πρόβλεψη της παραγωγής ενός φωτοβολταϊκού συστήματος πριν από την εγκατάστασή του, εφόσον είναι γνωστά τα τεχνικά χαρακτηριστικά του και υπάρχει η δυνατότητα να παραχθούν οι απαιτούμενες προβλέψεις με τη χρήση μοντέλων NWP.



Σχήμα 3.3: Οι σημαντικότερες τεχνικές πρόβλεψης φωτοβολταϊκής παραγωγής

- **Στατιστικά μοντέλα (Statistical models).** Σε αντίθεση με τα φυσικά μοντέλα, τα στατιστικά μοντέλα δεν χρειάζονται εσωτερικές πληροφορίες ενός συστήματος, για να το μοντελοποιήσουν. Απαιτούν ωστόσο την ύπαρξη ιστορικών δεδομένων, όπως μετεωρολογικά δεδομένα και μετρήσεις της παραγόμενης ισχύος, ώστε να προχωρήσουν στην εξαγωγή κάποιου μοτίβου ή κάποιας συσχέτισης από τα δεδομένα αυτά, χρησιμοποιώντας μαθηματικές εξισώσεις [45]. Επομένως, η ακρίβεια της πρόβλεψης εξαρτάται σε μεγάλο βαθμό από την ποιότητα των διαθέσιμων ιστορικών δεδομένων, αλλά και από το πλήθος τους. Οι στατιστικές τεχνικές που χρησιμοποιούνται μπορούν να διαχωριστούν περαιτέρω σε δύο ομάδες: τα μοντέλα πρόβλεψης που βασίζονται στην ανάλυση χρονοσειρών και αυτά τα οποία βασίζονται στη Μηχανική Μάθηση [45]. Καθιερωμένες τεχνικές ανάλυσης χρονοσειρών είναι η εκθετική εξομάλυνση (exponential smoothing), τα αυτοπαλινδρομικά μοντέλα κινητού μέσου όρου (autoregressive moving average – ARMA) και τα ολοκληρωμένα αυτοπαλινδρομικά μοντέλα κινητού μέσου όρου (autoregressive integrated moving average – ARIMA), ενώ οι κυριότερες τεχνικές μηχανικής μάθησης είναι τα τεχνητά νευρωνικά δίκτυα (ANNs), οι μηχανές διανυσμάτων υποστήριξης (Support Vector Machines – SVMs) και οι μηχανές ακραίας μάθησης (Extreme Learning Machines – ELMs).
- **Υβριδικά μοντέλα (Hybrid models).** Τα υβριδικά μοντέλα προκύπτουν από τον συνδυασμό δύο ή περισσότερων τεχνικών πρόβλεψης. Ο συνδυασμός αυτός αυξάνει τη συνολική ακρίβεια της πρόβλεψης, ενσωματώνοντας τα οφέλη των μεμονωμένων τεχνικών [44]. Σε πολλές περιπτώσεις, η χρήση μίας μόνο τεχνικής δεν είναι αρκετή, ώστε να επιτευχθεί η απαιτούμενη ακρίβεια, καθώς τα

μεμονωμένα μοντέλα μπορούν να παραλείψουν ορισμένες πληροφορίες εξαιτίας του τρόπου με τον οποίο μετασχηματίζουν τα δεδομένα. Έτσι, παρατηρείται συχνά ο συνδυασμός είτε δύο ή περισσότερων στατιστικών τεχνικών είτε μίας στατιστικής τεχνικής και ενός φυσικού μοντέλου πρόβλεψης [38]. Μειονέκτημα των υβριδικών μοντέλων αποτελεί το γεγονός ότι παράλληλα με την ακρίβεια της πρόβλεψης, αυξάνεται και η υπολογιστική πολυπλοκότητα του μοντέλου [44].

- Μέθοδος Persistence. Το μοντέλο Persistence στηρίζει τη λειτουργία του στην υπόθεση ότι η τιμή της παραγόμενης φωτοβολταϊκής ισχύος τη μελλοντική στιγμή $t+1$ είναι ίση με την αμέσως προηγούμενη μέτρησή της τη χρονική στιγμή t [39]. Η ακρίβεια της συγκεκριμένης μεθόδου μειώνεται καθώς αυξάνεται ο χρονικός ορίζοντας, επομένως χρησιμοποιείται κατά κύριο λόγο για την πολύ βραχυπρόθεσμη πρόβλεψη της φωτοβολταϊκής παραγωγής. Η απλότητα και το χαμηλό υπολογιστικό κόστος του μοντέλου Persistence το καθιστά ένα χρήσιμο εργαλείο για την ανάλυση της απόδοσης άλλων μοντέλων πρόβλεψης, με αποτέλεσμα να χρησιμοποιείται κυρίως ως σημείο αναφοράς κατά την αξιολόγηση διαφορετικών μοντέλων [39].

Τέλος, τα μοντέλα πρόβλεψης που χρησιμοποιούνται διακρίνονται σε αιτιοκρατικά (deterministic) και πιθανοτικά (probabilistic). Ως αιτιοκρατικά αναφέρονται τα μοντέλα που παράγουν σημειακές προβλέψεις, δηλαδή τα μοντέλα που τη χρονική στιγμή t παράγουν μία μεμονωμένη τιμή πρόβλεψης για όλα τα διαστήματα πρόβλεψης (forecast intervals) που συνθέτουν τον χρονικό ορίζοντα. Παρά το γεγονός ότι σε ένα αιτιοκρατικό πλαίσιο οι σημειακές αυτές προβλέψεις θα έπρεπε να χαρακτηρίζονται από μεγάλη σιγουριά, η στοχαστική φύση της φωτοβολταϊκής παραγωγής συνεπάγεται την παρουσία αβεβαιότητας, με αποτέλεσμα οι παραγόμενες σημειακές προβλέψεις να αποτελούν απλώς εκτιμήσεις [43].

Η αδυναμία των αιτιοκρατικών μοντέλων να ποσοτικοποιήσουν και να επικοινωνήσουν την αβεβαιότητα που σχετίζεται με την παραγόμενη πρόβλεψη έχει οδηγήσει στην ανάπτυξη πιθανοτικών μοντέλων πρόβλεψης. Τα πιθανοτικά μοντέλα πρόβλεψης, τα οποία χρησιμοποιούνται συνήθως για την πρόβλεψη αιολικής παραγωγής και την πρόβλεψη φορτίου, προσθέτουν πολύτιμες πληροφορίες για τις εκτιμώμενες τιμές, όπως τα άνω και κάτω όρια των πιθανών προβλέψεων, το επίπεδο εμπιστοσύνης για κάθε τιμή ή τον καθορισμό ενός εύρους πιθανών τιμών με τις αντίστοιχες συναρτήσεις πυκνότητας πιθανότητας [38].

3.4 ΔΕΙΚΤΕΣ ΑΞΙΟΛΟΓΗΣΗΣ

Η απόδοση και η ακρίβεια ενός μοντέλου φωτοβολταϊκής πρόβλεψης μπορεί να αποτιμηθεί μέσω διάφορων δεικτών αξιολόγησης, οι οποίοι επιτρέπουν τη σύγκριση μεταξύ διαφορετικών μοντέλων και τοποθεσιών εγκατάστασης των φωτοβολταϊκών. Κάθε τέτοιο μετρικό επικεντρώνεται σε μια συγκεκριμένη πτυχή μιας σημειακής κατανομής, με συνέπεια να μην υπάρχει κάποιο μετρικό το οποίο να είναι κατάλληλο για όλες τις περιπτώσεις [38]. Έτσι, δεν υπάρχει διαθέσιμο κάποιο συνεπές και σταθερό σύνολο μετρικών, καθώς διαφορετικοί ερευνητές χρησιμοποιούν διαφορετικά μετρικά ως κριτήρια αξιολόγησης [46].

Οι δείκτες αξιολόγησης που χρησιμοποιούνται συνηθέστερα από τους περισσότερους ερευνητές είναι τα κλασικά στατιστικά μετρικά σφάλματος. Τα κυριότερα από αυτά είναι τα ακόλουθα:

- Ρίζα του Μέσου Τετραγωνικού Σφάλματος (Root Mean Square Error – *RMSE*). Το μετρικό *RMSE* παρέχει μια καθολική μέτρηση του σφάλματος για όλη τη διάρκεια του χρονικού ορίζοντα της πρόβλεψης και δίνεται από την εξίσωση (3.1):

$$RMSE = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (\hat{P}_i - P_i)^2} \quad (3.1)$$

Το μετρικό *RMSE* έχει την τάση να τιμωρεί τα μεγάλα σφάλματα πρόβλεψης, καθώς ο τετραγωνισμός κάθε όρου σφάλματος σταθμίζει τα σφάλματα αυτά σε μεγαλύτερο βαθμό από τα μικρά σφάλματα, ενώ είναι χρήσιμο για την αξιολόγηση της συνολικής απόδοσης των προβλέψεων, ειδικά όταν παρατηρούνται ακραία φαινόμενα [46].

- Μέσο Απόλυτο Σφάλμα (*MAE*). Το συγκεκριμένο μετρικό δείχνει τη μέση απόσταση μεταξύ των μετρούμενων τιμών και των παραγόμενων προβλέψεων, ενώ είναι κατάλληλο για την αξιολόγηση ομοιόμορφων σφαλμάτων πρόβλεψης.

$$MAE = \frac{1}{N} \cdot \sum_{i=1}^N |\hat{P}_i - P_i| \quad (3.2)$$

Το μετρικό *MAE* αποτελεί, επίσης, ένα καθολικό μετρικό, χωρίς ωστόσο να τιμωρεί τα ακραία φαινόμενα πρόβλεψης στον βαθμό που το κάνει το *RMSE*. Έτσι, ένας μεγάλος αριθμός πολύ μικρών σφαλμάτων μπορεί εύκολα να υπερισχύσει ενός μικρού αριθμού μεγάλων σφαλμάτων [46].

- Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (*MAPE*). Όπως και το μέσο απόλυτο σφάλμα, το μετρικό *MAPE* είναι κατάλληλο για την αξιολόγηση ομοιόμορφων σφαλμάτων πρόβλεψης και δίνεται από την εξίσωση (3.3):

$$MAPE = \frac{1}{N} \cdot \sum_{i=1}^N \left| \frac{\hat{P}_i - P_i}{P_N} \right| \times 100\% \quad (3.3)$$

Το *MAPE* μπορεί να χρησιμοποιηθεί για τη σύγκριση αποτελεσμάτων που αφορούν διαφορετικές χωρικές και χρονικές κλίμακες σφαλμάτων πρόβλεψης [46], καθώς οι όροι σφάλματος κανονικοποιούνται με βάση την ονομαστική ισχύ της εκάστοτε φωτοβολταϊκής εγκατάστασης.

Στις εξισώσεις (3.1), (3.2) και (3.3), N είναι το πλήθος των παραγόμενων σημειακών προβλέψεων για τον χρονικό ορίζοντα της πρόβλεψης, P_i είναι η μετρούμενη φωτοβολταϊκή ισχύς εξόδου στο i -οστό χρονικό βήμα, \hat{P}_i είναι η αντίστοιχη φωτοβολταϊκή παραγωγή που εκτιμάται από το μοντέλο πρόβλεψης και P_N είναι η ονομαστική ισχύς της εξεταζόμενης φωτοβολταϊκής εγκατάστασης.

ΑΝΑΛΥΣΗ ΚΑΙ ΕΠΕΞΕΡΓΑΣΙΑ ΙΣΤΟΡΙΚΩΝ ΔΕΔΟΜΕΝΩΝ

4.1 ΔΕΔΟΜΕΝΑ ΕΙΣΟΔΟΥ ΜΟΝΤΕΛΩΝ ΠΡΟΒΛΕΨΗΣ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

Οι εισόδοι ενός μοντέλου πρόβλεψης φωτοβολταϊκής παραγωγής επηρεάζουν άμεσα την ακρίβεια της παραγόμενης πρόβλεψης και αποτελούν καταλυτικό παράγοντα όσον αφορά τον καθορισμό της συνολικής απόδοσης του μοντέλου. Συγκεκριμένα, πέρα από τη βελτίωση της ακρίβειας της πρόβλεψης, η κατάλληλη επιλογή και επεξεργασία των εισόδων του εκάστοτε μοντέλου μπορεί να ενισχύσει την απόδοσή του όσον αφορά την υπολογιστική πολυπλοκότητα και το αντίστοιχο κόστος [39]. Επομένως, η σχεδίαση ενός μοντέλου πρόβλεψης με τον βέλτιστο αριθμό εισόδων είναι εξαιρετικά σημαντική.

Η προέλευση των εισόδων ενός μοντέλου πρόβλεψης φωτοβολταϊκής παραγωγής αποτελεί ένα επιπρόσθετο κριτήριο αναφορικά με την ταξινόμησή του. Έτσι, τα διάφορα μοντέλα πρόβλεψης διακρίνονται σε δύο κατηγορίες: τα μοντέλα που χρησιμοποιούν ενδογενή δεδομένα εισόδου (endogenous data) και εκείνα που κάνουν χρήση εξωγενών δεδομένων εισόδου (exogenous data). Τα ενδογενή δεδομένα σχηματίζονται από χρονοσειρές με χρονική υστέρηση ή/και τρέχουσες χρονοσειρές, στις οποίες είναι καταγεγραμμένες οι τιμές της φωτοβολταϊκής παραγωγής της εξεταζόμενης εγκατάστασης [38]. Αντίθετα, ένα μοντέλο που χρησιμοποιεί εξωγενή δεδομένα μπορεί να αξιοποιήσει τοπικές μετεωρολογικές μετρήσεις, προβλέψεις από μοντέλα NWP, τιμές από άλλες μετεωρολογικές βάσεις δεδομένων, πληροφορίες από sky imagers (συσκευές που απεικονίζουν τον ουρανό), εικόνες από δορυφόρους και μετρήσεις από γειτονικές φωτοβολταϊκές εγκαταστάσεις [38].

Τα μοντέλα πρόβλεψης φωτοβολταϊκής παραγωγής τα οποία υλοποιούνται στην παρούσα διπλωματική εργασία βασίζονται σε στατιστικές τεχνικές μηχανικής μάθησης και αξιοποιούν ιστορικά δεδομένα που περιλαμβάνουν μετεωρολογικές μετρήσεις καθώς και την αντίστοιχη παραγόμενη ισχύ. Η απόδοση των παραπάνω μοντέλων πρόβλεψης εξαρτάται σε μεγάλο βαθμό από τη συσχέτιση μεταξύ των διαθέσιμων μετεωρολογικών παραμέτρων, που αποτελούν την πλειονότητα των συνιστωσών που συνθέτουν τα διανύσματα εισόδου, και της φωτοβολταϊκής ισχύος εξόδου. Ωστόσο, η συσχέτιση μεταξύ αυτών των παραμέτρων και της φωτοβολταϊκής παραγωγής διαφέρει ανάλογα με την τοποθεσία της εκάστοτε φωτοβολταϊκής εγκατάστασης, καθώς η μεταβλητότητα των μετεωρολογικών παραμέτρων εξαρτάται από τη γεωγραφική της θέση και τις αντίστοιχες καιρικές συνθήκες που επικρατούν [41]. Συνεπώς, είναι ιδιαίτερα σημαντική η μελέτη της συσχέτισης μεταξύ των διάφορων μετεωρολογικών παραγόντων που χρησιμοποιούνται ως εισόδοι ενός μοντέλου πρόβλεψης, όπως η ηλιακή ακτινοβολία και η θερμοκρασία, και της φωτοβολταϊκής ισχύος που αποτελεί την έξοδο του μοντέλου.

4.2 ΔΙΑΘΕΣΙΜΑ ΙΣΤΟΡΙΚΑ ΔΕΔΟΜΕΝΑ

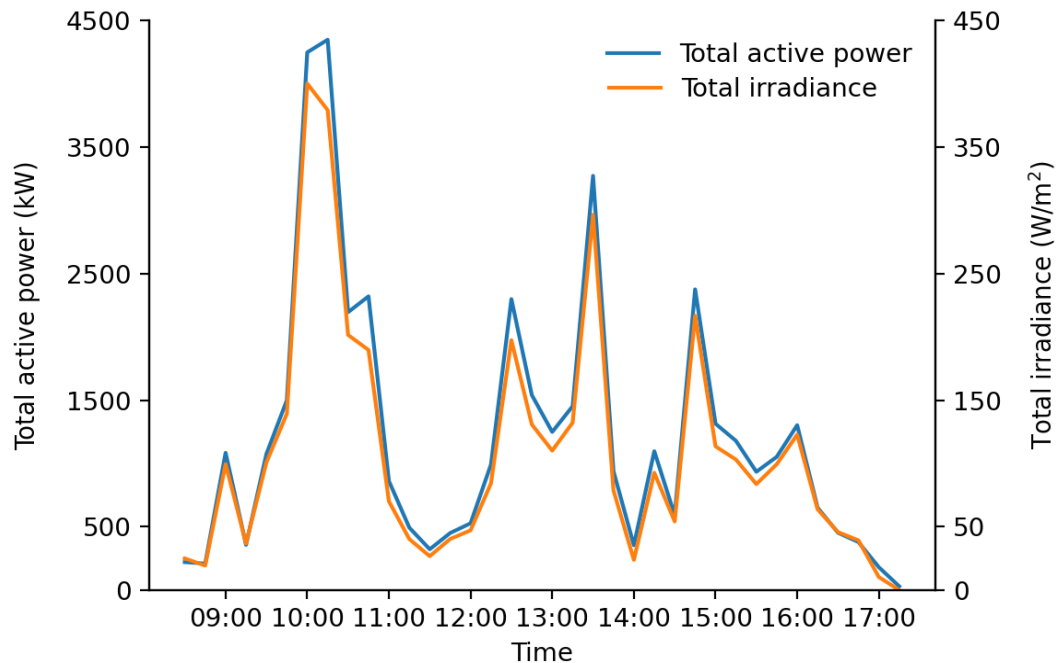
4.2.1 Φωτοβολταϊκό πάρκο της «Περδικούλας»

Η πρώτη φωτοβολταϊκή εγκατάσταση που εξετάζεται στο πλαίσιο της παρούσας διπλωματικής εργασίας είναι το φωτοβολταϊκό πάρκο της «Περδικούλας», με ονομαστική ισχύ 11900 kWp. Η ονομαστική ισχύς του φωτοβολταϊκού πάρκου, η οποία δίνεται σε kWp, αναφέρεται στη μέγιστη παραγόμενη ισχύ που μετράται για πρότυπες συνθήκες δοκιμής (Standard Test Conditions – STC). Οι πρότυπες συνθήκες δοκιμής που χρησιμοποιούνται στις φωτοβολταϊκές εφαρμογές είναι οι ακόλουθες:

1. Η θερμοκρασία των φωτοβολταϊκών στοιχείων είναι 25°C.
2. Η ένταση της προσπίπτουσας ηλιακής ακτινοβολίας είναι 1000 Watt ανά τετραγωνικό μέτρο (W/m²).
3. Ο συντελεστής μάζας αέρα (air mass coefficient), ο οποίος σχετίζεται με την ένταση και το φάσμα της προσπίπτουσας ηλιακής ακτινοβολίας, είναι 1,5 (AM1.5).

Τα ιστορικά δεδομένα τα οποία είναι διαθέσιμα για το φωτοβολταϊκό πάρκο της «Περδικούλας» περιλαμβάνουν μετρήσεις διάφορων μετεωρολογικών παραμέτρων καθώς και μετρήσεις της συνολικής ενεργού και αέργου ισχύος. Στις μετεωρολογικές παραμέτρους συγκαταλέγονται η θερμοκρασία του περιβάλλοντος, η σχετική υγρασία, η ταχύτητα και η κατεύθυνση του ανέμου (διαθέσιμες μετρήσεις από 5 διαφορετικούς μετεωρολογικούς σταθμούς). Περιλαμβάνονται, επίσης, η ένταση της συνολικής προσπίπτουσας ηλιακής ακτινοβολίας και η θερμοκρασία των πλαισίων για 10 και 28 φωτοβολταϊκές συστοιχίες αντίστοιχα, καθώς και ο υετός, δηλαδή μετρήσεις του ρυθμού πτώσης ή εναπόθεσης οποιουδήποτε προϊόντος προέρχεται από συμπύκνωση των υδρατμών της ατμόσφαιρας (διαθέσιμες μετρήσεις από δύο διαφορετικούς μετεωρολογικούς σταθμούς).

Τα διαθέσιμα ιστορικά δεδομένα για το φωτοβολταϊκό πάρκο της «Περδικούλας» καλύπτουν ένα χρονικό διάστημα διάρκειας 24 μηνών, από την 1^η Ιανουαρίου του 2019 και ώρα 00:15 έως την 1^η Ιανουαρίου 2021 και ώρα 00:00. Τόσο οι μετεωρολογικές μετρήσεις όσο και οι μετρήσεις της συνολικής ισχύος, ενεργού ή αέργου, που παράγει (ή καταναλώνει) το φωτοβολταϊκό πάρκο έχουν πραγματοποιηθεί με χρονικό βήμα (ή χρονική ανάλυση) τα 15 λεπτά. Επομένως, η χρονική ανάλυση των μετρήσεων περιορίζει τις δυνατές τιμές του χρονικού ορίζοντα και του χρονικού βήματος της παραγόμενης πρόβλεψης σε ακέραια πολλαπλάσια των 15 λεπτών. Ο περιορισμός αυτός οφείλεται στο γεγονός ότι τα μοντέλα πρόβλεψης μηχανικής μάθησης που περιγράφονται στη συνέχεια αξιοποιούν τα παραπάνω ιστορικά δεδομένα κατά τη διαδικασία της επιτηρούμενης εκπαίδευσής τους. Συνεπώς, η χρονική ανάλυση των παραγόμενων προβλέψεων εξαρτάται άμεσα από τη χρονική ανάλυση των μετρήσεων που χρησιμοποιήθηκαν για την παραγωγή τους μέσω της χαρτογράφησης εισόδου-εξόδου.



Σχήμα 4.1: Μοτίβα φωτοβολταϊκής ισχύος εξόδου και συνολικής ηλιακής ακτινοβολίας

Η κατάλληλη επιλογή των εισόδων από τις διαθέσιμες κατηγορίες μετρήσεων μπορεί να πραγματοποιηθεί μελετώντας τη συσχέτισή τους με τη φωτοβολταϊκή ισχύ εξόδου. Οι μεταβλητές εισόδου που εμφανίζουν ισχυρή συσχέτιση, είτε θετική είτε αρνητική, με την ισχύ εξόδου μπορούν να χρησιμοποιηθούν ως συνιστώσες των διανυσμάτων εισόδου, ενώ όσες εμφανίζουν ασθενή συσχέτιση θα έπρεπε να απορριφθούν [41]. Στο Σχήμα 4.1 φαίνονται τα μοτίβα της φωτοβολταϊκής ισχύος εξόδου (συνολική ενεργός ισχύς – Total active power) και της συνολικής ηλιακής ακτινοβολίας (Total irradiance, μετρήσεις μιας συγκεκριμένης συστοιχίας) για μία συγκεκριμένη ημέρα, τις ώρες που παρατηρείται ηλιοφάνεια. Παρά το γεγονός ότι για τη συγκεκριμένη ημέρα καταγράφηκε χαμηλή φωτοβολταϊκή παραγωγή, το οποίο υποδηλώνει ότι πρόκειται για βροχερή ή συννεφιασμένη ημέρα, τα μοτίβα του Σχήματος 4.1 παρουσιάζουν μεγάλη ομοιότητα παρά τις διακυμάνσεις που παρατηρούνται.

Η εξάρτηση της φωτοβολταϊκής παραγωγής από την ηλιακή ακτινοβολία, και κατά συνέπεια η σπουδαιότητά της ως εισόδου των μοντέλων πρόβλεψης, καταδεικνύεται, επίσης, από την υπολογιζόμενη μεταξύ τους συσχέτιση. Συγκεκριμένα, υπολογίζεται ο συντελεστής συσχέτισης Pearson (Pearson correlation coefficient – r) μεταξύ της συνολικής ενεργού ισχύος και της συνολικής ηλιακής ακτινοβολίας η οποία αφορά τη συστοιχία που χρησιμοποιήθηκε για τη δημιουργία του Σχήματος 4.1. Ο υπολογισμός πραγματοποιήθηκε για το σύνολο των διαθέσιμων ιστορικών δεδομένων του πάρκου της «Περδικούλας», με το αποτέλεσμα που προκύπτει ($r = 0,9967$) να αποδεικνύει την ισχυρή θετική συσχέτισή τους. Παράλληλα, αντίστοιχα υψηλοί είναι και οι συντελεστές συσχέτισης μεταξύ της ισχύος εξόδου και της συνολικής ηλιακής ακτινοβολίας για την πλειονότητα των φωτοβολταϊκών συστοιχιών για τις οποίες διατίθενται μετρήσεις.

Όσον αφορά τις υπόλοιπες μετεωρολογικές παραμέτρους, υψηλούς συντελεστές συσχέτισης με την ισχύ εξόδου παρουσιάζουν οι θερμοκρασίες των φωτοβολταϊκών πλαισίων

των συστοιχιών, ενώ έπονται οι μετρήσεις της ταχύτητας του ανέμου και της θερμοκρασίας του περιβάλλοντος. Αντίθετα, ο υετός και η κατεύθυνση του ανέμου παρουσιάζουν πολύ ασθενή συσχέτιση με την ισχύ εξόδου, ενώ οι συντελεστές συσχέτισης που υπολογίζονται για τη σχετική υγρασία διαφέρουν ανάλογα με τον μετεωρολογικό σταθμό προέλευσης των μετρήσεων. Ταυτόχρονα, ισχυρή, αλλά αρνητική συσχέτιση με τη συνολική ενεργό ισχύ εμφανίζει η συνολική άεργος ισχύς, καθώς ο συντελεστής Pearson που υπολογίζεται μεταξύ τους είναι ίσος με $-0,9329$.

4.2.2 Φωτοβολταϊκό πάρκο «Lamprini»

Η δεύτερη εγκατάσταση φωτοβολταϊκής παραγωγής που εξετάζεται στην παρούσα διπλωματική εργασία είναι το φωτοβολταϊκό πάρκο με ονομασία «Lamprini». Το φωτοβολταϊκό πάρκο «Lamprini» αποτελείται από 10 φωτοβολταϊκές συστοιχίες (photovoltaic arrays), ενώ η συνολική ονομαστική ισχύς των φωτοβολταϊκών του πάρκου ανέρχεται στα 1550,775 kWp. Τα ιστορικά δεδομένα του φωτοβολταϊκού πάρκου «Lamprini» καλύπτουν τμηματικά ένα χρονικό διάστημα περίπου 2 ετών: (i) από την 1^η Ιανουαρίου του 2020 και ώρα 00:01 έως την 31^η Δεκεμβρίου του 2020 και ώρα 00:00 και (ii) από την 1^η Ιανουαρίου του 2021 και ώρα 00:01 έως την 31^η Δεκεμβρίου του 2021 και ώρα 00:00. Ωστόσο, σε αντίθεση με το φωτοβολταϊκό πάρκο της «Περδικούλας», η χρονική ανάλυση των διαθέσιμων ιστορικών δεδομένων του πάρκου «Lamprini» είναι ένα (1) λεπτό, γεγονός που προσφέρει μεγαλύτερη ευελιξία όσον αφορά τον χρονικό ορίζοντα και το χρονικό βήμα της παραγόμενης πρόβλεψης.

Όσον αφορά τις μετεωρολογικές μετρήσεις, είναι διαθέσιμα δύο διαφορετικά σύνολα μετρήσεων για την ένταση της ηλιακής ακτινοβολίας που προσπίπτει στην κεκλιμένη επιφάνεια των φωτοβολταϊκών στοιχείων (Inclined Irradiance) και τη θερμοκρασία των πλαισίων (Module temperature). Επιπρόσθετα, διατίθενται μετρήσεις για την περιβαλλοντική θερμοκρασία (Ambient temperature), τη σχετική υγρασία (Relative humidity), τον υετό (Precipitation), την ταχύτητα και την κατεύθυνση του ανέμου (Wind speed & direction). Παράλληλα, είναι διαθέσιμες οι αντίστοιχες μετρήσεις της ενεργού και αέργου ισχύος που παράγει ή καταναλώνει η εγκατάσταση.

Καθώς η γεωγραφική θέση του φωτοβολταϊκού πάρκου «Lamprini» διαφέρει από εκείνη του πάρκου της «Περδικούλας», είναι απαραίτητο να μελετηθεί εκ νέου η συσχέτιση μεταξύ των διαθέσιμων μεταβλητών εισόδου και της παραγόμενης φωτοβολταϊκής ισχύος. Στον Πίνακα 4.1 παρουσιάζονται οι τιμές του συντελεστή συσχέτισης Pearson μεταξύ της ισχύος εξόδου (Power) και των υπόλοιπων παραμέτρων εισόδου, οι οποίες υπολογίστηκαν για το σύνολο των ιστορικών δεδομένων του πάρκου «Lamprini». Το πρώτο σύνολο μετρήσεων που αφορά την ηλιακή ακτινοβολία εμφανίζει την ισχυρότερη συσχέτιση, ενώ για το δεύτερο σύνολο υπολογίζεται σημαντικά χαμηλότερος συντελεστής Pearson, γεγονός που ενδεχομένως οφείλεται σε κάποια δυσλειτουργία του αντίστοιχου πυρανόμετρου (όργανο μέτρησης της έντασης της ηλιακής ακτινοβολίας). Ταυτόχρονα, παρόμοια συμπεριφορά παρατηρείται και για τα δύο σύνολα μετρήσεων που αφορούν τη θερμοκρασία των πλαισίων, τα οποία παρουσιάζουν τους αμέσως υψηλότερους θετικούς συντελεστές συσχέτισης.

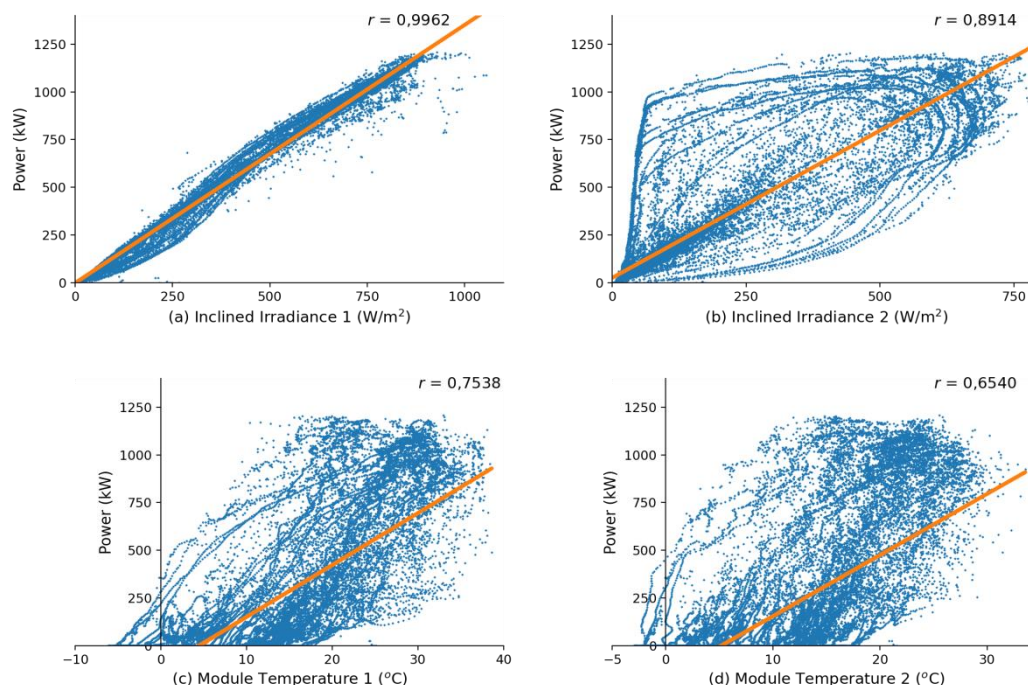
Πίνακας 4.1: Συντελεστής συσχέτισης Pearson μεταξύ της φωτοβολταϊκής ισχύος εξόδου και των διαθέσιμων παραμέτρων εισόδου

	Reactive Power	Incl. Irrad. 1	Incl. Irrad. 2	Amb. Temp.	Precip.	Rel. Hum.	Wind Dir.	Wind Speed	Mod. Temp. 1	Mod. Temp. 2
Power	-0,9698	0,9921	0,8928	0,4466	-0,0635	-0,5258	0,2891	0,3626	0,8239	0,7415

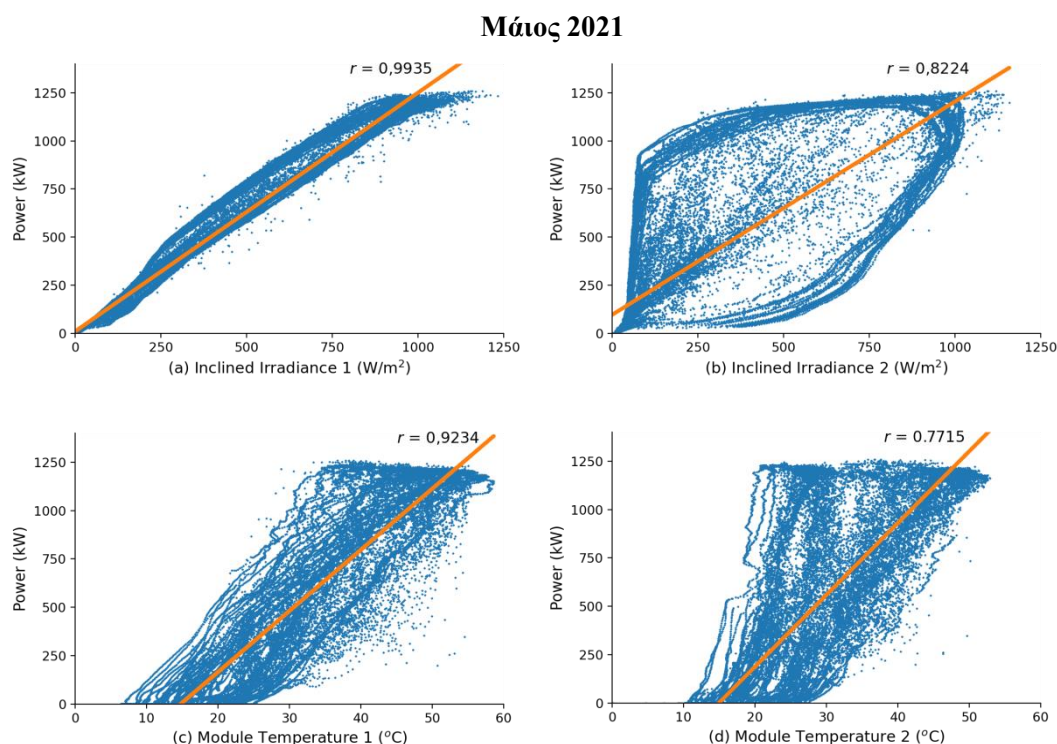
Η άεργος ισχύς (Reactive Power) εμφανίζει ξανά πολύ ισχυρή αρνητική συσχέτιση με την ισχύ εξόδου, ενώ σχετικά ισχυρή είναι και η αρνητική συσχέτιση της σχετικής υγρασίας. Παράλληλα, η κατεύθυνση του ανέμου και ο υετός παρουσιάζουν και πάλι ασθενή συσχέτιση με την παραγόμενη ισχύ, όπως και στο φωτοβολταϊκό πάρκο της «Περδικούλας».

Η επίδραση των μεταβλητών εισόδου στην έξοδο του μοντέλου πρόβλεψης μπορεί, επίσης, να αξιολογηθεί με τη χρήση μοντέλων γραμμικής παλινδρόμησης (linear regression), όπως αυτά που απεικονίζονται στα Σχήματα 4.2 και 4.3. Για τη δημιουργία του Σχήματος 4.2 έγινε χρήση των δεδομένων του Ιανουαρίου 2021 και υπολογίστηκαν η ευθεία γραμμικής παλινδρόμησης και ο συντελεστής Pearson ανάμεσα στη φωτοβολταϊκή ισχύ εξόδου και: 1) τα δύο διαφορετικά σύνολα μετρήσεων της ηλιακής ακτινοβολίας (a, b), και 2) τα δύο διαφορετικά σύνολα μετρήσεων της θερμοκρασίας των πλαισίων (c, d). Στη συνέχεια, για την κατασκευή του Σχήματος 4.3 ακολουθήθηκε η ίδια διαδικασία, αλλά χρησιμοποιήθηκαν τα ιστορικά δεδομένα του Μαΐου 2021 για το φωτοβολταϊκό πάρκο «Lamprini».

Ιανουάριος 2021



Σχήμα 4.2: Δεδομένα Ιανουαρίου 2021: Ευθεία γραμμικής παλινδρόμησης και συσχέτιση μεταξύ της ισχύος εξόδου και (a) του 1^{ου} συνόλου μετρήσεων ηλιακής ακτινοβολίας, (b) του 2^{ου} συνόλου μετρήσεων ηλιακής ακτινοβολίας, (c) του 1^{ου} συνόλου μετρήσεων της θερμοκρασίας των πλαισίων, (d) του 2^{ου} συνόλου μετρήσεων της θερμοκρασίας των πλαισίων



Σχήμα 4.3: Δεδομένα Μαΐου 2021: Ευθεία γραμμικής παλινδρόμησης και συσχέτιση μεταξύ της ισχύος εξόδου και (α) του 1^{ου} συνόλου μετρήσεων ηλιακής ακτινοβολίας, (β) του 2^{ου} συνόλου μετρήσεων ηλιακής ακτινοβολίας, (γ) του 1^{ου} συνόλου μετρήσεων της θερμοκρασίας των πλαισίων, (δ) του 2^{ου} συνόλου μετρήσεων της θερμοκρασίας των πλαισίων

Όπως φαίνεται στα Σχήματα 4.2 και 4.3, τα σύνολα μετρήσεων με χαρακτηριστικό αριθμό ένα (1) παρουσιάζουν ισχυρότερη συσχέτιση με την παραγόμενη φωτοβολταϊκή ισχύ συγκριτικά με τα αντίστοιχα σύνολα με χαρακτηριστικό αριθμό δύο (2) και για τους δύο μήνες που εξετάστηκαν. Η συμπεριφορά αυτή συνάδει με τις αντίστοιχες τιμές του συντελεστή συσχέτισης Pearson που υπολογίστηκαν για το σύνολο των διαθέσιμων ιστορικών δεδομένων, ενισχύοντας την πεποίθηση ότι τα δεδομένα που προέρχονται από τα δεύτερα κατά σειρά σύνολα μετρήσεων είναι προβληματικά. Τέλος, αξίζει να σημειωθεί ότι ενώ η συσχέτιση του πρώτου συνόλου μετρήσεων της ηλιακής ακτινοβολίας παρουσιάζει πολύ μικρή απόκλιση για τους δύο εξεταζόμενους μήνες, ο αντίστοιχος συντελεστής συσχέτισης της θερμοκρασίας των πλαισίων αυξάνεται σημαντικά τον Μάιο, συμβαδίζοντας με τις αυξημένες θερμοκρασίες που παρατηρούνται.

4.3 ΠΡΟΕΠΕΞΕΡΓΑΣΙΑ ΔΕΔΟΜΕΝΩΝ ΕΙΣΟΔΟΥ

Τα ιστορικά δεδομένα φωτοβολταϊκής παραγωγής καθώς και οι αντίστοιχες μετεωρολογικές μετρήσεις αποτελούν συνήθεις εισόδους πολλών μοντέλων πρόβλεψης της φωτοβολταϊκής παραγωγής. Ωστόσο, τα παραπάνω ιστορικά δεδομένα συχνά περιλαμβάνουν αιχμές και μη στάσιμα στοιχεία που οφείλονται στις μεταβλητές μετεωρολογικές συνθήκες,

στην εποχικότητα, σε διακυμάνσεις της ζήτησης ηλεκτρικής ενέργειας και σε βλάβες του συστήματος ηλεκτρικής ενέργειας. Οι ακραίες αυτές τιμές επηρεάζουν σημαντικά την ακρίβεια της παραγόμενης πρόβλεψης, καθώς οδηγούν σε μεγάλα σφάλματα πρόβλεψης που πηγάζουν από την ανεπαρκή εκπαίδευση του μοντέλου που χρησιμοποιείται. Η προεπεξεργασία των διαθέσιμων ιστορικών δεδομένων μπορεί να αμβλύνει σημαντικά το πρόβλημα της ανεπαρκούς εκπαίδευσης του εκάστοτε μοντέλου. Κατά συνέπεια, έχουν εφαρμοστεί αρκετές μέθοδοι προεπεξεργασίας των δεδομένων εισόδου των μοντέλων πρόβλεψης.

Ο μετασχηματισμός κυματιδίων (Wavelet Transform – WT) και η κανονικοποίηση (normalization) αποτελούν δύο πολύ διαδεδομένες τεχνικές προεπεξεργασίας δεδομένων, καθώς μπορούν να τροποποιήσουν το εύρος τιμών των δεδομένων. Συγκεκριμένα, η κανονικοποίηση χρησιμοποιείται για να περιορίσει το εύρος τιμών των διάφορων μεταβλητών εισόδου, οι οποίες συχνά ανήκουν σε διαφορετικές τάξεις μεγέθους, σε ένα μικρότερο εύρος τιμών, διατηρώντας παράλληλα τη μεταξύ τους συσχέτιση. Έτσι, η μέθοδος της κανονικοποίησης συμβάλλει στη μείωση των σφαλμάτων πρόβλεψης και του υπολογιστικού κόστους βελτιώνοντας, έτσι, την ακρίβεια και την απόδοση του μοντέλου.

Η κανονικοποίηση των δεδομένων εισόδου, η οποία εφαρμόζεται και στην παρούσα διπλωματική εργασία, συνήθως περιορίζει το εύρος τιμών των παραμέτρων εισόδου είτε στο διάστημα $[-1,1]$ είτε στο διάστημα $[0,1]$. Το διάστημα που επιλέγεται για τη διαδικασία της κανονικοποίησης συχνά καθορίζεται από τις αρχικές τιμές των δεδομένων εισόδου. Επειδή τα ιστορικά δεδομένα των φωτοβολταϊκών πάρκων «Περδικούλα» και «Lamprini» περιλαμβάνουν κυρίως θετικές τιμές, η κανονικοποίηση των τιμών των παραμέτρων εισόδου πραγματοποιήθηκε, κατά κανόνα, στο διάστημα $[0,1]$. Συγκεκριμένα, εφαρμόστηκε η μέθοδος κανονικοποίησης μεγίστου-ελαχίστου, η οποία για κανονικοποίηση στο διάστημα $[0,1]$ περιγράφεται από την εξίσωση [41]:

$$x_{Normal,i} = \frac{x_{actual,i} - x_{min}}{x_{max} - x_{min}} \quad (4.1)$$

όπου $x_{Normal,i}$ είναι η νέα, κανονικοποιημένη τιμή του i -οστού δεδομένου εισόδου x_i , $x_{actual,i}$ είναι η πραγματική τιμή του δεδομένου εισόδου x_i και x_{max} , x_{min} είναι η μέγιστη και η ελάχιστη τιμή της μεταβλητής (ή παραμέτρου ή κατηγορίας) εισόδου στην οποία αντιστοιχεί το δεδομένο εισόδου x_i .

ΜΟΝΤΕΛΑ ΠΡΟΒΛΕΨΗΣ ΤΗΣ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ

5.1 ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ ΜΕ ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΕΜΠΡΟΣΘΙΑΣ ΤΡΟΦΟΔΟΤΗΣΗΣ

5.1.1 Εισαγωγή στα νευρωνικά δίκτυα εμπρόςθιας τροφοδότησης

Το πρώτο μοντέλο πρόβλεψης που υλοποιείται με σκοπό τη βραχυπρόθεσμη πρόβλεψη της φωτοβολταϊκής παραγωγής βασίζεται στα νευρωνικά δίκτυα εμπρόςθιας τροφοδότησης (feedforward). Η αρχιτεκτονική των feedforward νευρωνικών δικτύων χαρακτηρίζεται από την απουσία βρόχων ανατροφοδότησης μεταξύ των διαφορετικών στρωμάτων του νευρωνικού δικτύου ενώ, ταυτόχρονα, δεν υπάρχουν συνδέσεις μεταξύ των νευρώνων που ανήκουν στο ίδιο στρώμα [8]. Επομένως, η ροή της παρεχόμενης πληροφορίας πραγματοποιείται προς μία κατεύθυνση, από το στρώμα εισόδου προς το στρώμα εξόδου, μέσω της διαδοχικής σύνδεσης των στρωμάτων που συγκροτούν το νευρωνικό δίκτυο.

Ο παραπάνω τρόπος διασύνδεσης των νευρώνων επηρεάζει άμεσα τη συμπεριφορά που εμφανίζουν τα συγκεκριμένα δίκτυα. Έτσι, τα feedforward νευρωνικά δίκτυα είναι, εν γένει, στατικά συστήματα τα οποία δεν διαθέτουν μνήμη, υπό την έννοια ότι η απόκρισή τους σε μια νέα, άγνωστη είσοδο δεν εξαρτάται από την προηγούμενη κατάσταση του δικτύου. Παράλληλα, η αρχιτεκτονική του εκάστοτε νευρωνικού δικτύου σχετίζεται και με την επιλογή του κατάλληλου αλγορίθμου εκπαίδευσης.

Η πιο διαδεδομένη κατηγορία feedforward νευρωνικών δικτύων είναι τα στατικά multilayer perceptrons (MLPs), τα οποία χρησιμοποιούνται και στην παρούσα διπλωματική εργασία. Αναφορικά με τη διαδικασία μάθησης των συγκεκριμένων δικτύων, ο αλγόριθμος εκπαίδευσης με προς τα πίσω διάδοση του σφάλματος (backpropagation) αποτελεί μια υπολογιστικά αποδοτική και ιδιαίτερα χρήσιμη μέθοδο εκπαίδευσής τους [3]. Έτσι, τα πολυστρωματικά perceptrons που εκπαιδεύονται με χρήση του αλγορίθμου backpropagation συνιστούν μια πολύ δημοφιλή επιλογή μεταξύ των ερευνητών, αλλά και άλλων χρηστών που αξιοποιούν τα τεχνητά νευρωνικά δίκτυα.

Παρά τη δημοφιλία τους, η σχεδίαση feedforward νευρωνικών δικτύων παραμένει μια δύσκολη διαδικασία. Η πλειονότητα των δυσκολιών που παρατηρούνται έγκειται στην κατάλληλη επιλογή των υπερπαραμέτρων του εκάστοτε νευρωνικού δικτύου, όπως ο αριθμός των κρυφών στρωμάτων και ο αριθμός των νευρώνων κάθε στρώματος, ώστε το δίκτυο να αποκτήσει την ικανότητα της γενίκευσης, δηλαδή την ικανότητα να ανταποκρίνεται ικανοποιητικά σε άγνωστα δεδομένα. Η βέλτιστη επιλογή των υπερπαραμέτρων επιδιώκεται συνήθως μέσω δοκιμών, γεγονός που καθιστά τη διαδικασία της βελτιστοποίησης ιδιαίτερα επίπονη και χρονοβόρα.

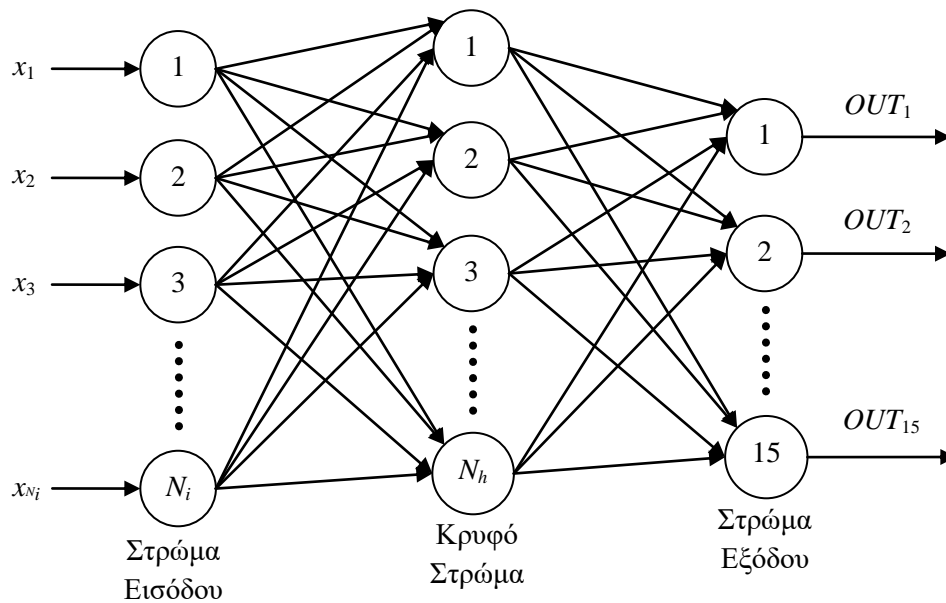
5.1.2 Κατασκευή του μοντέλου

Το πρώτο μοντέλο πρόβλεψης που κατασκευάζεται στο πλαίσιο της παρούσας διπλωματικής εργασίας είναι ένα νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης (FFNN), το οποίο σχεδιάζεται με βάση τη δομή του multilayer perceptron (MLP). Επομένως, το μοντέλο πρόβλεψης που υλοποιείται διαθέτει τουλάχιστον ένα κρυφό στρώμα και εμφανίζει υψηλό βαθμό συνδεσιμότητας ενώ οι νευρώνες του χρησιμοποιούν μη γραμμικές, διαφορίσιμες συναρτήσεις ενεργοποίησης [3]. Ο αριθμός των κρυφών στρωμάτων και η συνάρτηση ενεργοποίησης κάθε στρώματος επιλέγονται κατά τη σχεδίαση του δικτύου, ενώ ο βαθμός συνδεσιμότητας καθορίζεται από το πλήθος των συναπτικών του βαρών.

Ο σκοπός των μοντέλων πρόβλεψης που υλοποιούνται στην παρούσα διπλωματική εργασία είναι η βραχυπρόθεσμη πρόβλεψη της παραγόμενης ισχύος που καταγράφεται στην έξοδο φωτοβολταϊκών πάρκων. Τα ιστορικά δεδομένα που χρησιμοποιούνται κατά τις διαδικασίες εκπαίδευσης και αξιολόγησης των συγκεκριμένων μοντέλων προέρχονται από τα φωτοβολταϊκά πάρκα «Περδικούλα» και «Lampirini». Ωστόσο, η επιλογή του αριθμού των νευρώνων που συγκροτούν το στρώμα εισόδου (N_i) σχετίζεται άμεσα με τις διαθέσιμες παραμέτρους εισόδου. Επομένως, ο αριθμός των νευρώνων εισόδου τόσο του πρώτου μοντέλου πρόβλεψης (MLP) όσο και του δεύτερου, το οποίο περιγράφεται στην Ενότητα 5.2, επιλέγεται ανάλογα με το φωτοβολταϊκό πάρκο για το οποίο παράγεται η πρόβλεψη. Σε κάθε περίπτωση, λαμβάνεται υπόψη η συσχέτιση μεταξύ των παραμέτρων εισόδου και της ισχύος εξόδου, καθώς και η επιρροή των επιλεγμένων παραμέτρων στην απόδοση και την ακρίβεια των μοντέλων πρόβλεψης.

Όσον αφορά τους νευρώνες του στρώματος εξόδου, ο αριθμός τους καθορίζεται από τη λειτουργία που καλείται να επιτελέσει το τεχνητό νευρωνικό δίκτυο. Στην περίπτωση του πάρκου της «Περδικούλας», το νευρωνικό δίκτυο θα πρέπει να προβλέπει τη συνολική ενεργό ισχύ στην έξοδο του φωτοβολταϊκού πάρκου σε χρονικό ορίζοντα 225 λεπτών με χρονικό βήμα τα 15 λεπτά, με αφετηρία κάποια χρονική στιγμή που αντιστοιχεί σε 0, 15, 30 ή 45 λεπτά της εκάστοτε ώρας. Άρα, το μοντέλο πρόβλεψης που χρησιμοποιείται θα πρέπει να παράγει 15 προβλέψεις, όπου η πρώτη παραγόμενη πρόβλεψη θα αφορά τα επόμενα 15 λεπτά, η δεύτερη πρόβλεψη τα επόμενα 30 λεπτά και ούτω καθεξής μέχρι την τελευταία πρόβλεψη η οποία θα αφορά τα επόμενα 225 λεπτά, δηλαδή τη χρονική στιγμή που συμπίπτει με το τέλος του ορίζοντα πρόβλεψης. Τα μοντέλα πρόβλεψης που αναπτύσσονται στην παρούσα διπλωματική εργασία, συμπεριλαμβανομένου του μοντέλου MLP, παράγουν ταυτόχρονα τις 15 ζητούμενες προβλέψεις ως ένα διάνυσμα εξόδου το οποίο αποτελείται από 15 συνιστώσες. Επομένως, το στρώμα εξόδου των αντίστοιχων νευρωνικών δικτύων συγκροτείται από 15 νευρώνες εξόδου, έναν για κάθε τιμή πρόβλεψης.

Αναφορικά με το φωτοβολταϊκό πάρκο «Lampirini», η πρόβλεψη της ενεργού ισχύος εξόδου του πάρκου πραγματοποιείται για δύο διακριτούς χρονικούς ορίζοντες. Αρχικά, κατασκευάζεται νευρωνικό δίκτυο το οποίο προβλέπει την ισχύ εξόδου σε χρονικό ορίζοντα 15 λεπτών με χρονικό βήμα το ένα (1) λεπτό, ενώ ένα δεύτερο δίκτυο καλείται να προβλέψει τη φωτοβολταϊκή παραγωγή του πάρκου για χρονικό ορίζοντα 225 λεπτών με βήμα τα 15 λεπτά, εκκινώντας και πάλι από χρονική στιγμή που αντιστοιχεί σε 0, 15, 30 ή 45 λεπτά της αντίστοιχης ώρας. Άρα, η ταυτόχρονη παραγωγή των προβλέψεων που αντιστοιχούν στους δύο αυτούς χρονικούς ορίζοντες απαιτεί ξανά την ύπαρξη 15 νευρώνων εξόδου.



Σχήμα 5.1: Η δομή του νευρωνικού δικτύου εμπρόσθιας τροφοδότησης που χρησιμοποιείται από το μοντέλο MLP

Στο Σχήμα 5.1 απεικονίζεται ενδεικτικά η δομή του feedforward νευρωνικού δικτύου του μοντέλου MLP. Ο αριθμός νευρώνων εισόδου N_i και ο αριθμός κρυφών νευρώνων N_h επιλέγονται κατά τη σχεδίαση του δικτύου, ενώ το ενδεικτικό δίκτυο του Σχήματος 5.1 είναι πλήρως διασυνδεδεμένο. Ωστόσο, μία προσέγγιση όσον αφορά τη βελτιστοποίηση του μοντέλου πρόβλεψης, η οποία αναφέρεται ως κλάδεμα (pruning), μπορεί να μειώσει το βαθμό συνδεσιμότητας του νευρωνικού δικτύου. Συγκεκριμένα, το κλάδεμα του δικτύου υλοποιείται με την απαλοιφή των συναπτικών βαρών τα οποία κρίνονται αμελητέα καθώς στα συγκεκριμένα βάρη αποδίδεται μόνιμα η μηδενική τιμή. Η αφαίρεση συναπτικών βαρών από ένα πλήρως διασυνδεδεμένο δίκτυο μπορεί να πραγματοποιηθεί κατά τη διάρκεια της εκπαίδευσης ή μετά την ολοκλήρωσή της, ενώ υπάρχει η δυνατότητα να χρησιμοποιηθούν διάφοροι αλγόριθμοι κλαδέματος [17]. Το κλάδεμα ενός νευρωνικού δικτύου μπορεί να βελτιώσει την ικανότητα γενίκευσης του δικτύου, να μειώσει την πολυπλοκότητά του και τις απαιτήσεις σε hardware ή μνήμη καθώς και να αυξήσει την ταχύτητα ενδεχόμενης περαιτέρω εκπαίδευσής του [47].

Ο σκοπός των αναπτυσσόμενων μοντέλων πρόβλεψης σχετίζεται, επίσης, με την αντικειμενική συνάρτηση εκπαίδευσης των αντίστοιχων νευρωνικών δικτύων. Επομένως, όσον αφορά τα προβλήματα βραχυπρόθεσμης πρόβλεψης της φωτοβολταϊκής παραγωγής που περιγράφηκαν παραπάνω, επιλέγεται ως συνάρτηση κόστους το Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (*MAPE*), το οποίο ορίζεται από την εξίσωση (3.3). Η εκπαίδευση των νευρωνικών δικτύων που κατασκευάστηκαν στοχεύει στην ελαχιστοποίηση της συνάρτησης κόστους που επιλέχθηκε. Η εκπαίδευση του μοντέλου MLP πραγματοποιείται κάνοντας χρήση του αλγορίθμου backpropagation.

5.1.3 Εκπαίδευση του μοντέλου

Τα τεχνητά νευρωνικά δίκτυα που περιλαμβάνουν κρυφούς νευρώνες, όπως τα πολυστρωματικά perceptrons, είναι ικανά να πραγματοποιήσουν οποιαδήποτε χαρτογράφηση εισόδου-εξόδου, ακόμα και σε περιπτώσεις που παρόμοια πρότυπα εισόδου αντιστοιχούν σε πολύ διαφορετικά πρότυπα εξόδου. Η ικανότητα αυτή πηγάζει από την παρουσία των κρυφών νευρώνων, οι οποίοι δημιουργούν εσωτερικές αντιπροσωπεύσεις (internal representations) των προτύπων εισόδου [15]. Ωστόσο, η χρήση κρυφών νευρώνων καθιστά τη διαδικασία μάθησης των αντίστοιχων νευρωνικών δικτύων δυσκολότερη συγκριτικά με την εκπαίδευση δικτύων χωρίς κρυφά στρώματα, όπως το Perceptron του Rosenblatt. Δεδομένου ότι μέσω της συγκεκριμένης διαδικασίας μάθησης αποφασίζεται ποια χαρακτηριστικά των προτύπων εισόδου πρέπει να αντιπροσωπευθούν από τους κρυφούς νευρώνες [3], η επιπρόσθετη δυσκολία που παρατηρείται έγκειται στην κατάλληλη επιλογή μεταξύ των διαφορετικών εσωτερικών αντιπροσωπεύσεων της εισόδου, ώστε να επιτευχθεί η επιθυμητή συμπεριφορά.

Ο αλγόριθμος της προς τα πίσω διάδοσης του σφάλματος είναι μια διαδικασία μάθησης με επίβλεψη που αναπτύχθηκε για την εκπαίδευση πολυστρωματικών τεχνητών νευρωνικών δικτύων, δηλαδή δικτύων που διαθέτουν κρυφά στρώματα. Ο συγκεκριμένος αλγόριθμος εκπαίδευσης ρυθμίζει επαναλαμβανόμενα τις ελεύθερες παραμέτρους του νευρωνικού δικτύου με σκοπό να ελαχιστοποιήσει την απόκλιση που παρατηρείται ανάμεσα στα παραγόμενα από το δίκτυο διανύσματα εξόδου και τα αντίστοιχα επιθυμητά. Μέσω της παραπάνω διαδικασίας, οι κρυφοί νευρώνες του δικτύου, οι οποίοι δεν αποτελούν μέρος της εισόδου ή της εξόδου του συστήματος, είναι σε θέση να αντιπροσωπεύσουν σημαντικά χαρακτηριστικά του πεδίου τιμών το οποίο ορίζει τη λειτουργία που καλείται να επιτελέσει το δίκτυο [48].

Κατά την εκτέλεση του αλγορίθμου backpropagation, η εκπαίδευση ενός πολυστρωματικού νευρωνικού δικτύου πραγματοποιείται σε δύο φάσεις [3], [15]:

1. Αρχικά, οι τιμές των συναπτικών βαρών και των πολώσεων των νευρώνων του δικτύου διατηρούνται σταθερές καθώς το σήμα εισόδου διαδίδεται προς τα εμπρός στο δίκτυο, στρώμα προς στρώμα, καταλήγοντας στο στρώμα εξόδου, ώστε να υπολογιστεί η τιμή της εξόδου κάθε νευρώνα του δικτύου. Η πρώτη αυτή φάση, η οποία αναφέρεται ως forward phase, ολοκληρώνεται με τη σύγκριση των τιμών που παράγουν οι νευρώνες εξόδου του δικτύου με τις αντίστοιχες επιθυμητές, ώστε να υπολογιστεί το σήμα σφάλματος για κάθε νευρώνα του στρώματος εξόδου.
2. Η δεύτερη φάση, η οποία αναφέρεται ως backward phase, περιλαμβάνει ένα ανάλογο πέρασμα μέσω του δικτύου, το οποίο, ωστόσο, πραγματοποιείται προς την αντίθετη κατεύθυνση καθώς τα σήματα σφάλματος που υπολογίστηκαν διαδίδονται προς τα πίσω, ξεκινώντας από το στρώμα εξόδου. Κατά την προς τα πίσω διάδοση αυτών των σημάτων, πραγματοποιούνται διαδοχικές προσαρμογές των ελεύθερων παραμέτρων του δικτύου. Ο υπολογισμός των συγκεκριμένων προσαρμογών ξεκινά από το στρώμα εξόδου, ενώ υλοποιείται με διαφορετικό τρόπο για τους νευρώνες εξόδου και τους νευρώνες που συγκροτούν τα κρυφά στρώματα του δικτύου.

Η διαδικασία επιτηρούμενης μάθησης που βασίζεται στη χρησιμοποίηση του αλγορίθμου backpropagation συνιστά μια διαδικασία κατάβασης κλίσης, η οποία εφαρμόζεται στην αντικειμενική συνάρτηση που έχει επιλεχθεί για την εκπαίδευση του νευρωνικού δικτύου. Η κατάβαση κλίσης (gradient descent) είναι μία μέθοδος βελτιστοποίησης που αναζητά το ελάχιστο της επιφάνειας σφάλματος στον χώρο των ελεύθερων παραμέτρων του δικτύου, καθώς τα συναπτικά βάρη και οι πολώσεις των νευρώνων του ρυθμίζονται επαναληπτικά με σκοπό την ελαχιστοποίηση της επιλεγμένης συνάρτησης κόστους. Σε κάθε επανάληψη, η μέθοδος gradient descent, η οποία είναι συνυφασμένη με τον αλγόριθμο της προς τα πίσω διάδοσης του σφάλματος, απαιτεί τον υπολογισμό της κλίσης της αντικειμενικής συνάρτησης συναρτήσει κάθε ελεύθερης παραμέτρου του δικτύου [49]. Ο αλγόριθμος backpropagation είναι ένας ιδιαίτερα αποδοτικός τρόπος υπολογισμού των ζητούμενων μερικών παραγώγων, ειδικά για νευρωνικά δίκτυα τα οποία περιλαμβάνουν κρυφούς νευρώνες.

Για ένα δεδομένο διάνυσμα εισόδου, η εφαρμογή του αλγορίθμου της προς τα πίσω διάδοσης του σφάλματος ξεκινά από ένα εμπρόσθιο πέρασμα (forward pass) στο νευρωνικό δίκτυο, κατά το οποίο υπολογίζονται το αντίστοιχο διάνυσμα εξόδου καθώς και τα επιμέρους σήματα σφάλματος που προκύπτουν στους νευρώνες εξόδου. Η προσαρμογή των ελεύθερων παραμέτρων του δικτύου – η οποία πραγματοποιείται κατά τη δεύτερη φάση του αλγορίθμου, ξεκινώντας από το στρώμα εξόδου – υλοποιείται σύμφωνα με τον γενικευμένο κανόνα δέλτα (generalized delta rule) για feedforward νευρωνικά δίκτυα [15], ο οποίος περιγράφεται από τις ακόλουθες αναδρομικές εξισώσεις εκπαίδευσης:

$$\Delta w_{pj,qk}(n+1) = \eta \cdot \delta_{qk} \cdot y_{pj} + m \cdot \Delta w_{pj,qk}(n) \quad (5.1)$$

$$w_{pj,qk}(n+1) = w_{pj,qk}(n) + \Delta w_{pj,qk}(n+1) \quad (5.2)$$

όπου n είναι ο αύξων αριθμός της επανάληψης της διαδικασίας εκπαίδευσης, η είναι ο ρυθμός μάθησης, m είναι ο συντελεστής ορμής, y_{pj} είναι η τιμή που παράγει ο νευρώνας p του στρώματος j στην έξοδό του, $w_{pj,qk}$ είναι η τιμή του συναπτικού βάρους που συνδέει τον νευρώνα p του στρώματος j με τον νευρώνα q του αμέσως επόμενου στρώματος k , $\Delta w_{pj,qk}$ είναι η μεταβολή του αντίστοιχου βάρους $w_{pj,qk}$ και δ_{qk} είναι ο συντελεστής μεταβολής δ του νευρώνα q του στρώματος k .

Ο συντελεστής μεταβολής δ αφορά τα υπολογιζόμενα σήματα σφάλματος τα οποία διαδίδονται προς τα πίσω στο νευρωνικό δίκτυο. Ο υπολογισμός του είναι μια αναδρομική διαδικασία η οποία ξεκινά από τους νευρώνες του στρώματος εξόδου. Για έναν νευρώνα εξόδου, ο υπολογισμός του δ γίνεται μέσω της εξίσωσης (5.3):

$$\delta_{qk} = (y_{qk} - \hat{y}_{qk}) \cdot \frac{\partial f_{qk}}{\partial z_{qk}} \quad (5.3)$$

όπου y_{qk} είναι η επιθυμητή έξοδος του νευρώνα q του στρώματος k , το οποίο θεωρείται ως το στρώμα εξόδου, \hat{y}_{qk} είναι η αντίστοιχη έξοδος που υπολογίζεται από το νευρωνικό δίκτυο

και $\frac{\partial f_{qk}}{\partial z_{qk}}$ είναι η μερική παράγωγος της συνάρτησης ενεργοποίησης του νευρώνα q ως προς

τη συνολική είσοδό του. Ο υπολογισμός του δ για κάθε νευρώνα εξόδου αποτελεί το πρώτο βήμα του προς τα πίσω περάσματος (backward pass), το οποίο πραγματοποιείται στο πλαίσιο του αλγορίθμου backpropagation. Στη συνέχεια, μπορούν να υπολογιστούν οι μεταβολές όλων των συναπτικών βαρών που τροφοδοτούν το στρώμα εξόδου [15].

Για τους κρυφούς νευρώνες του δικτύου, δεν υπάρχει κάποια προκαθορισμένη επιθυμητή τιμή όσον αφορά την έξοδό τους. Επομένως, ο υπολογισμός του δ δεν μπορεί να πραγματοποιηθεί χρησιμοποιώντας την εξίσωση (5.3), η οποία αφορά αποκλειστικά τους νευρώνες εξόδου. Έτσι, το σήμα σφάλματος ενός κρυφού νευρώνα υπολογίζεται αναδρομικά με βάση τα σήματα σφάλματος των νευρώνων του αμέσως επόμενου στρώματος με τους οποίους συνδέεται άμεσα καθώς και τα αντίστοιχα συναπτικά βάρη [15], μέσω της ακόλουθης σχέσης:

$$\delta_{pj} = \frac{\partial f_{pj}}{\partial z_{pj}} \cdot \sum_q \delta_{qk} \cdot w_{pj,qk} \quad (5.4)$$

όπου $\frac{\partial f_{pj}}{\partial z_{pj}}$ είναι η μερική παράγωγος της συνάρτησης ενεργοποίησης του νευρώνα p του

στρώματος j ως προς τη συνολική είσοδό του, $w_{pj,qk}$ είναι η τιμή του συναπτικού βάρους που συνδέει τον νευρώνα p του στρώματος j με κάποιον νευρώνα q του αμέσως επόμενου στρώματος k και δ_{qk} είναι ο συντελεστής μεταβολής δ που έχει ήδη υπολογιστεί για τον εκάστοτε νευρώνα q . Από την εξίσωση (5.4) γίνεται έκδηλο ότι ο υπολογισμός του συντελεστή δ για έναν κρυφό νευρώνα απαιτεί τη γνώση των σημάτων σφάλματος όλων των νευρώνων του αμέσως επόμενου στρώματος με τους οποίους υπάρχει άμεση σύνδεση καθώς και των συναπτικών βαρών που χαρακτηρίζουν τις συγκεκριμένες συνδέσεις [3].

Αξίζει να σημειωθεί ότι η εξίσωση (5.1) αποτελεί μια τροποποιημένη μορφή του γενικευμένου κανόνα δέλτα, καθώς περιλαμβάνει τον όρο ορμής $m \cdot \Delta w_{pj,qk}(n)$. Ο συντελεστής m καθορίζει την επίδραση που έχει η προηγούμενη αλλαγή, στην οποία έχει ήδη υποβληθεί κάθε συναπτικό βάρος, στην τρέχουσα κατεύθυνση κίνησης στον χώρο των ελεύθερων παραμέτρων του δικτύου [15]. Ο γενικευμένος κανόνας δέλτα, ο οποίος δεν περιλαμβάνει τον όρο ορμής, δίνεται από την εξίσωση (5.5):

$$\Delta w_{pj,qk} = -\eta \cdot \frac{\partial E}{\partial w_{pj,qk}} \quad (5.5)$$

όπου E είναι η επιλεγμένη συνάρτηση κόστους και:

$$-\frac{\partial E}{\partial w_{pj,qk}} = \delta_{qk} \cdot y_{pj} \quad (5.6)$$

Σύμφωνα με την εξίσωση (5.5), η μεταβολή του εκάστοτε συναπτικού βάρους, όπως αυτή υπαγορεύεται από τον γενικευμένο κανόνα δέλτα, είναι ανάλογη με την παράγωγο της συνάρτησης κόστους ως προς το βάρος αυτό, και μάλιστα με αρνητική σταθερά αναλογίας.

Το αρνητικό πρόσημο της σταθεράς αναλογίας συνιστά την εκτέλεση κατάβασης κλίσης στον χώρο των ελεύθερων παραμέτρων του νευρωνικού δικτύου αναφορικά με την επιφάνεια σφάλματος που ορίζεται από τη συνάρτηση κόστους E , καθώς η μέθοδος gradient descent αναζητά μια κατεύθυνση κίνησης για την οποία η μεταβολή του συναπτικού βάρους συνεπάγεται μείωση της τιμής της συνάρτησης κόστους [3].

Παρά την υπολογιστική αποδοτικότητα του αλγορίθμου backpropagation, το γεγονός ότι βασίζεται στη μέθοδο κατάβασης κλίσης έχει ως αποτέλεσμα την εμφάνιση αντίστοιχων προβλημάτων. Το κυριότερο είναι το πρόβλημα των τοπικών ελαχίστων στα οποία μπορεί να παγιδευτεί ο αλγόριθμος κατά τη διαδικασία της εκπαίδευσης – πρόβλημα το οποίο παρατηρείται σε οποιαδήποτε τεχνική βελτιστοποίησης αναρρίχησης λόφων (Hill climbing) – καθώς στο σημείο του τοπικού ελαχίστου κάθε μικρή αλλαγή των ελεύθερων παραμέτρων του δικτύου οδηγεί σε αύξηση της συνάρτησης κόστους. Άλλα προβλήματα αφορούν την αργή σύγκλιση του αλγορίθμου σε κάποιο ελάχιστο της επιφάνειας σφάλματος καθώς και τη μεγάλη ευαισθησία που παρουσιάζει όσον αφορά την (αρχική) επιλογή του ρυθμού μάθησης.

Το πρώτο μοντέλο πρόβλεψης που αναπτύσσεται στην παρούσα διπλωματική εργασία είναι ένα πολυστρωματικό perceptron, δηλαδή ένα νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης που περιλαμβάνει κρυφούς νευρώνες. Επομένως, η εκπαίδευση του συγκεκριμένου μοντέλου πραγματοποιείται με χρήση του αλγορίθμου προς τα πίσω διάδοσης του σφάλματος. Ως διαδικασία μάθησης με επίβλεψη, ο αλγόριθμος backpropagation απαιτεί την ύπαρξη ενός συνόλου εκπαίδευσης το οποίο αποτελείται από διανύσματα εισόδου καθώς και από τα αντίστοιχα επιθυμητά διανύσματα εξόδου. Τόσο το φωτοβολταϊκό πάρκο της «Περδικούλας» όσο και το φωτοβολταϊκό πάρκο «Lampirini» διαθέτουν τα ιστορικά δεδομένα που απαιτούνται για τη δημιουργία τέτοιων συνόλων εκπαίδευσης.

Τα διανύσματα εισόδου που χρησιμοποιούνται για την εκπαίδευση των νευρωνικών δικτύων του μοντέλου MLP με σκοπό την πρόβλεψη της φωτοβολταϊκής ισχύος στην έξοδο των παραπάνω φωτοβολταϊκών πάρκων είναι δυνατόν να περιλαμβάνουν τόσο μετεωρολογικές μετρήσεις όσο και μετρήσεις ισχύος του εκάστοτε πάρκου. Παράλληλα, ως συνιστώσες των διανυσμάτων εισόδου ορίζονται ο αριθμός της ημέρας του έτους (Day of Year – DoY) αλλά και η χρονική στιγμή της ημέρας (t) που χαρακτηρίζουν το εκάστοτε σύνολο μετρήσεων. Οι συνιστώσες αυτές εξάγονται από τη χρονική σήμανση (Timestamp) η οποία είναι διαθέσιμη για κάθε σύνολο μετρήσεων, ενώ οι τιμές που λαμβάνουν ανήκουν στα ακόλουθα εύρη τιμών:

- Ο αριθμός της ημέρας παίρνει τιμές από 1 έως 365 για τα μη δίσεκτα έτη, όπως το 2019 και το 2021, με την τιμή 1 να αντιστοιχεί στην 1^η Ιανουαρίου και την τιμή 365 στην 31^η Δεκεμβρίου. Για τα δίσεκτα έτη, όπως το 2020, το εύρος των τιμών που χρησιμοποιούνται είναι από 1 έως 366, με την τιμή 1 να αντιστοιχεί στην 1^η Ιανουαρίου και την τιμή 366 στην 31^η Δεκεμβρίου (η μία επιπλέον τιμή αφορά την πρόσθετη ημέρα του δίσεκτου έτους στις 29 Φεβρουαρίου).
- Η χρονική στιγμή της ημέρας παίρνει τιμές ανάλογα με τη χρονική ανάλυση των διαθέσιμων ιστορικών δεδομένων. Για το φωτοβολταϊκό πάρκο «Περδικούλα», αλλά και για το πάρκο «Lampirini» όταν για αυτό παράγεται πρόβλεψη σε χρονικό ορίζοντα 225 λεπτών, η συνιστώσα t , για κάθε διαφορετική ημέρα, λαμβάνει τιμές από 1 έως 96, με $t=1$ για τη χρονική στιγμή 00:00, $t=2$ για τη χρονική στιγμή 00:15 και συνεχίζοντας με τον ίδιο τρόπο μέχρι την τελευταία

τιμή $t=96$ για τη χρονική στιγμή 23:45. Αντίθετα, όταν για το φωτοβολταϊκό πάρκο «Lampirini» διενεργείται πρόβλεψη ανά λεπτό, η τιμή της συνιστώσας t παίρνει τιμές στο εύρος 1 έως 1440, με την τιμή $t=1$ να αντιστοιχεί στη χρονική στιγμή 00:00, την τιμή $t=2$ στη χρονική στιγμή 00:01 και ούτω καθεξής μέχρι την τελευταία τιμή $t=1440$, η οποία αντιστοιχεί στη χρονική στιγμή 23:59 της εξεταζόμενης ημέρας.

Τα διανύσματα εξόδου του συνόλου εκπαίδευσης, τα οποία αναφέρονται και ως targets ή labels, συνιστούν την επιθυμητή απόκριση του αναπτυσσόμενου μοντέλου MLP, όταν αυτό τροφοδοτείται με τα αντίστοιχα διανύσματα εισόδου. Εφόσον όλες οι υλοποιήσεις του μοντέλου MLP στο πλαίσιο της παρούσας διπλωματικής εργασίας αφορούν την ταυτόχρονη παραγωγή 15 προβλέψεων στην έξοδο του εκάστοτε νευρωνικού δικτύου, τα επιθυμητά διανύσματα εξόδου αποτελούνται από 15 συνιστώσες, μία για κάθε νευρώνα εξόδου, όπως περιγράφηκε στην Ενότητα 5.1.2 για όλες τις περιπτώσεις που εξετάστηκαν. Τα νευρωνικά δίκτυα που σχεδιάστηκαν στοχεύουν, μέσα από τη διαδικασία της εκπαίδευσης, να προσεγγίσουν ικανοποιητικά την επιθυμητή απόκριση που αντιστοιχεί στα διανύσματα εισόδου με τα οποία τροφοδοτούνται και, ταυτόχρονα, να αποκτήσουν την ικανότητα της γενίκευσης. Η αξιολόγησή τους στη βάση των συγκεκριμένων στόχων πραγματοποιείται κάνοντας χρήση κατάλληλων δεικτών αξιολόγησης.

5.1.4 Αξιολόγηση του μοντέλου

Η αξιολόγηση της απόδοσης του μοντέλου MLP έγκειται στον υπολογισμό των μετρικών σφάλματος που έχουν επιλεγεί για το εξεταζόμενο πρόβλημα, και ιδιαίτερα του μετρικού *MAPE*, όπως ορίζεται στην εξίσωση (3.3). Οι τιμές των επιλεγμένων δεικτών αξιολόγησης που υπολογίζονται εξαρτώνται τόσο από τα δεδομένα εισόδου του μοντέλου όσο και από τη διαμόρφωση του αντίστοιχου τεχνητού νευρωνικού δικτύου [3]. Επομένως, η καταλληλότητα των δεδομένων που χρησιμοποιούνται ως είσοδοι του μοντέλου MLP καθώς και των υπερπαραμέτρων του νευρωνικού δικτύου μπορεί να αξιολογηθεί μέσω της αποτίμησης των παραπάνω δεικτών.

Κατά την εκπαίδευση ενός feedforward νευρωνικού δικτύου με τον αλγόριθμο της προς τα πίσω διάδοσης του σφάλματος, ο υπολογισμός των συγκεκριμένων μετρικών σφάλματος εκτείνεται σε όλους τους νευρώνες εξόδου του δικτύου και πραγματοποιείται ανά εποχή, δηλαδή αφού το νευρωνικό δίκτυο έχει τροφοδοτηθεί με όλα τα διανύσματα εισόδου που συγκροτούν το σύνολο εκπαίδευσης. Καθώς η διαδικασία της εκπαίδευσης εξελίσσεται το νευρωνικό δίκτυο υλοποιεί πιο σύνθετες χαρτογραφήσεις εισόδου-εξόδου, γεγονός που κατά κανόνα οδηγεί στη μείωση των υπολογιζόμενων μετρικών καθώς ο αριθμός των εποχών αυξάνεται [3]. Ωστόσο, αυτή η μείωση δεν συνεπάγεται απαραίτητα ότι το νευρωνικό δίκτυο έχει αποκτήσει την ικανότητα της γενίκευσης, καθώς ενδέχεται να έχει απλά απομνημονεύσει τα ζεύγη προτύπων εισόδου-εξόδου (υπερπροσαρμογή). Επομένως, είναι αναγκαίο να εκτιμηθεί η απόδοση του μοντέλου μετά το πέρας της εκπαίδευσής του, για δεδομένα εισόδου που δεν χρησιμοποιήθηκαν κατά τη διαδικασία της μάθησης. Τα δεδομένα αυτά συνιστούν το

σύνολο ελέγχου και χρησιμοποιούνται για την αξιολόγηση της συμπεριφοράς του εκπαιδευμένου μοντέλου όσον αφορά την ικανότητα γενίκευσης.

Στο πλαίσιο της παρούσας διπλωματικής εργασίας, τα δεδομένα των συνόλων εκπαίδευσης και ελέγχου έχουν την ίδια προέλευση, η οποία είναι το σύνολο των διαθέσιμων ιστορικών δεδομένων είτε του φωτοβολταϊκού πάρκου της «Περδικούλας» είτε του πάρκου «Lampirini». Ωστόσο, τα δύο παραπάνω σύνολα είναι ξένα, αφού κατασκευάζονται με τέτοιο τρόπο, ώστε η τομή τους να είναι το κενό σύνολο. Έτσι, το σύνολο ελέγχου αποτελείται από διανύσματα εισόδου, καθώς και από αντίστοιχα επιθυμητά διανύσματα εξόδου, τα οποία το εκάστοτε νευρωνικό δίκτυο επεξεργάζεται για πρώτη φορά κατά την αξιολόγησή του. Ως εκ τούτου, ο υπολογισμός των επιλεγμένων μετρικών σφάλματος για το σύνολο ελέγχου συνιστά αξιολόγηση της συμπεριφοράς του εκπαιδευμένου μοντέλου για νέα, άγνωστα δεδομένα, ενώ η σύγκριση των συγκεκριμένων τιμών για διαφορετικά νευρωνικά δίκτυα μπορεί να χρησιμοποιηθεί για την εύρεση της βέλτιστης διαμόρφωσης όσον αφορά τις υπερπαραμέτρους του δικτύου του μοντέλου MLP.

Η επιλογή του καταλληλότερου feedforward νευρωνικού δικτύου μπορεί, επίσης, να υλοποιηθεί χρησιμοποιώντας ένα σύνολο επικύρωσης (validation set). Αρχικά, το σύνολο των διαθέσιμων ιστορικών δεδομένων διαχωρίζεται σε δύο ανεξάρτητα σύνολα: ένα σύνολο δεδομένων που χρησιμοποιείται κατά τη διαδικασία της μάθησης και το σύνολο ελέγχου. Στη συνέχεια, το σύνολο μάθησης (learning set) διαχωρίζεται εκ νέου σε δύο ανεξάρτητα σύνολα: το σύνολο εκπαίδευσης και το σύνολο επικύρωσης. Κατά τη διαδικασία της μάθησης, το νευρωνικό δίκτυο εκπαιδύεται κάνοντας χρήση των δεδομένων του συνόλου εκπαίδευσης, ενώ, παράλληλα, αξιολογείται η συμπεριφορά του για τα δεδομένα του συνόλου επικύρωσης. Δεδομένου ότι το σύνολο επικύρωσης είναι διαφορετικό από το σύνολο εκπαίδευσης, οι τιμές των μετρικών σφάλματος που υπολογίζονται για το σύνολο επικύρωσης αποτελούν το κριτήριο με βάση το οποίο πραγματοποιείται η επιλογή της βέλτιστης διαμόρφωσης ανάμεσα στα εξεταζόμενα νευρωνικά δίκτυα.

Ωστόσο, η επιλογή της βέλτιστης διαμόρφωσης αξιολογώντας τα εξεταζόμενα feedforward νευρωνικά δίκτυα βάσει του συνόλου επικύρωσης μπορεί να οδηγήσει στην επιλογή ενός μοντέλου το οποίο παρουσιάζει υπερπροσαρμογή στα δεδομένα του συγκεκριμένου συνόλου. Επομένως, και σε αυτήν την περίπτωση είναι απαραίτητη η αξιολόγηση της ικανότητας του επιλεγμένου μοντέλου να ανταποκριθεί ικανοποιητικά σε άγνωστα σε αυτό δεδομένα. Για τον σκοπό αυτό χρησιμοποιείται το σύνολο ελέγχου, το οποίο είναι διαφορετικό τόσο από το σύνολο εκπαίδευσης όσο και από το σύνολο επικύρωσης, για το οποίο εκτιμάται η απόδοση γενίκευσης του μοντέλου που επιλέχθηκε [3].

Συνοψίζοντας, η βάση γνώσης που έχει δημιουργηθεί, δηλαδή το σύνολο των διαθέσιμων ιστορικών δεδομένων για το φωτοβολταϊκό πάρκο «Περδικούλα» ή «Lampirini», διαιρείται είτε σε σύνολα εκπαίδευσης και ελέγχου είτε σε σύνολα εκπαίδευσης, επικύρωσης και ελέγχου. Σε κάθε περίπτωση, η επιλογή του μεγέθους των παραπάνω συνόλων, η οποία πραγματοποιείται από τον χρήστη πριν από την εκπαίδευση του μοντέλου, είναι ιδιαίτερα σημαντική όσον αφορά τη συμπεριφορά του νευρωνικού δικτύου [50], ενώ μπορεί επίσης να καθοριστεί μέσα από μια διαδικασία βελτιστοποίησης, αντίστοιχα με τις υπερπαραμέτρους σχεδίασης και αλγορίθμου βελτιστοποίησης. Στην παρούσα διπλωματική εργασία, η αναζήτηση των βέλτιστων υπερπαραμέτρων του μοντέλου MLP πραγματοποιείται με βάση την αξιολόγηση της συμπεριφοράς του για το σύνολο επικύρωσης.

5.1.5 Διαδικασία βελτιστοποίησης των υπερπαραμέτρων

Η επιλογή των υπερπαραμέτρων ενός τεχνητού νευρωνικού δικτύου είναι μια ιδιαίτερα σύνθετη και δύσκολη διαδικασία. Συγκεκριμένα, η επιλογή τους συνιστά τόσο ένα πρόβλημα βελτιστοποίησης, καθώς αναζητούνται διαμορφώσεις υπερπαραμέτρων που ελαχιστοποιούν το σφάλμα επικύρωσης (validation error), όσο και ένα πρόβλημα γενίκευσης, αφού η βελτιστοποίηση της απόδοσης του μοντέλου όσον αφορά το σύνολο επικύρωσης δεν μπορεί να εγγυηθεί ότι το μοντέλο θα αποκτήσει την ικανότητα της γενίκευσης [21]. Παράλληλα, η σχέση ανάμεσα στο σφάλμα επικύρωσης, το οποίο αποτελεί το κριτήριο που εφαρμόζεται κατά τη διαδικασία επιλογής, και τις (αριθμητικές) υπερπαραμέτρους του δικτύου μπορεί να αποδειχθεί ιδιαίτερα περίπλοκη. Έτσι, η διαδικασία βελτιστοποίησης μιας υπερπαραμέτρου απαιτεί, εν γένει, τη δοκιμή πολλών διαφορετικών τιμών.

Η διαδικασία βελτιστοποίησης των υπερπαραμέτρων ενός μοντέλου μηχανικής μάθησης αποτελείται από τέσσερις βασικές συνιστώσες [22]:

1. έναν εκτιμητή (estimator) και την αντίστοιχη αντικειμενική συνάρτηση,
2. έναν χώρο αναζήτησης (ή χώρο διαμόρφωσης),
3. μια ευριστική μέθοδο ή μια μέθοδο βελτιστοποίησης και
4. μια συνάρτηση αξιολόγησης.

Ο εκτιμητής είναι το αντικείμενο που προσαρμόζεται στα διαθέσιμα δεδομένα, ώστε τελικά να επιτελέσει τη λειτουργία για την οποία σχεδιάστηκε το αντίστοιχο μοντέλο. Στο πλαίσιο του μοντέλου MLP, ο εκτιμητής είναι ένα νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης, το οποίο κατασκευάζεται με σκοπό τη βραχυπρόθεσμη πρόβλεψη της ισχύος εξόδου των φωτοβολταϊκών πάρκων «Περδικούλα» και «Lampirini».

Ο χώρος διαμόρφωσης (configuration space), δηλαδή ο χώρος στον οποίο αναζητείται ο βέλτιστος συνδυασμός υπερπαραμέτρων, περιλαμβάνει τιμές που μπορούν να λάβουν οι διάφορες υπερπαραμέτροι του μοντέλου. Οι τιμές αυτές μπορεί να είναι συνεχείς (ρυθμός μάθησης, συντελεστής ορμής), διακριτές (αριθμός των κρυφών νευρώνων, mini-batch size), κατηγορήματα (επιλογή των συναρτήσεων ενεργοποίησης και του αλγορίθμου βελτιστοποίησης) ή και δυαδικές, για παράδειγμα εάν θα πραγματοποιηθεί κανονικοποίηση των δεδομένων ή όχι. Το γεγονός ότι οι υπερπαραμέτροι των μοντέλων μηχανικής μάθησης, στα οποία ανήκει και το μοντέλο MLP, συνήθως λαμβάνουν τιμές που προέρχονται από διαφορετικά πεδία ορισμού εμπλουτίζει τη δομή του χώρου διαμόρφωσης, αυξάνοντας έτσι τη δυσκολία της διαδικασίας βελτιστοποίησης [51].


Στην παρούσα διπλωματική εργασία, η αναζήτηση του βέλτιστου συνδυασμού υπερπαραμέτρων για το μοντέλο MLP επιχειρείται κυρίως μέσω της μεθόδου «Δοκιμή και Σφάλμα» («Trial and Error»). Η συγκεκριμένη μέθοδος αποτελεί μια ευριστική τεχνική η οποία εφαρμόζεται εξ ολοκλήρου χειροκίνητα και είναι ιδιαίτερα διαδεδομένη, εξαιτίας και της απλότητάς της. Κατά την εφαρμογή της μεθόδου «Trial and Error», πραγματοποιούνται δοκιμές για πληθώρα τιμών κάθε υπερπαραμέτρου του μοντέλου, με τη διαδικασία να επαναλαμβάνεται μέχρι την επίτευξη ικανοποιητικών αποτελεσμάτων ή την εξάντληση του διαθέσιμου χρόνου [22]. Για κάθε συνδυασμό υπερπαραμέτρων που δοκιμάζεται, το feedforward νευρωνικό δίκτυο εκπαιδεύεται εκ νέου, εφαρμόζοντας την καινούρια

διαμόρφωση, ενώ υπολογίζονται τόσο το σφάλμα επικύρωσης όσο και το σφάλμα για το σύνολο ελέγχου που έχει επιλεγεί.

Η μέθοδος αναζήτησης πλέγματος (Grid Search) είναι μια ακόμα πολύ διαδεδομένη μέθοδος βελτιστοποίησης των υπερπαραμέτρων ενός μοντέλου μηχανικής μάθησης. Η μέθοδος Grid Search πραγματοποιεί μια εξαντλητική αναζήτηση στον χώρο διαμόρφωσης, ο οποίος καθορίζεται από τον χρήστη και περιλαμβάνει σύνολα τιμών για κάθε εξεταζόμενη υπερπαραμέτρο. Συγκεκριμένα, για έναν δεδομένο χώρο αναζήτησης, η μέθοδος αναζήτησης πλέγματος αξιολογεί όλους τους δυνατούς συνδυασμούς υπερπαραμέτρων, οι οποίοι προκύπτουν από το Καρτεσιανό γινόμενο των συνόλων που έχει προκαθορίσει ο χρήστης [22]. Το πλεονέκτημα αυτής της μεθόδου έγκειται στο γεγονός ότι μπορεί να παραλληλιστεί πλήρως, αλλά και στην ευκολία με την οποία υλοποιείται. Ωστόσο, δεν είναι αποδοτική για χώρους αναζήτησης που περιλαμβάνουν μεγάλο αριθμό υπερπαραμέτρων, αφού το Καρτεσιανό γινόμενο που αξιολογείται περιέχει αριθμό στοιχείων που αυξάνεται εκθετικά με τον αριθμό των υπερπαραμέτρων [21]. Για να ξεπεραστεί αυτό το σημαντικό μειονέκτημα, μπορεί να χρησιμοποιηθεί η μέθοδος της τυχαίας αναζήτησης (Random Search).

Σε αντιδιαστολή με τη μέθοδο αναζήτησης πλέγματος, η μέθοδος Random Search δεν αξιολογεί την απόδοση του μοντέλου για όλους τους δυνατούς συνδυασμούς του χώρου διαμόρφωσης υπερπαραμέτρων. Αντίθετα, η συγκεκριμένη μέθοδος επιλέγει και αξιολογεί τυχαίους συνδυασμούς υπερπαραμέτρων, οι οποίοι προέρχονται από χώρο αναζήτησης παρόμοιο με αυτόν που χρησιμοποιήθηκε για την εφαρμογή της μεθόδου Grid Search. Συγκεκριμένα, η τιμή κάθε εξεταζόμενης υπερπαραμέτρου επιλέγεται δειγματοληπτικά από μία προκαθορισμένη κατανομή, με αποτέλεσμα να ελέγχονται συνδυασμοί υπερπαραμέτρων οι οποίοι έχουν επιλεγεί ανεξάρτητα. Η κατανομή που ακολουθείται μπορεί να είναι διαφορετική για κάθε υπερπαραμέτρο, ενώ κατά κανόνα χρησιμοποιείται η ομοιόμορφη κατανομή [21]. Η μέθοδος τυχαίας αναζήτησης διατηρεί τα πρακτικά πλεονεκτήματα που παρουσιάζει η μέθοδος αναζήτησης πλέγματος, ενώ, ταυτόχρονα, μπορεί να οδηγήσει στην εύρεση εξίσου αποδοτικών μοντέλων σε σημαντικά μικρότερο υπολογιστικό χρόνο, ειδικά για χώρους αναζήτησης πολλών διαστάσεων (high-dimensional search spaces) [52].

Η αξιολόγηση του εκάστοτε συνδυασμού υπερπαραμέτρων, ο οποίος προκύπτει από την εφαρμογή των τριών παραπάνω μεθόδων, ή και οποιασδήποτε άλλης μεθόδου βελτιστοποίησης, πραγματοποιείται μέσω του υπολογισμού της αντίστοιχης τιμής της συνάρτησης αξιολόγησης. Η αξιολόγηση του μοντέλου MLP της παρούσας διπλωματικής εργασίας αφορά τον υπολογισμό του μετρικού *MAPE* (εξίσωση (3.3)) για το σύνολο επικύρωσης. Παράλληλα, όσον αφορά τις μεθόδους Grid Search και Random Search, η αξιολόγηση του μοντέλου στα δεδομένα επικύρωσης υλοποιείται με χρήση της μεθόδου διασταυρούμενης επικύρωσης πολλαπλών τμημάτων (multifold cross-validation). Συγκεκριμένα [3], το σύνολο δεδομένων που χρησιμοποιείται κατά τη διαδικασία της μάθησης διαιρείται σε k υποσύνολα, με $k > 1$, και το μοντέλο εκπαιδεύεται σε όλα τα υποσύνολα εκτός από ένα, το οποίο παραλείπεται και ως εκ τούτου αποτελεί το σύνολο επικύρωσης για τη συγκεκριμένη δοκιμή. Η συγκεκριμένη διαδικασία επαναλαμβάνεται k φορές, ενώ σε κάθε δοκιμή χρησιμοποιείται ως σύνολο επικύρωσης ένα διαφορετικό, κάθε φορά, υποσύνολο, όπως φαίνεται στο Σχήμα 5.2 για $k = 3$. Η απόδοση του μοντέλου αξιολογείται υπολογίζοντας τη μέση τιμή του μετρικού σφάλματος για το σύνολο των δοκιμών που διενεργήθηκαν, δηλαδή για k διαφορετικά σύνολα επικύρωσης.



Σχήμα 5.2: Απεικόνιση της μεθόδου διασταυρούμενης επικύρωσης πολλαπλών τμημάτων για $k = 3$: σε κάθε δοκιμή, το υποσύνολο που σκιάζεται με μπλε χρώμα αποτελεί το σύνολο επικύρωσης, με βάση το οποίο αξιολογείται η απόδοση του μοντέλου

5.1.6 Επαλήθευση της λειτουργίας του μοντέλου

Τα μοντέλα πρόβλεψης της παρούσας διπλωματικής εργασίας υλοποιούνται και προσομοιώνονται με χρήση κατάλληλου λογισμικού σε ηλεκτρονικό υπολογιστή. Για τον σκοπό αυτό, τα νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης του μοντέλου MLP κατασκευάζονται, εκπαιδεύονται και αξιολογούνται μέσω κώδικα που αναπτύσσεται στη γλώσσα προγραμματισμού Python, και συγκεκριμένα στην έκδοση Python 3, και ο οποίος γράφεται σε αρχεία notebook. Τα αρχεία notebook – τα οποία έχουν τη δυνατότητα να περιέχουν τόσο κώδικα όσο και εμπλουτισμένα στοιχεία κειμένου, για παράδειγμα παραγράφους κειμένου, μαθηματικές εξισώσεις και σχήματα – δημιουργούνται στο περιβάλλον Jupyter Notebook [53], το οποίο είναι ένα διαδικτυακό, διαδραστικό υπολογιστικό περιβάλλον που υποστηρίζει τη γλώσσα προγραμματισμού Python και πολλές χρήσιμες βιβλιοθήκες λογισμικού.

Ως επαλήθευση της ορθής λειτουργίας του μοντέλου MLP αναφέρεται η διενέργεια ελέγχου, ώστε να διαπιστωθεί εάν η προσομοίωση του μοντέλου, η οποία πραγματοποιείται σε Python στο πλαίσιο του περιβάλλοντος Jupyter Notebook, υπολογίζει σωστά τις τιμές των επιλεγμένων μετρικών σφάλματος, αναφορικά με το πρόβλημα της βραχυπρόθεσμης πρόβλεψης φωτοβολταϊκής παραγωγής για τα φωτοβολταϊκά πάρκα «Περδικούλα» και «Lampripi». Ο παραπάνω έλεγχος υλοποιείται με τη βοήθεια του λογισμικού υπολογιστικών φύλλων Microsoft Excel. Συγκεκριμένα, μετά το πέρας της εκπαίδευσης ενός ενδεικτικού νευρωνικού δικτύου του μοντέλου MLP, εξάγονται σε φύλλα εργασίας τόσο οι ρυθμισμένες τιμές των συναπτικών βαρών και των πολώσεων του δικτύου όσο και τα δεδομένα που δεσμεύθηκαν για την εκπαίδευσή του, τα οποία συμπεριλαμβάνουν ένα δεδομένο σύνολο επικύρωσης. Έτσι, μπορεί να πραγματοποιηθεί ο υπολογισμός των επιλεγμένων μετρικών σφάλματος για τα συγκεκριμένα δεδομένα, αξιοποιώντας τις εξισώσεις που χαρακτηρίζουν το νευρωνικό δίκτυο και τους νευρώνες του, και πιο συγκεκριμένα την εξίσωση (2.2), η οποία υπολογίζει την έξοδο κάθε νευρώνα ανάλογα με τη συνάρτηση ενεργοποίησής του, και την εξίσωση (3.3) μέσω της οποίας υπολογίζεται το βασικό μετρικό σφάλματος (*MAPE*).

Αρχικά, για κάθε δiάνυσμα εισόδου που έχει εξαχθεί, υπολογίζονται οι έξοδοι όλων των νευρώνων του δικτύου μέσω κατάλληλα διαμορφωμένων φύλλων εργασίας, ξεκινώντας από το στρώμα εισόδου και καταλήγοντας στο στρώμα εξόδου. Στη συνέχεια, υπολογίζεται το Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (*MAPE*) μεταξύ των τιμών που υπολογίστηκαν για τους νευρώνες εξόδου και του επιθυμητού διανύσματος εξόδου που αντιστοιχεί στο δiάνυσμα εισόδου που εξετάζεται. Η διαδικασία αυτή επαναλαμβάνεται για το σύνολο των διανυσμάτων εισόδου, τα οποία διαχωρίζονται σε δεδομένα εκπαίδευσης και επικύρωσης, οπότε υπολογίζονται και τα αντίστοιχα συνολικά *MAPE*, τα οποία αφορούν τα σύνολα εκπαίδευσης και επικύρωσης. Τα συνολικά αυτά *MAPE*, ή Mean *MAPE*, προκύπτουν ως μέσοι όροι των μεμονωμένων *MAPE* που υπολογίστηκαν για κάθε δiάνυσμα εισόδου του αντίστοιχου συνόλου. Οι τιμές τους συγκρίνονται με τις αντίστοιχες τιμές που υπολογίστηκαν κατά την προσομοίωση του μοντέλου, με τις τιμές που συγκρίνονται να πρέπει να είναι ίσες ή σχεδόν ίσες, βάσει και της ακρίβειας του χρησιμοποιούμενου ηλεκτρονικού υπολογιστή.

Η επαλήθευση της λειτουργίας του μοντέλου περιλαμβάνει, επίσης, τον έλεγχο των μετρικών σφάλματος που υπολογίζονται για το σύνολο ελέγχου. Για τον σκοπό αυτό, χρησιμοποιούνται οι τιμές των προσαρμοσμένων ελεύθερων παραμέτρων του δικτύου, οι οποίες έχουν ήδη εξαχθεί, καθώς και τα δεδομένα του συνόλου ελέγχου, ενώ η διαδικασία που ακολουθείται είναι ίδια με αυτή που περιγράφηκε για τα δεδομένα εκπαίδευσης και επικύρωσης. Τέλος, αξίζει να σημειωθεί ότι κατά την επαλήθευση του μοντέλου μπορούν να χρησιμοποιηθούν και άλλα μετρικά σφάλματος, όπως το Μέσο Τετραγωνικό Σφάλμα (Mean Square Error – *MSE*), το οποίο δίνεται από την εξίσωση (5.7):

$$MSE = \frac{1}{N} \cdot \sum_{i=1}^N (\hat{P}_i - P_i)^2 \quad (5.7)$$

όπου N είναι το πλήθος των παραγόμενων σημειακών προβλέψεων για τον χρονικό ορίζοντα της πρόβλεψης, P_i είναι η μετρούμενη (επιθυμητή) φωτοβολταϊκή ισχύς εξόδου στο i -οστό χρονικό βήμα και \hat{P}_i είναι η αντίστοιχη φωτοβολταϊκή παραγωγή που εκτιμάται από το μοντέλο πρόβλεψης. Στο πλαίσιο της παρούσας διπλωματικής εργασίας, η τιμή της μεταβλητής N είναι σε κάθε περίπτωση ίση με 15, καθώς για κάθε εξεταζόμενο ορίζοντα πρόβλεψης παράγονται 15 σημειακές προβλέψεις.

5.2 ΠΡΟΒΛΕΨΗ ΦΩΤΟΒΟΛΤΑΪΚΗΣ ΠΑΡΑΓΩΓΗΣ ΜΕ ΧΡΗΣΗ EXTREME LEARNING MACHINES

5.2.1 Εισαγωγή στις Μηχανές Ακραίας Μάθησης

Το δεύτερο μοντέλο που αναπτύσσεται αποσκοπώντας στη βραχυπρόθεσμη πρόβλεψη της φωτοβολταϊκής παραγωγής των πάρκων «Περδικούλα» και «Lamprini» βασίζεται, επίσης, στα νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης. Ωστόσο, σε αντίθεση με τα συμβατικά feedforward νευρωνικά δίκτυα τα οποία εκπαιδεύονται κατά κύριο λόγο με τον αλγόριθμο backpropagation, η διαδικασία μάθησης των νευρωνικών δικτύων του δεύτερου

μοντέλου πρόβλεψης υλοποιείται με χρήση του αλγορίθμου μάθησης Extreme Learning Machine (ELM).

Ο αλγόριθμος ELM προτάθηκε από τους G.-B. Huang, Q.-Y. Zhu και C.-K. Siew [54], [55] ως μία νέα μέθοδος εκπαίδευσης για feedforward νευρωνικά δίκτυα τα οποία διαθέτουν ένα κρυφό στρώμα (single-hidden layer feedforward neural networks – SLFNs). Η μέθοδος αυτή επιλέγει τυχαία τα συναπτικά βάρη και τις πολώσεις των κρυφών νευρώνων και στη συνέχεια υπολογίζει με αναλυτικό τρόπο τις τιμές των ελεύθερων παραμέτρων (συναπτικά βάρη) για τους νευρώνες εξόδου του δικτύου. Επομένως, η διαφορά των νευρωνικών δικτύων του δεύτερου μοντέλου (μοντέλο ELM) από τα συμβατικά feedforward νευρωνικά δίκτυα (μοντέλο MLP) έγκειται στο γεγονός ότι τα συναπτικά βάρη και οι πολώσεις των νευρώνων τους δεν προσαρμόζονται μέσω επαναληπτικής διαδικασίας.

Η ανάπτυξη του αλγορίθμου Extreme Learning Machine πραγματοποιήθηκε με σκοπό την αύξηση της ταχύτητας εκπαίδευσης των SLFNs, καθώς η διαδικασία με την οποία μαθαίνει ένα συμβατικό feedforward νευρωνικό δίκτυο είναι μια, εν γένει, αργή διαδικασία. Η χαμηλή αυτή ταχύτητα εκπαίδευσης οφείλεται σε δύο βασικούς παράγοντες [55]:

1. Τα συμβατικά νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης εκπαιδεύονται, κατά κύριο λόγο, με χρήση αργών αλγορίθμων μάθησης οι οποίοι βασίζονται τη λειτουργία τους στον υπολογισμό της κλίσης της αντικειμενικής συνάρτησης εκπαίδευσης, όπως ο αλγόριθμος της προς τα πίσω διάδοσης του σφάλματος.
2. Οι υπερπαραμέτροι των συγκεκριμένων νευρωνικών δικτύων ρυθμίζονται επαναληπτικά χρησιμοποιώντας τους παραπάνω αλγορίθμους μάθησης. Τα συγκεκριμένα νευρωνικά δίκτυα διαθέτουν πληθώρα υπερπαραμέτρων, ενώ κάθε φορά που ελέγχεται η τιμή μιας υπερπαραμέτρου η διαδικασία της εκπαίδευσης και η αξιολόγηση του αντίστοιχου μοντέλου επαναλαμβάνονται από την αρχή [22].

Αντίθετα, τα νευρωνικά δίκτυα που εφαρμόζουν τον αλγόριθμο ELM ολοκληρώνουν την εκπαίδευσή τους με άκρως υψηλότερες ταχύτητες, ενώ, θεωρητικά, έχουν τη δυνατότητα να προχωρήσουν σε εξίσου καλή γενίκευση με τα αντίστοιχα συμβατικά.

5.2.2 Κατασκευή του μοντέλου

Το δεύτερο μοντέλο πρόβλεψης που αναπτύσσεται στο πλαίσιο της παρούσας διπλωματικής εργασίας είναι, όπως και το πρώτο μοντέλο, ένα feedforward νευρωνικό δίκτυο, που σχεδιάζεται μεν βάσει της δομής του multilayer perceptron (Σχήμα 5.1), αλλά εκπαιδεύεται με τον αλγόριθμο ELM. Τα νευρωνικά δίκτυα του μοντέλου ELM διαθέτουν μόνο ένα κρυφό στρώμα, ενώ ως συνάρτηση ενεργοποίησης αυτού του κρυφού στρώματος μπορεί να επιλεγεί οποιαδήποτε απείρως διαφορίσιμη (ομαλή) συνάρτηση $f: \mathbb{R} \rightarrow \mathbb{R}$ [55]. Παραδείγματα τέτοιων συναρτήσεων είναι η σιγμοειδής συνάρτηση, η οποία ορίζεται στην εξίσωση (2.3), η συνάρτηση υπερβολικής εφαπτομένης, η οποία ορίζεται στην εξίσωση (2.4), η εκθετική συνάρτηση και η συνάρτηση ακτινικής βάσης (Radial Basis Function – RBF).

Όσον αφορά το στρώμα εισόδου, ο αριθμός των νευρώνων επιλέγεται ξανά βάσει των διαθέσιμων ιστορικών δεδομένων, τα οποία αντλούνται από τα φωτοβολταϊκά πάρκα «Περδικούλα» και «Lampirini». Η επιλογή των καταλληλότερων παραμέτρων εισόδου πραγματοποιείται εξετάζοντας τη συσχέτισή τους με την παραγόμενη ισχύ στην έξοδο του πάρκου που μελετάται και, κυρίως, υπολογίζοντας τα επιλεγμένα μετρικά σφάλματος για τα σύνολα επικύρωσης και ελέγχου του εκάστοτε νευρωνικού δικτύου, δηλαδή κάθε δικτύου που προσομοιώνεται για διαφορετικό συνδυασμό παραμέτρων εισόδου.

Εφόσον τα νευρωνικά δίκτυα του μοντέλου ELM κατασκευάζονται με σκοπό να επιτελέσουν την ίδια λειτουργία με τα δίκτυα του μοντέλου MLP, ο αριθμός των νευρώνων που συγκροτούν το στρώμα εξόδου τους είναι σε κάθε περίπτωση σταθερός και ίσος με 15. Επομένως, το στρώμα εξόδου συγκροτείται από 15 νευρώνες, ώστε να παράγονται ταυτόχρονα οι 15 σημειακές προβλέψεις που ζητούνται για τον εκάστοτε ορίζοντα πρόβλεψης, ενώ ως συνάρτηση ενεργοποίησης των νευρώνων εξόδου επιλέγεται η γραμμική, η οποία ορίζεται στην ακόλουθη εξίσωση:

$$f(z) = z \quad (5.8)$$

Πρέπει να σημειωθεί ότι οι νευρώνες εξόδου των συγκεκριμένων δικτύων δεν περιλαμβάνουν τιμές πόλωσης, με αποτέλεσμα να απαιτείται μονάχα ο υπολογισμός των συναπτικών βαρών εξόδου, δηλαδή των βαρών που αφορούν τις συνδέσεις ανάμεσα στους νευρώνες του κρυφού στρώματος και του στρώματος εξόδου.

5.2.3 Διαδικασία της εκπαίδευσης

Η εκπαίδευση ενός νευρωνικού δικτύου με τον αλγόριθμο Extreme Learning Machine έγκειται στον καθορισμό των συναπτικών βαρών των νευρώνων εξόδου του. Ο καθορισμός τους υλοποιείται με τρόπο αναλυτικό, μέσω του υπολογισμού του γενικευμένου αντίστροφου πίνακα (generalized inverse matrix) για τον πίνακα που περιλαμβάνει τις εξόδους του κρυφού στρώματος (hidden layer output matrix) [55].

Για ένα δεδομένο σύνολο εκπαίδευσης $S = \{(\mathbf{x}_i, \mathbf{t}_i) \mid \mathbf{x}_i \in \mathbf{R}^n, \mathbf{t}_i \in \mathbf{R}^{15}, i = 1, \dots, N\}$, όπου $\mathbf{x}_i = [x_{i,1}, x_{i,2}, \dots, x_{i,n}]^T$ είναι το i -οστό διάνυσμα εισόδου που αποτελείται από n παραμέτρους, $\mathbf{t}_i = [t_{i,1}, t_{i,2}, \dots, t_{i,15}]^T$ είναι το αντίστοιχο (i -οστό) διάνυσμα 15 επιθυμητών εξόδων και N είναι το πλήθος των ζευγών διανυσμάτων εισόδου-εξόδου του συνόλου εκπαίδευσης S , κάθε feedforward νευρωνικό δίκτυο του αναπτυσσόμενου μοντέλου ELM μοντελοποιείται ως εξής:

$$\sum_{j=1}^{N_h} \beta_j \cdot f(\mathbf{w}_j \cdot \mathbf{x}_i + b_j) = \mathbf{o}_i \quad (5.9)$$

όπου $\mathbf{w}_j = [w_{j,1}, w_{j,2}, \dots, w_{j,n}]^T$ είναι το διάνυσμα των βαρών που χαρακτηρίζουν τις συνάψεις μεταξύ των n νευρώνων εισόδου και του j -οστού κρυφού νευρώνα, b_j είναι η πόλωσή του, f είναι η συνάρτηση ενεργοποίησης των νευρώνων του κρυφού στρώματος,

$\boldsymbol{\beta}_j = [\beta_{j,1}, \beta_{j,2}, \dots, \beta_{j,15}]^T$ είναι το διάνυσμα των συναπτικών βαρών για τις συνδέσεις μεταξύ του j -οστού κρυφού νευρώνα και των 15 νευρώνων εξόδου και N_h είναι το πλήθος των κρυφών νευρώνων του δικτύου. Δεδομένου ότι ως συνάρτηση ενεργοποίησης των νευρώνων εξόδου έχει επιλεγθεί η γραμμική (εξίσωση (5.8)), το διάνυσμα $\mathbf{o}_i = [o_{i,1}, o_{i,2}, \dots, o_{i,15}]^T$ συνιστά την έξοδο που παράγει το νευρωνικό δίκτυο για το i -οστό διάνυσμα εισόδου.

Ένα αντίστοιχο συμβατικό SLFN μπορεί να προσεγγίσει τα N ζεύγη διανυσμάτων εισόδου-εξόδου με μηδενικό σφάλμα [55], δηλαδή υπάρχουν $\boldsymbol{\beta}_j$, \mathbf{w}_j και b_j τα οποία ικανοποιούν την ακόλουθη σχέση:

$$\sum_{j=1}^{N_h} \boldsymbol{\beta}_j \cdot f(\mathbf{w}_j \cdot \mathbf{x}_i + b_j) = \mathbf{t}_i, \quad i=1, \dots, N \quad (5.10)$$

Οι N εξισώσεις που προκύπτουν μπορούν, επίσης, να γραφούν με συμπαγή τρόπο ως εξής:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (5.11)$$

όπου:

$$\mathbf{H} = \begin{bmatrix} f(\mathbf{w}_1 \cdot \mathbf{x}_1 + b_1) & \dots & f(\mathbf{w}_{N_h} \cdot \mathbf{x}_1 + b_{N_h}) \\ \vdots & \vdots & \vdots \\ f(\mathbf{w}_1 \cdot \mathbf{x}_N + b_1) & \dots & f(\mathbf{w}_{N_h} \cdot \mathbf{x}_N + b_{N_h}) \end{bmatrix}_{N \times N_h} \quad (5.12)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \boldsymbol{\beta}_1^T \\ \vdots \\ \boldsymbol{\beta}_{N_h}^T \end{bmatrix}_{N_h \times 15} \quad (5.13)$$

$$\mathbf{T} = \begin{bmatrix} \mathbf{t}_1^T \\ \vdots \\ \mathbf{t}_N^T \end{bmatrix}_{N \times 15} \quad (5.14)$$

Ο πίνακας \mathbf{H} που ορίζεται από την εξίσωση (5.12) αποτελεί τον πίνακα εξόδου του κρυφού στρώματος του νευρωνικού δικτύου. Η j -οστή στήλη του πίνακα \mathbf{H} αντιστοιχεί στην έξοδο του j -οστού κρυφού νευρώνα όσον αφορά τα διανύσματα εισόδου $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$.

Η συμβατική εκπαίδευση ενός SLFN μπορεί να πραγματοποιηθεί αναζητώντας συγκεκριμένες τιμές των \mathbf{w}_j , b_j και $\boldsymbol{\beta}$, για j από ένα (1) έως N_h , οι οποίες ελαχιστοποιούν την τιμή της νόρμας $\|\mathbf{H}(\mathbf{w}_j, b_j)\boldsymbol{\beta} - \mathbf{T}\|$. Επειδή ο πίνακας \mathbf{H} είναι άγνωστος, η διαδικασία ελαχιστοποίησης της συγκεκριμένης νόρμας υλοποιείται με χρήση αλγορίθμων μάθησης που βασίζονται στην κατάβαση κλίσης, οι οποίοι προσαρμόζουν επαναληπτικά τις ελεύθερες παραμέτρους του δικτύου [54].

Εφόσον η συνάρτηση ενεργοποίησης του κρυφού στρώματος ενός SLFN είναι απείρως διαφορίσιμη, τα συναπτικά βάρη και οι πολώσεις των κρυφών νευρώνων του μπορούν να επιλεγθούν τυχαία, χωρίς να απαιτείται μετέπειτα προσαρμογή τους. Αφού εκχωρηθούν τυχαίες τιμές στις παραπάνω παραμέτρους του δικτύου, το νευρωνικό δίκτυο μπορεί, πλέον, να θεωρηθεί ως ένα γραμμικό σύστημα, το οποίο εκπαιδεύεται με τον αλγόριθμο ELM. Συγκεκριμένα, οι τυχαίες τιμές που επιλέχθηκαν για τα συναπτικά βάρη και τις πολώσεις των κρυφών νευρώνων στην αρχή της διαδικασίας της εκπαίδευσης παραμένουν αμετάβλητες σε όλη τη διάρκειά της, με αποτέλεσμα να παραμένει αμετάβλητος και ο πίνακας \mathbf{H} . Έτσι, η εκπαίδευση ενός νευρωνικού δικτύου του μοντέλου MLP – η οποία αφορά την ελαχιστοποίηση της ίδιας νόρμας $\|\mathbf{H}(\mathbf{w}_j, b_j)\boldsymbol{\beta} - \mathbf{T}\|$, αλλά για σταθερές τιμές των \mathbf{w}_j και b_j – ισοδυναμεί με την εύρεση μιας λύσης ελαχίστων τετραγώνων (least-squares solution – $\hat{\boldsymbol{\beta}}$) του γραμμικού, πλέον, συστήματος της εξίσωσης (5.11) [55]. Η λύση ελαχίστων τετραγώνων με τη μικρότερη δυνατή νόρμα όσον αφορά το συγκεκριμένο γραμμικό σύστημα είναι η ακόλουθη [56]:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^\dagger \mathbf{T} \quad (5.15)$$

όπου \mathbf{H}^\dagger είναι ο γενικευμένος αντίστροφος πίνακας Moore-Penrose του πίνακα \mathbf{H} .

Επομένως, ο αλγόριθμος μάθησης Extreme Learning Machine, ο οποίος χρησιμοποιείται και στην παρούσα διπλωματική εργασία για την εκπαίδευση των νευρωνικών δικτύων του μοντέλου ELM, συνοψίζεται ως εξής: Αρχικά, καθορίζεται ένα σύνολο εκπαίδευσης \mathcal{S} , μια συνάρτηση ενεργοποίησης f για τους κρυφούς νευρώνες του δικτύου καθώς και ο αριθμός τους N_h , ενώ το πρώτο βήμα του αλγορίθμου αφορά την εκχώρηση αυθαίρετων τιμών στα συναπτικά βάρη και τις πολώσεις των κρυφών νευρώνων. Οι αυθαίρετες αυτές τιμές παράγονται τυχαία με βάση κάποια συνεχή κατανομή πιθανοτήτων [55] και παραμένουν αμετάβλητες σε όλη τη διάρκεια της εκπαίδευσης του νευρωνικού δικτύου. Στη συνέχεια, υπολογίζεται ο πίνακας \mathbf{H} , ο οποίος αποτελεί τον πίνακα εξόδου του κρυφού στρώματος και ορίζεται από την εξίσωση (5.12). Τέλος, υπολογίζονται τα συναπτικά βάρη των νευρώνων εξόδου μέσω της εξίσωσης (5.15), όπου οι πίνακες $\boldsymbol{\beta}$ και \mathbf{T} ορίζονται από τις εξισώσεις (5.13) και (5.14), αντίστοιχα.

Τα νευρωνικά δίκτυα που εκπαιδεύονται με χρήση του αλγορίθμου ELM παρουσιάζουν αρκετά ενδιαφέροντα χαρακτηριστικά, τα οποία τα ξεχωρίζουν από τα αντίστοιχα συμβατικά feedforward νευρωνικά δίκτυα. Το σημαντικότερο, ίσως, χαρακτηριστικό τους είναι η εξαιρετικά υψηλή ταχύτητα που διακρίνει τη διαδικασία της μάθησης. Η ταχύτητα μάθησης ενός SLFN που εκπαιδεύεται με τον αλγόριθμο ELM μπορεί να είναι χιλιάδες φορές υψηλότερη συγκριτικά με ένα SLFN που χρησιμοποιεί τον αλγόριθμο backpropagation [54]. Παράλληλα, το γεγονός ότι ο αλγόριθμος ELM επιδιώκει να φτάσει όχι μόνο στο ελάχιστο σφάλμα εκπαίδευσης, αλλά και στην ελάχιστη νόρμα συναπτικών βαρών, μπορεί να οδηγήσει το προτεινόμενο μοντέλο ELM σε καλύτερα αποτελέσματα, όσον αφορά την ικανότητα της γενίκευσης για νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης.

Ένα επιπρόσθετο πλεονέκτημα του αλγορίθμου ELM έγκειται στην απλότητά του, η οποία αφορά τόσο τον τρόπο με τον οποίο παρουσιάζεται και περιγράφεται όσο και τον τρόπο με τον οποίο φτάνει στη βέλτιστη δυνατή λύση. Ο αλγόριθμος ELM φτάνει στις ζητούμενες λύσεις με τρόπο ξεκάθαρο, χωρίς να αντιμετωπίζει προβλήματα αντίστοιχα με

εκείνα που παρατηρούνται κατά την εκπαίδευση των συμβατικών feedforward νευρωνικών δικτύων, όπως η ύπαρξη τοπικών ελαχίστων, η υπερπροσαρμογή και η ευαισθησία όσον αφορά την επιλογή του ρυθμού μάθησης. Επομένως, ο αλγόριθμος ELM δεν απαιτεί τη χρησιμοποίηση επικουρικών μεθόδων, όπως η μέθοδος early stopping, για την αποφυγή των παραπάνω προβλημάτων.

5.2.4 Αξιολόγηση του μοντέλου

Αφού ολοκληρωθεί η διαδικασία εκπαίδευσης ενός νευρωνικού δικτύου του μοντέλου ELM, τα συναπτικά βάρη που υπολογίστηκαν αναλυτικά για τους νευρώνες εξόδου του χρησιμοποιούνται, ώστε να παραχθούν προβλέψεις για δεδομένα εισόδου που είναι άγνωστα στο δίκτυο. Η αξιολόγηση του μοντέλου ELM αφορά την απόδοση του εκάστοτε νευρωνικού δικτύου για τα άγνωστα αυτά δεδομένα και πραγματοποιείται μέσω του υπολογισμού των κατάλληλων μετρικών σφάλματος.

Στο πλαίσιο της παρούσας διπλωματικής εργασίας, αναπτύσσονται δύο διαφορετικά μοντέλα πρόβλεψης (MLP, ELM) με σκοπό να συγκριθούν η απόδοσή τους καθώς και η βέλτιστη ακρίβεια πρόβλεψης που μπορεί να επιτύχει το κάθε μοντέλο για τους χρονικούς ορίζοντες πρόβλεψης που μελετήθηκαν. Επομένως, η αξιολόγηση των δύο αυτών διακριτών μοντέλων πραγματοποιείται με χρήση των ίδιων μετρικών σφάλματος. Έτσι, η αξιολόγηση των νευρωνικών δικτύων του μοντέλου ELM αφορά κυρίως τον υπολογισμό του *MAPE* για τα σύνολα επικύρωσης και ελέγχου που έχουν καθοριστεί. Ως εκ τούτου, για να καταστεί δυνατή η άμεση σύγκριση της συμπεριφοράς των νευρωνικών δικτύων του μοντέλου ELM με τα αντίστοιχα δίκτυα του μοντέλου MLP πρέπει, σε κάθε περίπτωση, να έχουν επιλεγεί παρεμφερή σύνολα επικύρωσης και ελέγχου.

Ταυτόχρονα, για κάθε νευρωνικό δίκτυο του μοντέλου ELM που εκπαιδεύεται και αξιολογείται, καταγράφεται, επίσης, ο χρόνος που απαιτήθηκε για να ολοκληρωθεί η διαδικασία της εκπαίδευσής του. Ο χρόνος αυτός συγκρίνεται με τον απαιτούμενο χρόνο εκπαίδευσης των αντίστοιχων νευρωνικών δικτύων του πρώτου μοντέλου πρόβλεψης, ώστε να επιβεβαιωθεί το σημαντικό συγκριτικό πλεονέκτημα που προσφέρει το μοντέλο ELM έναντι του μοντέλου MLP.

5.2.5 Βελτιστοποίηση του μοντέλου

Η προσπάθεια βελτιστοποίησης ενός νευρωνικού δικτύου του μοντέλου ELM συνιστά μια πιο εύκολη διαδικασία συγκριτικά με το μοντέλο MLP. Το γεγονός αυτό οφείλεται στον αριθμό των διαθέσιμων υπερπαραμέτρων που εξετάζονται με σκοπό την εύρεση της βέλτιστης διαμόρφωσης. Για ένα συμβατικό feedforward νευρωνικό δίκτυο (μοντέλο MLP), η εύρεση της βέλτιστης διαμόρφωσης απαιτεί την κατάλληλη ρύθμιση πληθώρας υπερπαραμέτρων, οι οποίες, ταυτόχρονα, ορίζονται σε διαφορετικά πεδία. Παράλληλα, υπάρχουν υπερπαραμέτροι οι οποίες χρησιμοποιούνται και ρυθμίζονται ανάλογα

με την τιμή που λαμβάνει κάποια άλλη υπερπαραμέτρος, με αποτέλεσμα να δημιουργούνται ακόμα πιο περίπλοκοι χώροι διαμόρφωσης.

Αντίθετα, ένα νευρωνικό δίκτυο που εκπαιδεύεται με τον αλγόριθμο Extreme Learning Machine διαθέτει πολύ μικρότερο αριθμό υπερπαραμέτρων. Συγκεκριμένα, για τα SLFNs της παρούσας διπλωματικής εργασίας διενεργούνται δοκιμές για τη βελτιστοποίηση δύο μόνο υπερπαραμέτρων: (i) του αριθμού των νευρώνων του στρώματος εισόδου και του κρυφού στρώματος και (ii) της συνάρτησης που επιλέγεται για την ενεργοποίηση των κρυφών νευρώνων. Το γεγονός ότι η βέλτιστη διαμόρφωση του δικτύου αναζητείται αποκλειστικά σε συνδυασμούς των δύο συγκεκριμένων υπερπαραμέτρων έχει ως αποτέλεσμα τη δημιουργία χώρων διαμόρφωσης οι οποίοι παρουσιάζουν σαφώς μικρότερη πολυπλοκότητα και σημαντικά χαμηλότερη διάσταση (dimensionality), διευκολύνοντας έτσι τη διαδικασία βελτιστοποίησης του δικτύου.

Αξίζει να σημειωθεί ότι η βελτιστοποίηση ενός μοντέλου Extreme Learning Machine μπορεί, επίσης, να πραγματοποιηθεί ρυθμίζοντας κατάλληλα τα συναπτικά βάρη και τις πολώσεις των νευρώνων του κρυφού στρώματος, ώστε να επιλεγούν οι τιμές των (w_j, b_j) για τις οποίες το μοντέλο παρουσιάζει τη βέλτιστη απόδοση [57]. Η ρύθμιση αυτή μπορεί να γίνει με τη χρήση διάφορων τεχνικών βελτιστοποίησης, όπως ο αλγόριθμος Βελτιστοποίησης Σμήνους Σωματιδίων (Particle Swarm Optimization – PSO), ο οποίος προτάθηκε από τους Kennedy και Eberhart [58]. Ωστόσο, η συγκεκριμένη μέθοδος βελτιστοποίησης δεν υλοποιείται στο πλαίσιο της παρούσας διπλωματικής εργασίας.

5.2.6 Επαλήθευση της λειτουργία του μοντέλου

Σε αντιστοιχία με το μοντέλο MLP, η ορθή λειτουργία του μοντέλου ELM μπορεί, επίσης, να επαληθευθεί με χρήση του λογισμικού Microsoft Excel καθώς και κάποιων πρόσθετων επεκτάσεών του [59]. Αρχικά, αναπτύσσεται κώδικας με σκοπό την εξαγωγή των δεδομένων που χρησιμοποιούνται για την εκπαίδευση ενός ενδεικτικού νευρωνικού δικτύου του μοντέλου ELM σε φύλλα εργασίας. Τα δεδομένα αυτά είναι τα διανύσματα εισόδου του συνόλου εκπαίδευσης καθώς και τα αντίστοιχα επιθυμητά διανύσματα εξόδου. Εξάγονται, επίσης, οι τυχαίες τιμές που εκχωρήθηκαν στα συναπτικά βάρη και τις πολώσεις των κρυφών νευρώνων του δικτύου.

Στη συνέχεια, υπολογίζονται ο πίνακας εξόδου του κρυφού στρώματος του ενδεικτικού νευρωνικού δικτύου (\mathbf{H}) καθώς και ο αντίστοιχος γενικευμένος αντίστροφος πίνακας Moore-Penrose (\mathbf{H}^\dagger). Έτσι, ο υπολογισμός των συναπτικών βαρών των νευρώνων εξόδου του δικτύου, ο οποίος συνιστά την ολοκλήρωση της εκπαίδευσής του, μπορεί να πραγματοποιηθεί εφαρμόζοντας την εξίσωση (5.15), δηλαδή υπολογίζοντας το γινόμενο του πίνακα \mathbf{H}^\dagger και του πίνακα που περιέχει τα επιθυμητά διανύσματα εξόδου (\mathbf{T}) που έχουν εξαχθεί από το υπολογιστικό περιβάλλον Jupyter Notebook.

Με τον υπολογισμό του πίνακα $\hat{\beta}$, μπορούν πλέον να υπολογιστούν οι έξοδοι του νευρωνικού δικτύου, όταν αυτό τροφοδοτείται με τα διανύσματα εισόδου του συνόλου εκπαίδευσης. Ο υπολογισμός αυτός πραγματοποιείται πολλαπλασιάζοντας τον αντίστοιχο πίνακα εξόδου του κρυφού στρώματος με τον πίνακα των συναπτικών βαρών εξόδου που

υπολογίστηκε. Τέλος, υπολογίζονται τα μετρικά σφάλματος που έχουν επιλεγεί (*MARE*), τα οποία συγκρίνονται με τις αντίστοιχες τιμές που προέκυψαν κατά την προσομοίωση του μοντέλου.

Ο έλεγχος του μοντέλου ELM μπορεί να επεκταθεί και στα σύνολα επικύρωσης και ελέγχου, χρησιμοποιώντας τα αντίστοιχα διανύσματα εισόδου για τον υπολογισμό του πίνακα **H** που αντιστοιχεί στην εκάστοτε περίπτωση. Δεδομένου ότι ο πίνακας των συναπτικών βαρών εξόδου $\hat{\beta}$ παραμένει αμετάβλητος, ο υπολογισμός των ζητούμενων κάθε φορά εξόδων του νευρωνικού δικτύου ουσιαστικά αφορά τον υπολογισμό του πίνακα εξόδου του κρυφού στρώματος ανάλογα με την περίπτωση που εξετάζεται.

ΠΑΡΟΥΣΙΑΣΗ ΤΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ

6.1 ΔΙΑΧΩΡΙΣΜΟΣ ΤΗΣ ΒΑΣΗΣ ΓΝΩΣΗΣ

Η διαδικασία της εκπαίδευσης ενός τεχνητού νευρωνικού δικτύου ξεκινά με την επιλογή, την ανάλυση και την επεξεργασία δεδομένων, χρησιμοποιώντας, συνήθως, τεχνικές που προέρχονται από τη στατιστική και την επεξεργασία σημάτων. Το πρώτο αυτό βήμα είναι συχνά και το κρίσιμότερο όσον αφορά την ανάπτυξη ενός νευρωνικού δικτύου, καθώς η ικανότητά του να διακρίνει ανεπαίσθητες σχέσεις προϋποθέτει την ύπαρξη δεδομένων τα οποία υποστηρίζουν την εξαγωγή αυτών των σχέσεων [6]. Επομένως, η συλλογή κατάλληλων δεδομένων εκπαίδευσης, δηλαδή η δημιουργία μιας βάσης γνώσης (knowledge base) η οποία αποτελείται από επαρκή και αντιπροσωπευτικά του εκάστοτε προβλήματος δεδομένα, είναι εξαιρετικά σημαντική.

Η βάση γνώσης του προβλήματος που μελετάται στην παρούσα διπλωματική εργασία, δηλαδή του προβλήματος της βραχυπρόθεσμης πρόβλεψης της φωτοβολταϊκής παραγωγής ενός φωτοβολταϊκού πάρκου, συγκροτείται από διαθέσιμα ιστορικά δεδομένα τα οποία αφορούν δύο διαφορετικά φωτοβολταϊκά πάρκα, το πάρκο της «Περδικούλας» καθώς και το πάρκο «Lampirini». Η πρόβλεψη της φωτοβολταϊκής παραγωγής των δύο αυτών φωτοβολταϊκών πάρκων συνιστά δύο διακριτά προβλήματα, των οποίων η επίλυση απαιτεί διαφορετικές βάσεις γνώσης. Επομένως, η συνολική βάση γνώσης διαχωρίζεται, αρχικά, στα δεδομένα που αφορούν το φωτοβολταϊκό πάρκο της «Περδικούλας» και σε εκείνα που αφορούν το φωτοβολταϊκό πάρκο «Lampirini». Τα ιστορικά δεδομένα κάθε πάρκου, τα οποία περιγράφονται αναλυτικά στην Ενότητα 4.2, αποτελούν την αντίστοιχη βάση γνώσης των δύο διακριτών προβλημάτων προς επίλυση.

Παράλληλα, για κάθε φωτοβολταϊκό πάρκο που εξετάζεται, η διαθέσιμη βάση γνώσης διαιρείται περαιτέρω είτε σε σύνολα εκπαίδευσης και ελέγχου είτε σε σύνολα εκπαίδευσης, επικύρωσης και ελέγχου, όπως γίνεται στο πλαίσιο της παρούσας διπλωματικής εργασίας. Σε κάθε περίπτωση, ο διαχωρισμός των δεδομένων της βάσης γνώσης στα παραπάνω σύνολα πρέπει να γίνει με τρόπο αντιπροσωπευτικό, ώστε να μελετηθούν όλα τα φαινόμενα που συμβάλλουν στο συνολικό πρόβλημα. Για τον σκοπό αυτό, τόσο το σύνολο εκπαίδευσης όσο και τα σύνολα επικύρωσης και ελέγχου αποτελούνται από δεδομένα που αντιστοιχούν σε διαφορετικές εποχές του έτους, σε όλους τους μήνες του έτους, σε διαφορετικές ημέρες του ίδιου μήνα και σε διαφορετικές ώρες της ημέρας. Έτσι, καθίσταται δυνατή η αξιολόγηση της συμπεριφοράς του εκάστοτε μοντέλου για όλες τις πτυχές του προβλήματος.

Στον Πίνακα 6.1 καταγράφονται τα επιμέρους σύνολα ελέγχου που χρησιμοποιούνται για την αξιολόγηση της απόδοσης, όσον αφορά τη γενίκευση, ενός μοντέλου πρόβλεψης το οποίο εφαρμόζεται στο φωτοβολταϊκό πάρκο της «Περδικούλας».

Πίνακας 6.1: Επιμέρους σύνολα ελέγχου για την αξιολόγηση μοντέλων πρόβλεψης που αφορούν το φωτοβολταϊκό πάρκο της «Περδικούλας»

A/A	Ημερομηνία	Από	Έως	DoY	Από <i>t</i>	Έως <i>t</i>
1	5 Δεκεμβρίου 2020	08:15	11:45	340	34	48
2	14 Δεκεμβρίου 2020	12:00	15:30	349	49	63
3	27 Δεκεμβρίου 2020	09:45	13:15	362	40	54
4	8 Ιανουαρίου 2020	08:30	12:00	8	35	49
5	17 Ιανουαρίου 2020	12:30	16:00	17	51	65
6	27 Ιανουαρίου 2020	08:45	12:15	27	36	50
7	3 Φεβρουαρίου 2020	10:00	13:30	34	41	55
8	14 Φεβρουαρίου 2020	08:15	11:45	45	34	48
9	29 Φεβρουαρίου 2020	13:30	17:00	60	55	69
10	6 Μαρτίου 2020	07:45	11:15	66	32	46
11	10 Μαρτίου 2020	12:30	16:00	70	51	65
12	25 Μαρτίου 2020	09:00	12:30	85	37	51
13	1 Απριλίου 2020	14:30	18:00	92	59	73
14	18 Απριλίου 2020	07:30	11:00	109	31	45
15	26 Απριλίου 2020	08:45	12:15	117	36	50
16	2 Μαΐου 2020	10:30	14:00	123	43	57
17	14 Μαΐου 2020	07:30	11:00	135	31	45
18	27 Μαΐου 2020	07:00	10:30	148	29	43
19	10 Ιουνίου 2020	07:45	11:15	162	32	46
20	20 Ιουνίου 2020	12:15	15:45	172	50	64
21	30 Ιουνίου 2020	16:15	19:45	182	66	80
22	2 Ιουλίου 2020	08:45	12:15	184	36	50
23	15 Ιουλίου 2020	10:00	13:30	197	41	55
24	29 Ιουλίου 2020	15:00	18:30	211	61	75
25	5 Αυγούστου 2020	07:45	11:15	218	32	46
26	10 Αυγούστου 2020	11:00	14:30	223	45	59
27	27 Αυγούστου 2020	14:45	18:15	240	60	74
28	4 Σεπτεμβρίου 2020	08:15	11:45	248	34	48
29	13 Σεπτεμβρίου 2020	09:00	12:30	257	37	51
30	27 Σεπτεμβρίου 2020	10:45	14:15	271	44	58
31	2 Οκτωβρίου 2020	10:30	14:00	276	43	57
32	15 Οκτωβρίου 2020	08:45	12:15	289	36	50
33	28 Οκτωβρίου 2020	13:00	16:30	302	53	67
34	7 Νοεμβρίου 2020	13:30	17:00	312	55	69
35	15 Νοεμβρίου 2020	11:15	14:45	320	46	60

Πίνακας 6.1: Επιμέρους σύνολα ελέγχου για την αξιολόγηση μοντέλων πρόβλεψης που αφορούν το φωτοβολταϊκό πάρκο της «Περδικούλας» (συνέχεια)

A/A	Ημερομηνία	Από	Έως	DoY	Από t	Έως t
36	23 Νοεμβρίου 2020	12:00	15:30	328	49	63

Οι στήλες «Από» και «Έως» αφορούν τις χρονικές στιγμές για τις οποίες πραγματοποιείται η πρώτη και η τελευταία πρόβλεψη του εκάστοτε χρονικού ορίζοντα. Για παράδειγμα, για το επιμέρους σύνολο ελέγχου με αύξοντα αριθμό (A/A) ίσο με ένα (1), η πρώτη πρόβλεψη που παράγει το μοντέλο αφορά τη χρονική στιγμή 08:15, ενώ η τελευταία παραγόμενη πρόβλεψη, η οποία παράγεται ταυτόχρονα με την πρώτη αλλά και όλες τις ενδιάμεσες προβλέψεις, τη χρονική στιγμή 11:45. Το διάνυσμα εισόδου που χρησιμοποιείται για την παραγωγή των συγκεκριμένων προβλέψεων αποτελείται από τις επιλεγμένες παραμέτρους εισόδου που αντιστοιχούν στην ίδια ημέρα (5 Δεκεμβρίου 2020) και στην αμέσως προηγούμενη χρονική στιγμή (08:00), για την οποία έχει απαιτηθεί η ύπαρξη διαθέσιμων δεδομένων. Επομένως, ο χρονικός ορίζοντας της πρόβλεψης είναι το διάστημα 08:00–11:45, το οποίο διαρκεί 225 λεπτά και περιλαμβάνει 15 προβλέψεις, με χρονικό βήμα τα 15 λεπτά.

Η στήλη «DoY» αφορά τον αριθμό της ημέρας για την οποία διενεργείται η πρόβλεψη, ενώ οι στήλες «Από t » και «Έως t » αντιστοιχούν, επίσης, στις χρονικές στιγμές της πρώτης και της τελευταίας πρόβλεψης. Οι τιμές των DoY και t εξάγονται από τη χρονική σήμανση που συνοδεύει κάθε σύνολο μετρήσεων μέσω της ανάπτυξης κατάλληλου κώδικα, ενώ περιγράφονται αναλυτικά στην Ενότητα 5.1.3. Για το παράδειγμα του επιμέρους συνόλου ελέγχου με A/A 1, η τιμή 340 αφορά την ημέρα 5 Δεκεμβρίου για το δίσεκτο έτος 2020, ενώ οι τιμές 34 και 48 αφορούν τις χρονικές στιγμές 08:15 και 11:45 αντίστοιχα, για χρονική ανάλυση 15 λεπτών.

Κατά την αξιολόγηση της απόδοσης ενός τεχνητού νευρωνικού δικτύου που εκπαιδεύτηκε χρησιμοποιώντας ιστορικά δεδομένα του φωτοβολταϊκού πάρκου της «Περδικούλας», τα 36 επιμέρους σύνολα ελέγχου του Πίνακα 6.1 αποτελούν τις επιμέρους συνιστώσες του συνόλου ελέγχου. Για κάθε επιμέρους σύνολο ελέγχου, το οποίο αποτελείται από ένα διάνυσμα εισόδου και το αντίστοιχο επιθυμητό διάνυσμα εξόδου 15 συνιστωσών, παράγεται ένα διάνυσμα εξόδου με 15 συνιστώσες (μία για κάθε πρόβλεψη), το οποίο συνιστά την απόκριση του χρησιμοποιούμενου μοντέλου πρόβλεψης στο διάνυσμα εισόδου. Έτσι, υπολογίζεται η τιμή των επιλεγμένων μετρικών σφάλματος, τα οποία για την παρούσα διπλωματική εργασία είναι το *MAPE* και το *MSE*, τα οποία ορίζονται με τις εξισώσεις (3.3) και (5.7) αντίστοιχα, με αποτέλεσμα η υπολογιζόμενη τιμή κάθε μετρικού σφάλματος για το σύνολο ελέγχου να προκύπτει ως ο μέσος όρος των παραπάνω επιμέρους τιμών, δηλαδή ως Mean *MAPE* και Mean *MSE*, αντίστοιχα.

Όπως φαίνεται στον Πίνακα 6.1, τα 36 επιμέρους σύνολα ελέγχου που αφορούν το φωτοβολταϊκό πάρκο της «Περδικούλας» επιλέχθηκαν, ώστε να είναι όσο το δυνατόν περισσότερο αντιπροσωπευτικά. Συγκεκριμένα, για κάθε μήνα του εξεταζόμενου έτους (2020) κατασκευάζονται τρία διαφορετικά επιμέρους σύνολα ελέγχου, τα οποία αφορούν διαφορετικές ημέρες κάθε μήνα αλλά και διαφορετικές ώρες της ημέρας. Ωστόσο, πρέπει να σημειωθεί ότι οι ώρες της ημέρας που επιλέχθηκαν αφορούν αποκλειστικά ώρες μετά την ανατολή και πριν τη δύση του ήλιου. Η επιλογή αυτή στηρίζεται στο γεγονός ότι εξαιτίας της

έλλειψης φωτοβολταϊκής παραγωγής τις ώρες μετά τη δύση και πριν την ανατολή του ήλιου, οι αντίστοιχες υπολογιζόμενες τιμές των μετρικών σφάλματος αναμένεται να είναι πάρα πολύ μικρές, γεγονός που πιστοποιήθηκε με τη διενέργεια ορισμένων προκαταρκτικών δοκιμών. Έτσι, τα επιμέρους σύνολα ελέγχου που χρησιμοποιούνται αφορούν εξ ολοκλήρου χρονικά διαστήματα κατά τα οποία καταγράφεται φωτοβολταϊκή παραγωγή, αφού η ενδεχόμενη ύπαρξη πάρα πολύ μικρών σφαλμάτων – τα οποία μάλιστα αντιστοιχούν σε δεδομένα που δεν παρουσιάζουν ενδιαφέρον, δηλαδή δεδομένα που αφορούν χρονικά διαστήματα κατά τα οποία δεν υπάρχει παραγωγή φωτοβολταϊκής ισχύος – θα επηρέαζε σημαντικά τους μέσους όρους που υπολογίζονται όσον αφορά το σύνολο ελέγχου.

Η συγκεκριμένη προσέγγιση εφαρμόζεται, επίσης, κατά την επιλογή των δεδομένων του συνόλου εκπαίδευσης καθώς και του συνόλου επικύρωσης. Αρχικά, τα ιστορικά δεδομένα που αντιστοιχούν στις ημέρες του Πίνακα 6.1 διαχωρίζονται από τα υπόλοιπα δεδομένα που είναι διαθέσιμα στη βάση γνώσης, ενώ, μετά από κατάλληλη διαχείριση, συγκροτούνται σε 36 επιμέρους σύνολα ελέγχου. Στη συνέχεια, ακολουθεί η επεξεργασία των υπόλοιπων διαθέσιμων δεδομένων, τα οποία θα συγκροτήσουν τα σύνολα εκπαίδευσης και επικύρωσης. Συγκεκριμένα, από τα δεδομένα που έχουν παραμείνει διαθέσιμα στη βάση γνώσης αφαιρούνται, αρχικά, τα σύνολα μετρήσεων τα οποία περιλαμβάνουν κενές θέσεις, δηλαδή θέσεις στις οποίες δεν έχει αποδοθεί κάποια τιμή. Παράλληλα, αφαιρούνται τα σύνολα μετρήσεων για τα οποία η τιμή της ενεργού ισχύος που καταγράφηκε στην έξοδο του φωτοβολταϊκού πάρκου είναι μηδενική ή αρνητική, καθώς και τα σύνολα μετρήσεων που αντιστοιχούν σε επιθυμητά διανύσματα εξόδου τα οποία περιλαμβάνουν μηδενικές ή αρνητικές τιμές της ενεργού ισχύος. Επομένως, τα δεδομένα που χρησιμοποιούνται κατά τη διαδικασία της μάθησης, είτε αυτά είναι διανύσματα εισόδου είτε επιθυμητά διανύσματα εξόδου, αφορούν αποκλειστικά χρονικές στιγμές για τις οποίες υπάρχει φωτοβολταϊκή παραγωγή.

Τέλος, τα δεδομένα αυτά διαχωρίζονται στο σύνολο επικύρωσης και το σύνολο εκπαίδευσης. Ο διαχωρισμός αυτός μπορεί να υλοποιηθεί είτε δεσμεύοντας ένα ποσοστό των δεδομένων του συνόλου μάθησης κατά τη διαδικασία της εκπαίδευσης (μοντέλο MLP) είτε κατασκευάζοντας εξ αρχής ένα σύνολο επικύρωσης με τα επιθυμητά χαρακτηριστικά (μοντέλο MLP, μοντέλο ELM). Στο πλαίσιο της παρούσας διπλωματικής εργασίας, συνήθως χρησιμοποιούνται σύνολα επικύρωσης προσαρμοσμένων χαρακτηριστικών, δηλαδή σύνολα που κατασκευάστηκαν από τον χρήστη του νευρωνικού δικτύου. Για το φωτοβολταϊκό πάρκο της «Περδικούλας», το σύνολο επικύρωσης κατασκευάζεται με τέτοιο τρόπο, ώστε να περιλαμβάνει τα επιτρεπόμενα ιστορικά δεδομένα που αφορούν κάθε τέταρτη ημέρα του έτους που εξετάζεται, ενώ το σύνολο εκπαίδευσης συγκροτείται από τα υπόλοιπα δεδομένα του συνόλου μάθησης. Πρακτικά, η διαίρεση του συνόλου μάθησης σε σύνολα εκπαίδευσης και επικύρωσης γίνεται με αναλογία 75%–25% κατά προσέγγιση, όπου περίπου 75% των δεδομένων μάθησης ανήκει στο σύνολο εκπαίδευσης και το υπόλοιπο περίπου 25% στο σύνολο επικύρωσης.

Ο περιγραφόμενος τρόπος διαχωρισμού της βάσης γνώσης – αρχικά σε επιμέρους σύνολα τα οποία συγκροτούν το σύνολο ελέγχου και, στη συνέχεια, σε σύνολα επικύρωσης και εκπαίδευσης – αφορά το φωτοβολταϊκό πάρκο της «Περδικούλας». Ωστόσο, μπορεί εύκολα να επεκταθεί σε παρεμφερείς βάσεις γνώσης, όπως αυτή που αποτελείται από το σύνολο των διαθέσιμων ιστορικών δεδομένων του φωτοβολταϊκού πάρκου «Lampirini». Στον

Πίνακα 6.2 καταγράφονται τα επιμέρους σύνολα ελέγχου που χρησιμοποιούνται για την αξιολόγηση της απόδοσης ενός μοντέλου πρόβλεψης που εφαρμόζεται στο φωτοβολταϊκό πάρκο «Lampirini», για προβλέψεις που πραγματοποιούνται σε χρονικό ορίζοντα πρόβλεψης 225 λεπτών με βήμα τα 15 λεπτά και αφορούν αποκλειστικά το έτος 2020.

Πίνακας 6.2: Επιμέρους σύνολα ελέγχου για την αξιολόγηση μοντέλων πρόβλεψης που αφορούν το φωτοβολταϊκό πάρκο «Lampirini» (2020) και ορίζοντα πρόβλεψης 225 λεπτών

A/A	Ημερομηνία	Από	Έως	DoY	Από <i>t</i>	Έως <i>t</i>
1	5 Δεκεμβρίου 2020	08:15	11:45	340	34	48
2	14 Δεκεμβρίου 2020	10:45	14:15	349	44	58
3	26 Δεκεμβρίου 2020	12:45	16:15	361	52	66
4	8 Ιανουαρίου 2020	12:15	15:45	8	50	64
5	17 Ιανουαρίου 2020	12:30	16:00	17	51	65
6	27 Ιανουαρίου 2020	08:45	12:15	27	36	50
7	3 Φεβρουαρίου 2020	10:00	13:30	34	41	55
8	14 Φεβρουαρίου 2020	08:15	11:45	45	34	48
9	29 Φεβρουαρίου 2020	13:30	17:00	60	55	69
10	6 Μαρτίου 2020	07:45	11:15	66	32	46
11	10 Μαρτίου 2020	12:30	16:00	70	51	65
12	25 Μαρτίου 2020	09:00	12:30	85	37	51
13	1 Απριλίου 2020	09:45	13:15	92	40	54
14	18 Απριλίου 2020	07:30	11:00	109	31	45
15	26 Απριλίου 2020	08:45	12:15	117	36	50
16	2 Μαΐου 2020	10:30	14:00	123	43	57
17	14 Μαΐου 2020	07:30	11:00	135	31	45
18	27 Μαΐου 2020	16:00	19:30	148	65	79
19	10 Ιουνίου 2020	07:45	11:15	162	32	46
20	20 Ιουνίου 2020	12:15	15:45	172	50	64
21	30 Ιουνίου 2020	16:15	19:45	182	66	80
22	2 Ιουλίου 2020	08:45	12:15	184	36	50
23	15 Ιουλίου 2020	10:00	13:30	197	41	55
24	29 Ιουλίου 2020	15:00	18:30	211	61	75
25	5 Αυγούστου 2020	07:45	11:15	218	32	46
26	10 Αυγούστου 2020	11:00	14:30	223	45	59
27	27 Αυγούστου 2020	14:45	18:15	240	60	74
28	4 Σεπτεμβρίου 2020	08:15	11:45	248	34	48
29	13 Σεπτεμβρίου 2020	09:00	12:30	257	37	51
30	27 Σεπτεμβρίου 2020	10:45	14:15	271	44	58
31	2 Οκτωβρίου 2020	10:30	14:00	276	43	57

Πίνακας 6.2: Επιμέρους σύνολα ελέγχου για την αξιολόγηση μοντέλων πρόβλεψης που αφορούν το φωτοβολταϊκό πάρκο «Lamprini» (2020) και ορίζοντα πρόβλεψης 225 λεπτών (συνέχεια)

A/A	Ημερομηνία	Από	Έως	DoY	Από t	Έως t
32	15 Οκτωβρίου 2020	08:45	12:15	289	36	50
33	28 Οκτωβρίου 2020	13:00	16:30	302	53	67
34	7 Νοεμβρίου 2020	13:30	17:00	312	55	69
35	15 Νοεμβρίου 2020	11:15	14:45	320	46	60
36	23 Νοεμβρίου 2020	12:00	15:30	328	49	63

Επειδή τα ιστορικά δεδομένα του φωτοβολταϊκού πάρκου «Lamprini» δίνονται με χρονική ανάλυση ενός (1) λεπτού, υπάρχει η δυνατότητα, μέσω κατάλληλης επεξεργασίας, να χρησιμοποιηθούν δεδομένα με χρονική ανάλυση 15 λεπτών. Συγκεκριμένα, από τη βάση γνώσης του φωτοβολταϊκού πάρκου «Lamprini» εξάγονται όλα τα σύνολα μετρήσεων που αφορούν χρονικές στιγμές του έτους 2020 οι οποίες αντιστοιχούν σε 0, 15, 30 ή 45 λεπτά της ώρας. Έτσι, δημιουργείται μια νέα βάση γνώσης, υποσύνολο της αρχικής, η οποία υποστηρίζει την παραγωγή προβλέψεων σε χρονικό ορίζοντα 225 λεπτών με βήμα τα 15 λεπτά. Ο διαχωρισμός της νέας αυτής βάσης γνώσης σε σύνολα ελέγχου, επικύρωσης και εκπαίδευσης πραγματοποιείται όπως στην περίπτωση του φωτοβολταϊκού πάρκου της «Περδικούλας».

Τα 36 επιμέρους σύνολα ελέγχου του Πίνακα 6.2 χρησιμοποιούνται για την αξιολόγηση των μοντέλων πρόβλεψης που εφαρμόζονται στη νέα βάση γνώσης που δημιουργήθηκε. Η αξιολόγηση αυτή πραγματοποιείται με σκοπό τη σύγκριση της συμπεριφοράς του εφαρμοζόμενου μοντέλου πρόβλεψης με τη συμπεριφορά αντίστοιχου μοντέλου που εφαρμόζεται στα δεδομένα του φωτοβολταϊκού πάρκου της «Περδικούλας». Ο έλεγχος ενός μοντέλου πρόβλεψης (MLP, ELM) σε διαφορετικές τοποθεσίες μπορεί να συμβάλει στον προσδιορισμό της ευρωστίας (robustness) του μοντέλου, καθώς τα μετρικά σφάλματος που υπολογίζονται μπορεί να διαφέρουν σημαντικά ανάλογα με την τοποθεσία του φωτοβολταϊκού πάρκου που εξετάζεται, εξαιτίας της διαφορετικής κλιματικής μεταβλητότητας κάθε περιοχής [38].

Παράλληλα, η συμπεριφορά των μοντέλων πρόβλεψης που αναπτύχθηκαν όσον αφορά το φωτοβολταϊκό πάρκο «Lamprini» για χρονικό ορίζοντα 225 λεπτών συγκρίνεται με τη συμπεριφορά που παρουσιάζουν παρεμφερή μοντέλα πρόβλεψης τα οποία αφορούν το ίδιο φωτοβολταϊκό πάρκο, αλλά διαφορετικό χρονικό ορίζοντα πρόβλεψης, συγκεκριμένα 15 λεπτών. Για τον σκοπό αυτό, τα εξεταζόμενα μοντέλα πρόβλεψης εκπαιδεύονται χρησιμοποιώντας δεδομένα του φωτοβολταϊκού πάρκου «Lamprini» τα οποία παρουσιάζουν χρονική ανάλυση ενός (1) λεπτού. Αρχικά, χρησιμοποιούνται ιστορικά δεδομένα που αφορούν αποκλειστικά το έτος 2020, οπότε κατασκευάζονται αντίστοιχα σύνολα ελέγχου, επικύρωσης και εκπαίδευσης. Τα επιμέρους σύνολα ελέγχου που χρησιμοποιούνται για την αξιολόγηση της απόδοσης ενός μοντέλου πρόβλεψης όσον αφορά το φωτοβολταϊκό πάρκο «Lamprini» για το έτος 2020 και χρονικό ορίζοντα πρόβλεψης 15 λεπτών παρουσιάζονται στον Πίνακα 6.3:

Πίνακας 6.3: Επιμέρους σύνολα ελέγχου για την αξιολόγηση μοντέλων πρόβλεψης που αφορούν το φωτοβολταϊκό πάρκο «Lampirini» (2020) και ορίζοντα πρόβλεψης 15 λεπτών

A/A	Ημερομηνία	Από	Έως	DoY	Από <i>t</i>	Έως <i>t</i>
1	5 Δεκεμβρίου 2020	10:00	10:14	340	601	615
2	14 Δεκεμβρίου 2020	12:00	12:14	349	721	735
3	26 Δεκεμβρίου 2020	08:20	08:34	361	501	515
4	8 Ιανουαρίου 2020	12:14	12:28	8	735	749
5	17 Ιανουαρίου 2020	14:27	14:41	17	868	882
6	27 Ιανουαρίου 2020	11:15	11:29	27	676	690
7	3 Φεβρουαρίου 2020	10:26	10:40	34	627	641
8	14 Φεβρουαρίου 2020	15:31	15:45	45	932	946
9	29 Φεβρουαρίου 2020	14:14	14:28	60	855	869
10	6 Μαρτίου 2020	12:11	12:25	66	732	746
11	10 Μαρτίου 2020	15:50	16:04	70	951	965
12	25 Μαρτίου 2020	13:56	14:10	85	837	851
13	1 Απριλίου 2020	13:59	14:13	92	840	854
14	18 Απριλίου 2020	15:30	15:44	109	931	945
15	26 Απριλίου 2020	17:15	17:29	117	1036	1050
16	2 Μαΐου 2020	15:42	15:56	123	943	957
17	14 Μαΐου 2020	10:30	10:44	135	631	645
18	27 Μαΐου 2020	18:48	19:02	148	1129	1143
19	10 Ιουνίου 2020	18:51	19:05	162	1132	1146
20	20 Ιουνίου 2020	12:29	12:43	172	750	764
21	30 Ιουνίου 2020	11:05	11:19	182	666	680
22	2 Ιουλίου 2020	13:55	14:09	184	836	850
23	15 Ιουλίου 2020	15:40	15:54	197	941	955
24	29 Ιουλίου 2020	17:40	17:54	211	1061	1075
25	5 Αυγούστου 2020	08:51	09:05	218	532	546
26	10 Αυγούστου 2020	14:04	14:18	223	845	859
27	27 Αυγούστου 2020	10:59	11:13	240	660	674
28	4 Σεπτεμβρίου 2020	17:13	17:27	248	1034	1048
29	13 Σεπτεμβρίου 2020	15:22	15:36	257	923	937
30	27 Σεπτεμβρίου 2020	14:12	14:26	271	853	867
31	2 Οκτωβρίου 2020	10:24	10:38	276	625	639
32	15 Οκτωβρίου 2020	08:55	09:09	289	536	550
33	28 Οκτωβρίου 2020	15:52	16:06	302	953	967
34	7 Νοεμβρίου 2020	09:24	09:38	312	565	579
35	15 Νοεμβρίου 2020	10:45	10:59	320	646	660

Πίνακας 6.3: Επιμέρους σύνολα ελέγχου για την αξιολόγηση μοντέλων πρόβλεψης που αφορούν το φωτοβολταϊκό πάρκο «Lampirini» (2020) και ορίζοντα πρόβλεψης 15 λεπτών (συνέχεια)

A/A	Ημερομηνία	Από	Έως	DoY	Από <i>t</i>	Έως <i>t</i>
36	23 Νοεμβρίου 2020	12:28	12:42	328	749	763

Ενώ οι στήλες «Από *t*» και «Έως *t*» του Πίνακα 6.3 αντιστοιχούν και πάλι στις χρονικές στιγμές της πρώτης και της τελευταίας παραγόμενης πρόβλεψης, οι τιμές που μπορούν πλέον να λάβουν έχουν διαφοροποιηθεί σε σχέση με τον Πίνακα 6.2. Η διαφοροποίηση αυτή οφείλεται στη χρονική ανάλυση των διαθέσιμων ιστορικών δεδομένων, η οποία είναι πλέον ένα (1) λεπτό και όχι 15 λεπτά. Παράλληλα, κάθε διάνυσμα εισόδου που χρησιμοποιείται για την παραγωγή πρόβλεψης αποτελείται από παραμέτρους εισόδου που αντιστοιχούν στην ίδια ημέρα και στο αμέσως προηγούμενο λεπτό. Για παράδειγμα, το διάνυσμα εισόδου που αντιστοιχεί στο επιμέρους σύνολο ελέγχου με A/A 36 του Πίνακα 6.3 περιλαμβάνει τιμές των μεταβλητών εισόδου οι οποίες καταγράφηκαν στις 23 Νοεμβρίου 2020 για τη χρονική στιγμή 12:27. Επομένως, ο χρονικός ορίζοντας της παραγόμενης πρόβλεψης είναι το διάστημα 12:27–12:42, το οποίο διαρκεί 15 λεπτά και περιλαμβάνει 15 επιμέρους προβλέψεις, με χρονικό βήμα το ένα (1) λεπτό.

Τέλος, εξετάστηκε η απόδοση των μοντέλων πρόβλεψης που αναπτύχθηκαν όταν για την εκπαίδευσή τους χρησιμοποιείται το σύνολο των διαθέσιμων ιστορικών δεδομένων του φωτοβολταϊκού πάρκου «Lampirini». Οι δοκιμές που διενεργούνται αποσκοπούν στη διερεύνηση της επίδρασης του πλήθους των ιστορικών δεδομένων στην απόδοση του μοντέλου. Συνεπώς, διερευνάται εάν η προσθήκη ενός μεγάλου πλήθους ιστορικών δεδομένων, τα οποία αφορούν το έτος 2021, στην ήδη χρησιμοποιούμενη βάση γνώσης μπορεί να οδηγήσει στην επίτευξη μεγαλύτερης ακρίβειας. Η εκτίμηση της ακρίβειας των συγκεκριμένων μοντέλων πραγματοποιείται με χρήση 36 νέων επιμέρους συνόλων ελέγχου, τα οποία αφορούν τις ίδιες ημέρες και τα ίδια διαστήματα πρόβλεψης με τα αντίστοιχα σύνολα του Πίνακα 6.3, αλλά για το έτος 2021. Τα νέα αυτά σύνολα παρουσιάζονται στον Πίνακα 6.4:

Πίνακας 6.4: Επιμέρους σύνολα ελέγχου για την αξιολόγηση μοντέλων πρόβλεψης που αφορούν το φωτοβολταϊκό πάρκο «Lampirini» (2020, 2021) και ορίζοντα πρόβλεψης 15 λεπτών

A/A	Ημερομηνία	Από	Έως	DoY	Από <i>t</i>	Έως <i>t</i>
1	5 Δεκεμβρίου 2021	10:00	10:14	340	601	615
2	14 Δεκεμβρίου 2021	12:00	12:14	349	721	735
3	26 Δεκεμβρίου 2021	08:20	08:34	361	501	515
4	8 Ιανουαρίου 2021	12:14	12:28	8	735	749
5	17 Ιανουαρίου 2021	14:27	14:41	17	868	882
6	27 Ιανουαρίου 2021	11:15	11:29	27	676	690
7	3 Φεβρουαρίου 2021	10:26	10:40	34	627	641
8	14 Φεβρουαρίου 2021	15:31	15:45	45	932	946
9	29 Φεβρουαρίου 2021	14:14	14:28	60	855	869

Πίνακας 6.4: Επιμέρους σύνολα ελέγχου για την αξιολόγηση μοντέλων πρόβλεψης που αφορούν το φωτοβολταϊκό πάρκο «Lamprini» (2020, 2021) και ορίζοντα πρόβλεψης 15 λεπτών (συνέχεια)

A/A	Ημερομηνία	Από	Έως	DoY	Από <i>t</i>	Έως <i>t</i>
10	6 Μαρτίου 2021	12:11	12:25	66	732	746
11	10 Μαρτίου 2021	15:50	16:04	70	951	965
12	25 Μαρτίου 2021	13:56	14:10	85	837	851
13	1 Απριλίου 2021	13:59	14:13	92	840	854
14	18 Απριλίου 2021	15:30	15:44	109	931	945
15	26 Απριλίου 2021	17:15	17:29	117	1036	1050
16	2 Μαΐου 2021	15:42	15:56	123	943	957
17	14 Μαΐου 2021	10:30	10:44	135	631	645
18	27 Μαΐου 2021	18:48	19:02	148	1129	1143
19	10 Ιουνίου 2021	18:51	19:05	162	1132	1146
20	20 Ιουνίου 2021	12:29	12:43	172	750	764
21	30 Ιουνίου 2021	11:05	11:19	182	666	680
22	2 Ιουλίου 2021	13:55	14:09	184	836	850
23	15 Ιουλίου 2021	15:40	15:54	197	941	955
24	29 Ιουλίου 2021	17:40	17:54	211	1061	1075
25	5 Αυγούστου 2021	08:51	09:05	218	532	546
26	10 Αυγούστου 2021	14:04	14:18	223	845	859
27	27 Αυγούστου 2021	10:59	11:13	240	660	674
28	4 Σεπτεμβρίου 2021	17:13	17:27	248	1034	1048
29	13 Σεπτεμβρίου 2021	15:22	15:36	257	923	937
30	27 Σεπτεμβρίου 2021	14:12	14:26	271	853	867
31	2 Οκτωβρίου 2021	10:24	10:38	276	625	639
32	15 Οκτωβρίου 2021	08:55	09:09	289	536	550
33	28 Οκτωβρίου 2021	15:52	16:06	302	953	967
34	7 Νοεμβρίου 2021	09:24	09:38	312	565	579
35	15 Νοεμβρίου 2021	10:45	10:59	320	646	660
36	23 Νοεμβρίου 2021	12:28	12:42	328	749	763

Τα επιμέρους σύνολα ελέγχου του Πίνακα 6.4 χρησιμοποιούνται, αρχικά, για την αξιολόγηση νευρωνικών δικτύων που εκπαιδεύτηκαν αποκλειστικά με ιστορικά δεδομένα του έτους 2021. Στη συνέχεια, τα σύνολα εκπαίδευσης και επικύρωσης εμπλουτίζονται με επιτρεπόμενα, βάσει της αρχικής μεθόδου διαχωρισμού που περιγράφηκε, δεδομένα του έτους 2020, ώστε να διερευνηθεί η επίτευξη ενδεχόμενης βελτίωσης όσον αφορά την ακρίβεια (απόδοση) των νευρωνικών δικτύων.

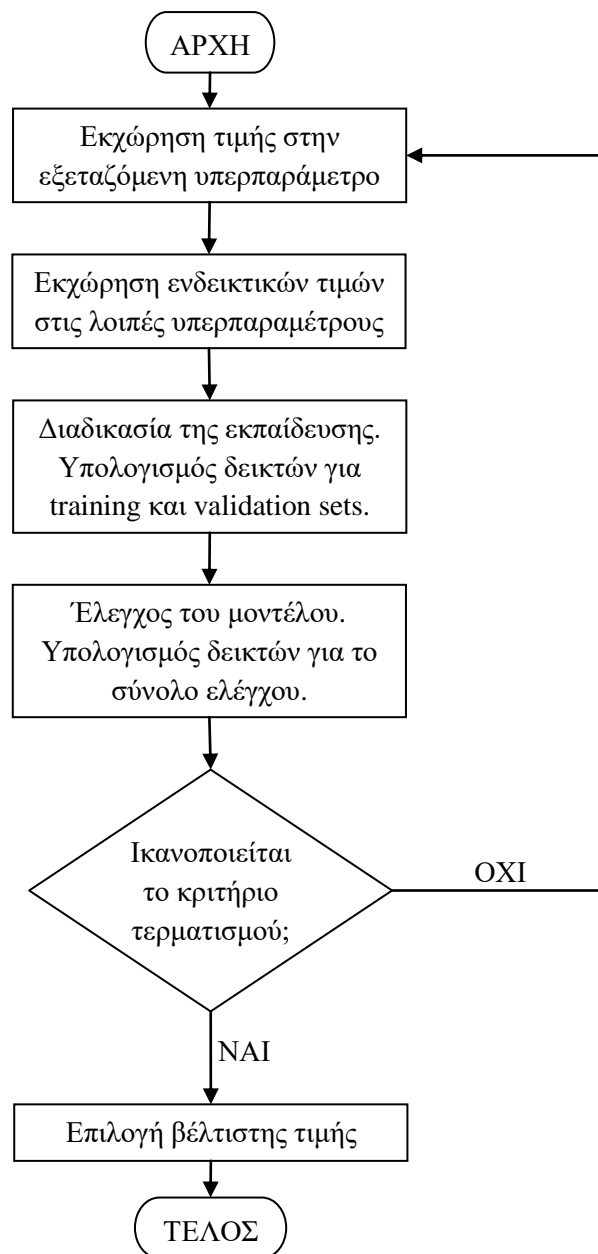
6.2 ΔΟΚΙΜΕΣ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ ΤΟΥ ΜΟΝΤΕΛΟΥ MLP

Η βελτιστοποίηση του μοντέλου MLP που αναπτύσσεται στην παρούσα διπλωματική εργασία αφορά την εύρεση της βέλτιστης διαμόρφωσης του αντίστοιχου νευρωνικού δικτύου. Πέρα από τις τιμές που επιλέγονται όσον αφορά τις υπερπαραμέτρους ενός δικτύου, η συμπεριφορά του εξαρτάται και από άλλες παραμέτρους, όπως το πλήθος των ιστορικών δεδομένων που χρησιμοποιούνται για την εκπαίδευση του δικτύου και ο τρόπος διαχωρισμού των διαθέσιμων δεδομένων σε σύνολα ελέγχου, εκπαίδευσης και ενδεχομένως επικύρωσης. Η διερεύνηση της επίδρασης μιας εξεταζόμενης παραμέτρου στην απόδοση του μοντέλου πρόβλεψης πραγματοποιείται μέσω της διενέργειας δοκιμών.

Στο πλαίσιο της παρούσας διπλωματικής εργασίας, οι δοκιμές που διενεργούνται με σκοπό τη βελτιστοποίηση ενός μοντέλου πρόβλεψης βασίζονται, κατά κανόνα, στη μέθοδο βελτιστοποίησης «Trial and Error». Συγκεκριμένα, για κάθε παράμετρο που εξετάζεται, η τιμή της συγκεκριμένης παραμέτρου μεταβάλλεται καθώς οι τιμές των υπόλοιπων υπερπαραμέτρων του δικτύου διατηρούνται σταθερές, είτε σε κάποια τιμή που έχει ήδη κριθεί βέλτιστη είτε σε κάποια προκαθορισμένη τιμή. Όσον αφορά την εξεταζόμενη υπερπαραμέτρο, δοκιμάζονται όσο το δυνατόν περισσότερες τιμές με σκοπό την εύρεση της βέλτιστης τιμής της, δηλαδή της τιμής για την οποία το υπολογιζόμενο μετρικό σφάλματος (*MAPE*) ελαχιστοποιείται.

Η εύρεση της βέλτιστης διαμόρφωσης υπερπαραμέτρων ενός νευρωνικού δικτύου απαιτεί, σε θεωρητικό επίπεδο, τον έλεγχο όλων των δυνατών συνδυασμών τους. Ωστόσο, το μεγάλο πλήθος υπερπαραμέτρων που απαιτούν ρύθμιση αλλά και το γεγονός ότι πολλές εξ αυτών είναι συνεχείς καθιστούν έναν τέτοιο έλεγχο πρακτικά ανέφικτο. Επομένως, οι δοκιμές που πραγματοποιούνται για κάθε εξεταζόμενη υπερπαραμέτρο αφορούν, συνήθως, κάποιο πεπερασμένο υποσύνολο του εύρους τιμών της αντίστοιχης υπερπαραμέτρου. Κάθε φορά που μεταβάλλεται η τιμή της εξεταζόμενης υπερπαραμέτρου, το νευρωνικό δίκτυο εκπαιδεύεται εκ νέου και η νέα αυτή διαμόρφωση αξιολογείται μέσω του υπολογισμού των επιλεγμένων δεικτών αξιολόγησης για τα σύνολα επικύρωσης και ελέγχου που έχουν καθοριστεί. Κατά την εφαρμογή της μεθόδου βελτιστοποίησης «Trial and Error», η διαδικασία αυτή επαναλαμβάνεται ενώ, παράλληλα, παρακολουθείται η εξέλιξη των υπολογιζόμενων δεικτών αξιολόγησης καθώς και ο χρόνος που απαιτείται για την ολοκλήρωσή της. Οι δοκιμές νέων τιμών όσον αφορά την υπερπαραμέτρο που εξετάζεται ολοκληρώνονται εφόσον κριθεί ότι δεν μπορεί να υπάρξει περαιτέρω βελτίωση της απόδοσης του μοντέλου πρόβλεψης ή ότι η αύξηση του απαιτούμενου χρόνου εκπαίδευσης και αξιολόγησης του μοντέλου δεν αντισταθμίζεται επαρκώς από ανάλογη βελτίωση όσον αφορά τη συμπεριφορά του.

Η διαδικασία που ακολουθείται με σκοπό την αναζήτηση της βέλτιστης τιμής της εκάστοτε υπερπαραμέτρου στο πλαίσιο της μεθόδου «Δοκιμή και Σφάλμα» παρουσιάζεται σχηματικά με το διάγραμμα ροής του Σχήματος 6.1. Το κριτήριο τερματισμού που εφαρμόζεται αφορά τον χρήστη του μοντέλου MLP, καθώς αυτός κρίνει εάν υπάρχουν περιθώρια βελτίωσης όσον αφορά την απόδοση του μοντέλου ή εάν η εξέλιξη των υπολογιζόμενων δεικτών αξιολόγησης δικαιολογεί τη διενέργεια περαιτέρω δοκιμών, εφαρμόζοντας νέες διαμορφώσεις υπερπαραμέτρων οι οποίες συχνά χαρακτηρίζονται από αυξημένο χρόνο εκτέλεσης.



Σχήμα 6.1: Διαδικασία αναζήτησης της βέλτιστης τιμής υπερπαραμέτρου στο πλαίσιο της μεθόδου «Trial and Error»

6.2.1 Φωτοβολταϊκό πάρκο της «Περδικούλας»

Η πρώτη υπερπαραμέτρος που εξετάστηκε για το μοντέλο MLP, όταν αυτό εφαρμόζεται στο φωτοβολταϊκό πάρκο της «Περδικούλας», είναι ο αριθμός των νευρώνων εισόδου. Η εύρεση του βέλτιστου αριθμού των νευρώνων που συγκροτούν το στρώμα εισόδου ισοδυναμεί με την επιλογή των κατηγοριών εισόδου για τις οποίες το μοντέλο MLP παρουσιάζει την καλύτερη συμπεριφορά, δηλαδή των μεταβλητών εισόδου για τις οποίες υπολογίζονται οι βέλτιστες τιμές των επιλεγμένων δεικτών αξιολόγησης.

Πίνακας 6.5: Δεδομένα εισόδου νευρωνικού δικτύου για το φωτοβολταϊκό πάρκο της «Περδικούλας»

Κωδική Ονομασία	Πλήρης Ονομασία	Μονάδες Μέτρησης
In1	Day of Year – DoY	-
In2	t	-
In3	Total PCC active power (kW) [PCC]	kW
In4	Total Irradiance ($W \cdot m^{-2}$) [Panel Group 2-5-07]	W/m^2
In5	Total Irradiance ($W \cdot m^{-2}$) [Panel Group 12-4-12]	W/m^2
In6	Total Irradiance ($W \cdot m^{-2}$) [Panel Group 4-1-04]	W/m^2
In7	Total Irradiance ($W \cdot m^{-2}$) [Panel Group 6-1-15]	W/m^2
In8	Module Temperature (C) [Panel Group 1-7-17]	$^{\circ}C$
In9	Module Temperature (C) [Panel Group 12-4-13]	$^{\circ}C$
In10	Module Temperature (C) [Panel Group 6-5-17]	$^{\circ}C$
In11	Total PCC reactive power (kVAr) [PCC]	kVAr
In12	Ambient temperature (C) [S/S11-12]	$^{\circ}C$
In13	Wind speed ($m \cdot s^{-1}$) [S/S11-12]	m/s
In14	Relative humidity (%) [S/S5-6 Weather Station]	%

Τα ιστορικά δεδομένα του φωτοβολταϊκού πάρκου της «Περδικούλας» διακρίνονται σε 62 κατηγορίες εισόδου, ενώ περιλαμβάνουν και την κατηγορία «Timestamp», από την οποία εξάγονται ο αριθμός της ημέρας του έτους (In1) και η χρονική στιγμή της ημέρας (In2) μετά από κατάλληλη επεξεργασία. Πέρα από τις δύο αυτές παραμέτρους εισόδου, αλλά και τη συνολική ενεργό ισχύ (In3), η σπουδαιότητα των υπόλοιπων παραμέτρων διερευνάται, αρχικά, υπολογίζοντας τον συντελεστή συσχέτισης Pearson μεταξύ της συνολικής ενεργού ισχύος και της εκάστοτε παραμέτρου (Ενότητα 4.2.1).

Στον Πίνακα 6.5 καταγράφονται οι μεταβλητές εισόδου που παρουσιάζουν την ισχυρότερη (θετική ή αρνητική) συσχέτιση με την ισχύ εξόδου συγκριτικά με αντίστοιχες μεταβλητές. Για παράδειγμα, η παράμετρος εισόδου In12 αναφέρεται στις μετρήσεις περιβαλλοντικής θερμοκρασίας του μετεωρολογικού σταθμού S/S11-12, οι οποίες παρουσιάζουν ισχυρότερη με τη συνολική ενεργό ισχύ συσχέτιση έναντι των υπόλοιπων διαθέσιμων μετρήσεων που αφορούν τη θερμοκρασία του περιβάλλοντος. Παράλληλα, ορισμένες μετεωρολογικές παράμετροι, όπως ο υετός και η κατεύθυνση του ανέμου, εμφανίζουν σταθερά πολύ ασθενή συσχέτιση με την ισχύ εξόδου. Επομένως, κρίνεται ότι οι συγκεκριμένες κατηγορίες εισόδου δεν χρήζουν περαιτέρω διερεύνησης.

Έτσι, στον Πίνακα 6.5 ορίζονται οι μεταβλητές εισόδου που χρησιμοποιούνται κατά τις δοκιμές βελτιστοποίησης του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας», ενώ ο αριθμός των μεταβλητών αυτών καθορίζει, επίσης, το εύρος τιμών όσον αφορά τον αριθμό των νευρώνων εισόδου. Συγκεκριμένα, το μοντέλο MLP δοκιμάζεται για αριθμό νευρώνων εισόδου που κυμαίνεται από 3 (In1–In3) έως 14, καθώς στις υπόλοιπες υπερπαραμέτρους του μοντέλου αποδίδονται ενδεικτικές τιμές, οι οποίες παραμένουν σταθερές. Τα αποτελέσματα αυτών των δοκιμών παρουσιάζονται στον ακόλουθο πίνακα:

Πίνακας 6.6: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας»

A/A	Νευρόνες εισόδου	Παράμετροι εισόδου	Training set MAPE (%)	Validation set MAPE (%)	Test set MAPE (%)
1	3	In1–In3	6,87	7,42	11,17
2	4	In1–In3, In7	6,74	7,22	10,88
3	4	In1–In3, In6	6,94	7,45	11,17
4	4	In1–In4	6,85	7,38	11,05
5	4	In1–In3, In5	6,70	7,24	10,99
6	5	In1–In3, In5, In7	6,71	7,22	10,88
7	5	In1–In3, In6, In7	6,77	7,25	10,87
8	5	In1–In4, In7	6,81	7,27	10,95
9	5	In1–In3, In7, In10	6,55	7,03	10,41
10	6	In1–In5, In7	6,83	7,31	10,80
11	6	In1–In3, In5–In7	6,89	7,38	10,93
12	6	In1–In3, In5, In7, In10	6,57	7,03	10,38
13	6	In1–In3, In7, In10, In11	6,53	7,04	10,46
14	6	In1–In3, In7, In9, In10	6,55	7,02	10,36
15	7	In1–In7	6,94	7,45	11,20
16	7	In1–In5, In7, In10	6,82	7,26	10,61
17	7	In1–In3, In5, In7, In9, In10	6,58	7,01	10,20
18	7	In1–In3, In5, In7, In10, In11	6,54	7,03	10,49
19	8	In1–In3, In5, In7–In10	6,94	7,33	10,53
20	8	In1–In3, In5, In7, In9, In10, In13	6,51	6,98	10,23
21	9	In1–In3, In5, In7, In9, In10, In12, In13	6,58	7,04	10,34
22	9	In1–In3, In5, In7, In9, In10, In13, In14	6,62	7,07	10,27
23	12	In1–In7, In9, In10, In12–In14	6,55	7,00	10,23
24	13	In1–In10, In12–In14	6,54	6,99	10,09
25	14	In1–In14	6,43	6,90	10,14

Τα αποτελέσματα του Πίνακα 6.6 αφορούν νευρωνικά δίκτυα του μοντέλου MLP τα οποία εκπαιδεύονται χρησιμοποιώντας ιστορικά δεδομένα τόσο του έτους 2020 όσο και του έτους 2019. Τα αποτελέσματα της στήλης «Test set *MAPE* (%)» αντιστοιχούν στο εκάστοτε Mean *MAPE* που υπολογίζεται για τα 36 επιμέρους σύνολα ελέγχου του Πίνακα 6.1, ενώ οι τιμές που καταγράφονται στις στήλες «Training set *MAPE* (%)» και «Validation set *MAPE* (%)» αφορούν τα σύνολα εκπαίδευσης και επικύρωσης που κατασκευάστηκαν σύμφωνα με τον τρόπο που περιγράφηκε στην Ενότητα 6.1. Παράλληλα, στις συγκεκριμένες στήλες σημειώνονται με έντονη γραμματοσειρά οι τιμές που αντιστοιχούν στη βέλτιστη διαμόρφωση του νευρωνικού δικτύου, δηλαδή οι ελάχιστες τιμές του *MAPE* για κάθε εξεταζόμενο σύνολο. Πρέπει, επίσης, να σημειωθεί ότι στην παρούσα διπλωματική εργασία, κάθε δοκιμή μιας συγκεκριμένης διαμόρφωσης η οποία πραγματοποιείται στο πλαίσιο της μεθόδου «Trial and Error» επαναλαμβάνεται συνολικά τρεις (3) φορές, με το αποτέλεσμα της εκάστοτε δοκιμής να προκύπτει ως ο μέσος όρος των τριών επιμέρους δοκιμών.

Σύμφωνα με τον Πίνακα 6.6, ο βέλτιστος συνδυασμός παραμέτρων εισόδου περιλαμβάνει το σύνολο των στοιχείων του Πίνακα 6.5 και, αντίστοιχα, ο βέλτιστος αριθμός νευρώνων εισόδου είναι 14. Παρά το γεγονός ότι η δοκιμή με A/A 24 – κατά την οποία χρησιμοποιούνται όλες οι επιλεγμένες παράμετροι εισόδου, εκτός από τη συνολική άεργο ισχύ – παρουσιάζει τη χαμηλότερη τιμή *MAPE* όσον αφορά το σύνολο ελέγχου, η διαμόρφωση που επιλέγεται ως βέλτιστη αντιστοιχεί στη δοκιμή με A/A 25, για την οποία καταγράφεται η ελάχιστη τιμή *MAPE* για το σύνολο επικύρωσης. Έτσι, σε όλες τις δοκιμές βελτιστοποίησης που ακολουθούν, ο αριθμός των νευρώνων εισόδου παραμένει σταθερός και ίσος με 14, ενώ κάθε νευρώνας εισόδου αντιπροσωπεύει μία κατηγορία εισόδου του Πίνακα 6.5.

Η επόμενη υπερπάρμετρος που εξετάστηκε είναι ο αριθμός των κρυφών νευρώνων του δικτύου, οι οποίοι συγκροτούνται σε ένα κρυφό στρώμα. Η αναζήτηση του βέλτιστου αριθμού κρυφών νευρώνων πραγματοποιείται στο διάστημα [1, 30] με βήμα 1. Συγκεκριμένα, ο αριθμός των κρυφών νευρώνων του δικτύου (N_h) ορίζεται ως μεταβλητή του μοντέλου MLP, ώστε οι απαιτούμενες διαδικασίες εκπαίδευσης, επικύρωσης και ελέγχου του δικτύου να υλοποιούνται αυτόματα για $N_h = 1, 2, \dots, 30$. Η αυτοματοποιημένη αυτή διαδικασία βασίζεται στη χρήση ενός βρόχου επανάληψης, μέσω του οποίου υλοποιείται η εκπαίδευση και η αξιολόγηση ενός νευρωνικού δικτύου, καθώς και η εξαγωγή των αποτελεσμάτων που αφορούν την αντίστοιχη διαμόρφωση υπερπαραμέτρων, για κάθε τιμή του N_h . Η διαδικασία αυτή επαναλαμβάνεται τρεις (3) φορές, με τα αποτελέσματα που αντιστοιχούν σε κάθε διαμόρφωση να προκύπτουν ως μέσος όρος των επιμέρους αυτών δοκιμών. Τα αποτελέσματα αυτά καταγράφονται στον Πίνακα 6.7.

Ωστόσο, οι τιμές του N_h για τις οποίες υπολογίζονται οι ελάχιστες τιμές του μετρικού *MAPE* αναφορικά με τα σύνολα εκπαίδευσης, επικύρωσης και ελέγχου είναι τιμές οι οποίες βρίσκονται κοντά στο δεξιό άκρο του διαστήματος που εξετάζεται ($N_h = 27, 28, 29$). Το γεγονός αυτό υποδηλώνει την ενδεχόμενη ύπαρξη καλύτερων τιμών, δηλαδή τιμών για τις οποίες μειώνεται το σφάλμα πρόβλεψης, πέρα από το συγκεκριμένο σύνολο του διαστήματος. Επομένως, προτείνεται [21] η περαιτέρω αναζήτηση της βέλτιστης τιμής της συγκεκριμένης υπερπαραμέτρου σε τιμές πέρα από αυτό το σύνολο. Έτσι, διενεργούνται επιπρόσθετες δοκιμές για το διάστημα [31, 35] με βήμα 1, τα αποτελέσματα των οποίων παρουσιάζονται, επίσης, στον Πίνακα 6.7:

Πίνακας 6.7: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων του κρυφού στρώματος του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας»

N_h	Training set <i>MAPE</i> (%)	Validation set <i>MAPE</i> (%)	Test set <i>MAPE</i> (%)
1	12,83	13,03	18,06
2	7,76	8,05	11,84
3	7,13	7,71	10,93
4	7,11	7,66	10,59
5	7,01	7,58	10,55
6	6,98	7,52	10,36
7	6,80	7,32	10,66
8	6,70	7,20	10,52
9	6,79	7,27	10,38
10	6,56	7,04	10,14
11	6,57	7,02	10,17
12	6,53	6,99	10,19
13	6,57	7,00	10,15
14	6,60	7,05	10,14
15	6,59	7,04	10,18
16	6,51	6,98	10,20
17	6,50	6,97	10,11
18	6,52	6,97	10,12
19	6,47	6,92	10,19
20	6,45	6,91	10,08
21	6,50	6,94	10,05
22	6,52	6,95	10,08
23	6,46	6,89	10,04
24	6,44	6,91	10,04
25	6,61	7,05	10,06
26	6,51	6,98	10,11
27	6,42	6,88	10,06
28	6,42	6,87	10,03
29	6,42	6,87	10,10
30	6,56	7,02	10,24
31	6,47	6,93	10,02
32	6,53	6,96	9,98
33	6,51	6,97	10,07
34	6,57	7,03	10,08
35	6,59	7,02	9,95

Σύμφωνα με τα αποτελέσματα του Πίνακα 6.7, η αναζήτηση του βέλτιστου αριθμού κρυφών νευρώνων στο διάστημα [31, 35] οδήγησε στην εμφάνιση χαμηλότερων τιμών του *MAPE*, η οποία, ωστόσο, περιορίστηκε στο σύνολο ελέγχου. Επομένως, η διαμόρφωση που κρίθηκε βέλτιστη περιλαμβάνει 28 κρυφούς νευρώνες, καθώς για τη διαμόρφωση αυτή καταγράφονται οι χαμηλότερες τιμές του *MAPE* στα training και validation sets, ενώ ταυτόχρονα καταγράφεται χαμηλότερη τιμή του *MAPE* για το σύνολο ελέγχου συγκριτικά με τη δοκιμή για $N_h = 29$. Έτσι, τα νευρωνικά δίκτυα που χρησιμοποιούνται κατά τις ακόλουθες δοκιμές βελτιστοποίησης διαθέτουν ένα κρυφό στρώμα το οποίο αποτελείται από 28 νευρώνες.

Η συνάρτηση ενεργοποίησης των νευρώνων αυτών αποτελεί, επίσης, αντικείμενο των δοκιμών βελτιστοποίησης του μοντέλου MLP. Η συνάρτηση ενεργοποίησης που εφαρμόζεται από τους νευρώνες του κρυφού στρώματος είναι μια μη γραμμική συνάρτηση, η οποία χρησιμοποιείται με σκοπό τη μοντελοποίηση μη γραμμικών συναρτήσεων. Στο πλαίσιο του περιβάλλοντος Jupyter Notebook, η σχεδίαση, η εκπαίδευση και η αξιολόγηση των νευρωνικών δικτύων που αναπτύσσονται πραγματοποιούνται με τη συμβολή της διεπαφής προγραμματισμού εφαρμογών (application programming interface – API) Keras [60]. Η διεπαφή Keras διαθέτει πλήθος ενσωματωμένων συναρτήσεων ενεργοποίησης, οι οποίες μπορούν να χρησιμοποιηθούν στο κρυφό στρώμα που κατασκευάζεται. Στην παρούσα διπλωματική εργασία, εξετάζεται η πλειονότητα των ενσωματωμένων αυτών συναρτήσεων, ενώ τα αποτελέσματα των αντίστοιχων δοκιμών παρουσιάζονται στον Πίνακα 6.8.

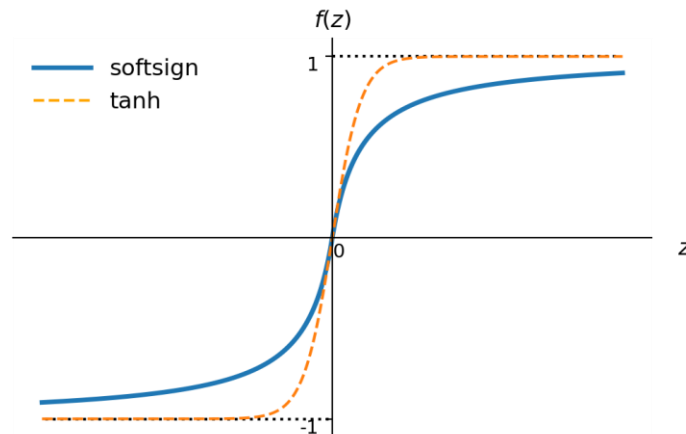
Βάσει των αποτελεσμάτων του Πίνακα 6.8, η συνάρτηση ενεργοποίησης που επιλέγεται για τους κρυφούς νευρώνες του δικτύου είναι η συνάρτηση softsign (Σχήμα 6.2), η οποία ορίζεται ως εξής:

$$f(z) \equiv \text{softsign}(z) = \frac{z}{|z|+1} \quad (6.1)$$

Παρά το γεγονός ότι για τη συνάρτηση ενεργοποίησης υπερβολικής εφαιτομένης (tanh) υπολογίζεται οριακά χαμηλότερη τιμή του μετρικού *MAPE* όσον αφορά το σύνολο επικύρωσης, συγκριτικά με τη συνάρτηση softsign, η αντίστοιχη τιμή που υπολογίζεται για το σύνολο ελέγχου είναι σημαντικά μεγαλύτερη. Επομένως, ως βέλτιστη συνάρτηση ενεργοποίησης επιλέγεται η συνάρτηση softsign, η οποία έχει παρόμοιο σχήμα με τη σιγμοειδή συνάρτηση.

Πίνακας 6.8: Δοκιμές βελτιστοποίησης όσον αφορά τη συνάρτηση ενεργοποίησης των κρυφών νευρώνων του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας»

Συνάρτηση ενεργοποίησης	Training set <i>MAPE</i> (%)	Validation set <i>MAPE</i> (%)	Test set <i>MAPE</i> (%)
ReLU	6,57	7,02	10,06
Sigmoid	6,71	7,21	10,39
Softplus	6,82	7,24	10,47
Softsign	6,51	6,96	9,91
Tanh	6,53	6,95	10,06
ELU	6,65	7,11	10,41
Exponential	6,63	7,08	10,23



Σχήμα 6.2: Η συνάρτηση ενεργοποίησης softsign

Ωστόσο, σε αντίθεση με τη σιγμοειδή συνάρτηση, η συνάρτηση softsign λαμβάνει τιμές στο εύρος $(-1, 1)$ και όχι στο $(0, 1)$. Επομένως, ενδεχόμενες αρνητικές τιμές εισόδου της συνάρτησης softsign μπορούν να χαρτογραφηθούν σε αρνητικές τιμές εξόδου, ενώ τιμές εισόδου οι οποίες προσεγγίζουν το μηδέν (0) μπορούν, επίσης, να χαρτογραφηθούν σε αντίστοιχες τιμές εξόδου κοντά στο μηδέν [61]. Παράλληλα, η συνάρτηση ενεργοποίησης softsign είναι πιο ομαλή συγκριτικά με τη συνάρτηση υπερβολικής εφαπτομένης, όπως φαίνεται στο Σχήμα 6.2, χαρακτηριστικό που συμβάλλει στην αύξηση της ταχύτητας όσον αφορά τη διαδικασία της εκπαίδευσης, καθώς το πρόβλημα της εξαφανιζόμενης κλίσης (vanishing gradient problem) εμφανίζεται με μικρότερη ένταση.

Στη συνέχεια, χρησιμοποιώντας τη συνάρτηση softsign ως συνάρτηση ενεργοποίησης των κρυφών νευρώνων, αναζητείται ο κατάλληλος αλγόριθμος βελτιστοποίησης (optimizer) της διαδικασίας εκπαίδευσης του νευρωνικού δικτύου. Ο αλγόριθμος βελτιστοποίησης καθορίζει τον τρόπο αναπροσαρμογής των ελεύθερων παραμέτρων του δικτύου, στοχεύοντας στην ελαχιστοποίηση της αντικειμενικής συνάρτησης που έχει επιλεγεί (MAPE). Ο πιο διαδεδομένος αλγόριθμος βελτιστοποίησης είναι η κατάβαση κλίσης (gradient descent), η οποία εφαρμόζεται και στο πλαίσιο του αλγορίθμου backpropagation.

Η αναπροσαρμογή των συναπτικών βαρών και των πολώσεων ενός νευρωνικού δικτύου μπορεί να πραγματοποιηθεί είτε αφού το δίκτυο επεξεργαστεί το σύνολο των δεδομένων εκπαίδευσης (batch learning) είτε αφότου επεξεργαστεί ένα (1) δείγμα ή έναν συγκεκριμένο αριθμό δειγμάτων (online learning), ο οποίος καθορίζεται από την τιμή της υπερπαραμέτρου mini-batch size. Όταν ο αλγόριθμος κατάβασης κλίσης εφαρμόζεται στο πλαίσιο της online μάθησης, όπως στην παρούσα διπλωματική εργασία, αναφέρεται ως στοχαστική κατάβαση κλίσης (stochastic gradient descent – SGD), καθώς ο τυχαίος τρόπος παρουσίασης των δειγμάτων του training set στο νευρωνικό δίκτυο καθιστά την αναζήτηση στον πολυδιάστατο χώρο των ελεύθερων παραμέτρων μια στοχαστική διαδικασία [3].

Στις δοκιμές που διενεργήθηκαν με σκοπό τον προσδιορισμό του βέλτιστου optimizer εξετάστηκε το σύνολο των διαθέσιμων αλγορίθμων βελτιστοποίησης της διεπαφής Keras, ενώ κατά τις δοκιμές οι υπερπαραμέτροι κάθε αλγορίθμου διατήρησαν τις πρότυπες τιμές τους. Τα αποτελέσματα των δοκιμών αυτών παρουσιάζονται στον ακόλουθο πίνακα:

Πίνακας 6.9: Δοκιμές βελτιστοποίησης όσον αφορά τον αλγόριθμο βελτιστοποίησης του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας»

Optimizer	Training set <i>MAPE</i> (%)	Validation set <i>MAPE</i> (%)	Test set <i>MAPE</i> (%)
SGD	6,45	6,92	9,96
RMSprop	6,44	6,88	10,04
Adam	6,35	6,81	9,90
Adadelta	15,80	16,37	15,77
Adagrad	12,85	13,55	13,46
Adamax	6,54	7,00	10,23
Nadam	6,36	6,83	9,93
Ftrl	14,10	14,66	13,99

Σύμφωνα με τα αποτελέσματα του Πίνακα 6.9, το μοντέλο MLP παρουσιάζει βέλτιστη συμπεριφορά, όταν εκπαιδεύεται κάνοντας χρήση του optimizer Adam, καθώς για τον συγκεκριμένο αλγόριθμο βελτιστοποίησης υπολογίζονται οι ελάχιστες τιμές του μετρικού *MAPE* και για τα τρία σύνολα δεδομένων που εξετάζονται. Συγκριτικά με τον βέλτιστο optimizer, οι αλγόριθμοι Nadam και SGD παρουσιάζουν παραπλήσια συμπεριφορά, ενώ οι Adagrad, Ftrl και Adadelta παρουσιάζουν σημαντικά υψηλότερες τιμές *MAPE*.

Ο αλγόριθμος Adam [62] είναι μία μέθοδος στοχαστικής βελτιστοποίησης η οποία βασίζεται στην κλίση της αντικειμενικής συνάρτησης, καθώς αποτελεί παραλλαγή του αλγορίθμου SGD. Ωστόσο, σε αντίθεση με τον αλγόριθμο στοχαστικής κατάβασης κλίσης, ο οποίος εφαρμόζει τον ίδιο ρυθμό μάθησης σε όλες τις ελεύθερες παραμέτρους, η μέθοδος Adam υπολογίζει ρυθμούς μάθησης προσαρμοσμένους σε κάθε ελεύθερη παράμετρο του δικτύου. Συγκεκριμένα, η μέθοδος αυτή υπολογίζει εκθετικά φθίνοντες κινητούς μέσους όρους της κλίσης αλλά και του τετραγώνου της κλίσης, καθώς οι υπερπαραμέτροι βελτιστοποίησης $\beta_1, \beta_2 \in [0, 1)$ ελέγχουν τους εκθετικούς ρυθμούς εξασθένισης των κινητών μέσων όρων. Οι κινητοί μέσοι όροι που υπολογίζονται αποτελούν εκτιμήσεις της $1^{ης}$ ροπής (μέση τιμή) και της $2^{ης}$ μη κεντρικής ροπής (μη κεντραρισμένη διακύμανση) της κλίσης και χρησιμοποιούνται για την ανανέωση των ελεύθερων παραμέτρων του δικτύου.

Όσον αφορά τις υπόλοιπες υπερπαραμέτρους σχεδίασης του νευρωνικού δικτύου, τα ιστορικά δεδομένα του φωτοβολταϊκού πάρκου της «Περδικούλας» αρχικά κανονικοποιούνται ανά κατηγορία εισόδου στο διάστημα $[0, 1]$, όπως ορίζεται στην εξίσωση (4.1). Παράλληλα, όλα τα νευρωνικά δίκτυα που υλοποιούνται στο πλαίσιο της παρούσας διπλωματικής εργασίας είναι πλήρως διασυνδεδεμένα, αφού δεν εφαρμόζεται κάποιος αλγόριθμος κλαδέματος. Επομένως, οι δοκιμές βελτιστοποίησης του μοντέλου MLP που διενεργούνται στη συνέχεια αφορούν τον αλγόριθμο βελτιστοποίησης που επιλέχθηκε, αλλά και τη διαδικασία της εκπαίδευσης γενικότερα. Η πρώτη υπερπάρμετρος που εξετάζεται είναι ο ρυθμός μάθησης που ορίζεται για τον αλγόριθμο Adam, ενώ ακολουθούν ο αριθμός των εποχών και η τιμή του mini-batch size. Τα αποτελέσματα των δοκιμών που αφορούν τον ρυθμό μάθησης καταγράφονται στον Πίνακα 6.10:

Πίνακας 6.10: Δοκιμές βελτιστοποίησης όσον αφορά τον ρυθμό μάθησης του αλγορίθμου βελτιστοποίησης του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας»

Ρυθμός μάθησης	Training set MAPE (%)	Validation set MAPE (%)	Test set MAPE (%)
0,0005	6,43	6,89	10,08
0,0010	6,40	6,87	9,90
0,0015	6,31	6,78	9,81
0,0020	6,35	6,80	9,87
0,0025	6,37	6,82	9,88

Η αναζήτηση του βέλτιστου αριθμού εποχών πραγματοποιείται στο διάστημα τιμών [200, 400] με βήμα 50, για ρυθμό μάθησης ίσο με 0,0015. Δεδομένου ότι τα αποτελέσματα που προέκυψαν για τις τιμές 300 και 400 είναι σχεδόν ίδια, η βελτιστοποίηση της υπερπαραμέτρου mini-batch size πραγματοποιείται και για τις δύο παραπάνω τιμές. Η βέλτιστη τιμή του mini-batch size αναζητείται μεταξύ των τιμών 32, 48 και 64, ενώ με βάση τα αποτελέσματα των συγκεκριμένων δοκιμών, η βέλτιστη διαμόρφωση του νευρωνικού δικτύου αφορά 300 εποχές μάθησης για mini-batch size ίσο με 32. Οι τιμές των μετρικών MAPE που υπολογίστηκαν για τη συγκεκριμένη διαμόρφωση είναι 6,27%, 6,73% και 9,63% για τα σύνολα εκπαίδευσης, επικύρωσης και ελέγχου, αντίστοιχα.

Η διενέργεια των παραπάνω δοκιμών συνιστά την ολοκλήρωση της διαδικασίας βελτιστοποίησης των συγκεκριμένων υπερπαραμέτρων του νευρωνικού δικτύου του μοντέλου MLP με τη μέθοδο «Trial and Error». Η βέλτιστη διαμόρφωση στην οποία κατέληξαν όλες οι προηγούμενες δοκιμές παρουσιάζεται συνοπτικά στον Πίνακα 6.11. Στον Πίνακα 6.11 καταγράφονται, επίσης, οι τιμές του μετρικού MAPE που αντιστοιχούν στη βέλτιστη αυτή διαμόρφωση.

Πίνακας 6.11: Βέλτιστες τιμές υπερπαραμέτρων του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας», μέθοδος «Trial and Error»

Νευρώνες εισόδου	14
Νευρώνες κρυφού στρώματος	28
Συνάρτηση ενεργοποίησης κρυφού στρώματος	Softsign
Αλγόριθμος βελτιστοποίησης	Adam
Ρυθμός μάθησης	0,0015
Αριθμός εποχών	300
Mini-batch size	32
Training set MAPE (%)	6,27
Validation set MAPE (%)	6,73
Test set MAPE (%)	9,63

Στη συνέχεια, θεωρώντας δεδομένες τις τιμές των υπερπαραμέτρων του Πίνακα 6.11, διερευνάται εάν η βέλτιστη διαμόρφωση του νευρωνικού δικτύου μπορεί να παρουσιάσει ακόμα καλύτερη συμπεριφορά, εφόσον μεταβληθεί το πλήθος ή ο τρόπος προεπεξεργασίας των χρησιμοποιούμενων ιστορικών δεδομένων. Όσον αφορά την προεπεξεργασία των διαθέσιμων ιστορικών δεδομένων, αξιολογείται η συμπεριφορά του μοντέλου MLP όταν οι χρονικές μεταβλητές εισόδου DoY και t κανονικοποιούνται με τη χρήση όρων ημιτόνου και συνημίτονου ως εξής [63]:

$$V_{d,1} = \sin\left(d \cdot \frac{2\pi}{Year\ length}\right); \quad V_{d,2} = \cos\left(d \cdot \frac{2\pi}{Year\ length}\right) \quad (6.2)$$

$$V_{t,1} = \sin\left(t \cdot \frac{2\pi}{t_{\max}}\right); \quad V_{t,2} = \cos\left(t \cdot \frac{2\pi}{t_{\max}}\right) \quad (6.3)$$

όπου d είναι ο αριθμός της ημέρας του έτους (DoY), $Year\ length$ είναι η διάρκεια του έτους (365 ημέρες ή 366 ημέρες για δίσεκτο έτος), t είναι η χρονική στιγμή της ημέρας και t_{\max} είναι η μέγιστη χρονική στιγμή συναρτήσεως της χρονικής ανάλυσης (96 ή 1440).

Οι νέες μεταβλητές εισόδου $V_{d,1}$, $V_{d,2}$, $V_{t,1}$ και $V_{t,2}$ αντικαθιστούν τις παραμέτρους DoY και t , οπότε το στρώμα εισόδου του νευρωνικού δικτύου περιλαμβάνει, πλέον, δύο (2) επιπλέον νευρώνες. Παράλληλα, οι υπόλοιπες κατηγορίες εισόδου του Πίνακα 6.5 κανονικοποιούνται και πάλι σύμφωνα με την εξίσωση (4.1), ενώ η εκπαίδευση και η αξιολόγηση του συγκεκριμένου νευρωνικού δικτύου πραγματοποιείται συνολικά τρεις φορές. Το μέσο $MARE$ που υπολογίζεται σε αυτές τις δοκιμές είναι 5,96%, 6,48% και 10,03% για τα σύνολα εκπαίδευσης, επικύρωσης και ελέγχου, αντίστοιχα.

Συγκριτικά με τις τιμές του Πίνακα 6.11, ο νέος τρόπος κανονικοποίησης των δεδομένων εισόδου οδήγησε μεν σε μείωση του μετρικού σφάλματος για τα σύνολα εκπαίδευσης και επικύρωσης, αλλά σε αύξηση του $MARE$ για το σύνολο ελέγχου. Η αύξηση αυτή ενδεχομένως οφείλεται σε υπερπροσαρμογή του μοντέλου στα δεδομένα επικύρωσης, η οποία μπορεί να αντιμετωπιστεί με χρήση της μεθόδου early stopping. Πρέπει, επίσης, να σημειωθεί ότι ως συνάρτηση ενεργοποίησης του στρώματος εξόδου χρησιμοποιείται, σε κάθε δοκιμή, η σιγμοειδής συνάρτηση, αφού σε κάθε περίπτωση η συνολική ενεργός ισχύς, η οποία αποτελεί την έξοδο του δικτύου, κανονικοποιείται στο διάστημα $[0, 1]$.

Η συμπεριφορά του μοντέλου αξιολογείται, επίσης, για την περίπτωση που τα διαθέσιμα ιστορικά δεδομένα χρησιμοποιούνται ως έχουν, δηλαδή χωρίς προεπεξεργασία. Για τη διεξαγωγή των συγκεκριμένων δοκιμών, ως συναρτήσεις ενεργοποίησης του κρυφού στρώματος και του στρώματος εξόδου ορίστηκαν οι συναρτήσεις ReLU και linear αντίστοιχα, καθώς οι συναρτήσεις αυτές δεν είναι (άνω) φραγμένες. Η συγκεκριμένη διαμόρφωση οδήγησε σε σημαντική αύξηση των υπολογιζόμενων μετρικών σφάλματος, αύξηση που πιστοποιεί τη σπουδαιότητα της προεπεξεργασίας των δεδομένων.

Τέλος, διερευνάται η επίδραση του πλήθους των ιστορικών δεδομένων που χρησιμοποιούνται στη συμπεριφορά του δικτύου. Σε όλες τις προηγούμενες δοκιμές, η εκπαίδευση και η αξιολόγηση των νευρωνικών δικτύων υλοποιήθηκε για το σύνολο των διαθέσιμων ιστορικών δεδομένων του φωτοβολταϊκού πάρκου της «Περδικούλας», δηλαδή

χρησιμοποιήθηκαν τα ιστορικά δεδομένα των ετών 2019 και 2020. Έτσι, πλέον διερευνάται η συμπεριφορά του δικτύου για χρήση ιστορικών δεδομένων που αφορούν αποκλειστικά το έτος 2020, όπου οι χρονικές μεταβλητές κανονικοποιήθηκαν βάσει της νέας μεθόδου κανονικοποίησης (sin/cos). Οι τιμές των Training set *MAPE*, Validation set *MAPE* και Test set *MAPE* που υπολογίστηκαν για τη συγκεκριμένη διαμόρφωση είναι 5,82%, 6,29% και 10,10% αντίστοιχα. Επομένως, η διαμόρφωση αυτή βελτιώνει την απόδοση του μοντέλου MLP για τα σύνολα εκπαίδευσης και επικύρωσης, ενώ οδηγεί σε μικρή αύξηση της τιμής του *MAPE* που υπολογίζεται για το σύνολο ελέγχου. Δεδομένου ότι η συμπεριφορά του μοντέλου για τα δεδομένα επικύρωσης αποτελεί το κυριότερο κριτήριο όσον αφορά την επιλογή της βέλτιστης τιμής μιας παραμέτρου, η τελευταία αυτή διαμόρφωση επιλέγεται ως η βέλτιστη διαμόρφωση του μοντέλου MLP για το φωτοβολταϊκό πάρκο της «Περδικούλας».

6.2.2 Φωτοβολταϊκό πάρκο «Lamprini» – Πρόβλεψη ανά 15 λεπτά

Η αναζήτηση ενός βέλτιστου μοντέλου MLP το οποίο παράγει προβλέψεις για το φωτοβολταϊκό πάρκο «Lamprini» σε χρονικό ορίζοντα 225 λεπτών με βήμα τα 15 λεπτά αποσκοπεί στη σύγκριση της απόδοσής του με το βέλτιστο μοντέλο της Ενότητας 6.2.1 για το φωτοβολταϊκό πάρκο της «Περδικούλας». Επομένως, τα νευρωνικά δίκτυα που εκπαιδεύονται και αξιολογούνται στην παρούσα Ενότητα χρησιμοποιούν, αποκλειστικά, ιστορικά δεδομένα του έτους 2020 για το πάρκο «Lamprini». Ταυτόχρονα, το σύνολο ελέγχου που χρησιμοποιείται για την αξιολόγηση της ικανότητας γενίκευσης των δικτύων αυτών (Πίνακας 6.2) είναι παρεμφερές με το σύνολο ελέγχου του Πίνακα 6.1, το οποίο αφορά το πάρκο της «Περδικούλας».

Η διαδικασία βελτιστοποίησης των υπερπαραμέτρων του μοντέλου πρόβλεψης MLP, όταν αυτό εφαρμόζεται στο φωτοβολταϊκό πάρκο «Lamprini» παράγοντας προβλέψεις ανά 15 λεπτά, ξεκινά με τον προσδιορισμό των καταλληλότερων μεταβλητών εισόδου. Οι κατηγορίες εισόδου που είναι διαθέσιμες για το πάρκο «Lamprini», είτε η πρόβλεψη παράγεται ανά 1 είτε ανά 15 λεπτά, παρουσιάζονται στον Πίνακα 6.12:

Πίνακας 6.12: Δεδομένα εισόδου νευρωνικών δικτύων για το φωτοβολταϊκό πάρκο «Lamprini»

Κωδική Ονομασία	Πλήρης Ονομασία	Μονάδες Μέτρησης
In1	Day of Year – DoY	-
In2	t	-
In3	Power (Meter) (1m) (kW) [PCC]	kW
In4	Reactive Power (Meter) (1m) (kVAr) [PCC]	kVAr
In5	Inclined Irradiance (1m) ($W \cdot m^{-2}$) [Weather Station]	W/m^2
In6	Inclined Irradiance 2 (1m) ($W \cdot m^{-2}$) [Weather Station]	W/m^2
In7	Ambient Temperature (1m) (C) [Weather Station]	°C
In8	Precipitation (1m) (mm/h) [Weather Station]	mm/h
In9	Relative Humidity (1m) (%) [Weather Station]	%

Πίνακας 6.12: Δεδομένα εισόδου νευρωνικών δικτύων για το φωτοβολταϊκό πάρκο «Lampirini» (συνέχεια)

Κωδική Ονομασία	Πλήρης Ονομασία	Μονάδες Μέτρησης
In10	Wind Direction (1m) (degrees) [Weather Station]	°
In11	Wind Speed (1m) ($m*s^{-1}$) [Weather Station]	m/s
In12	Module Temperature 1 (1m) (C) [Weather Station]	°C
In13	Module Temperature 2 (1m) (C) [Weather Station]	°C

Επομένως, το μοντέλο MLP δοκιμάζεται για αριθμό νευρώνων εισόδου που κυμαίνεται από 3 (In1–In3) έως 13 καθώς οι τιμές των λοιπών υπερπαραμέτρων του διατηρούνται σταθερές. Τα αποτελέσματα των συγκεκριμένων δοκιμών καταγράφονται στον ακόλουθο πίνακα:

Πίνακας 6.13: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου MLP για το φωτοβολταϊκό πάρκο «Lampirini» και χρονικό ορίζοντα πρόβλεψης 225 λεπτά

A/A	Νευρώνες εισόδου	Παράμετροι εισόδου	Training set MAPE (%)	Validation set MAPE (%)	Test set MAPE (%)
1	3	In1–In3	9,35	8,75	11,11
2	4	In1–In3, In5	9,27	8,69	11,10
3	4	In1–In3, In6	9,27	8,71	11,04
4	4	In1–In4	9,31	8,70	10,92
5	4	In1–In3, In12	9,33	8,77	11,20
6	5	In1–In3, In5, In6	9,19	8,64	10,82
7	6	In1–In5, In12	9,25	8,74	11,18
8	6	In1–In3, In5, In6, In12	9,05	8,52	10,74
9	6	In1–In6	9,15	8,56	10,74
10	6	In1–In4, In6, In12	9,17	8,63	10,94
11	7	In1–In6, In12	9,04	8,46	10,63
12	7	In1–In3, In5–In7, In12	8,96	8,38	10,70
13	7	In1–In3, In5, In6, In12, In13	8,98	8,42	10,71
14	7	In1–In3, In5, In6, In9, In12	9,00	8,40	10,86
15	7	In1–In3, In5, In6, In11, In12	8,99	8,50	10,96
16	8	In1–In3, In5–In7, In12, In13	8,95	8,39	10,76
17	8	In1–In6, In12, In13	8,99	8,45	10,59

Πίνακας 6.13: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου MLP για το φωτοβολταϊκό πάρκο «Lampirini» και χρονικό ορίζοντα πρόβλεψης 225 λεπτά (συνέχεια)

A/A	Νευρώνες εισόδου	Παράμετροι εισόδου	Training set MAPE (%)	Validation set MAPE (%)	Test set MAPE (%)
18	8	In1–In3, In5, In6, In9, In12, In13	8,90	8,30	10,54
19	8	In1–In3, In5, In6, In11–In13	8,87	8,27	10,57
20	9	In1–In7, In12, In13	8,91	8,34	10,61
21	9	In1–In3, In5, In6, In9, In11, In12	8,84	8,26	10,70
22	10	In1–In3, In5–In7, In9, In11–In13	8,79	8,21	10,62
23	11	In1–In7, In9, In11–In13	8,91	8,27	10,65
24	12	In1–In7, In9–In13	8,73	8,21	10,43
25	12	In1–In9, In11–In13	8,80	8,20	10,61
26	13	In1–In13	8,76	8,21	10,44

Σύμφωνα με τα αποτελέσματα του Πίνακα 6.13, ο βέλτιστος αριθμός νευρώνων εισόδου του νευρωνικού δικτύου που παράγει προβλέψεις για το φωτοβολταϊκό πάρκο «Lampirini» σε χρονικό ορίζοντα 225 λεπτών είναι 12. Ο συνδυασμός παραμέτρων εισόδου που αντιστοιχεί στους 12 αυτούς νευρώνες προκύπτει από τη δοκιμή με A/A 24, για την οποία καταγράφονται οι ελάχιστες τιμές *MAPE* για τα σύνολα εκπαίδευσης και ελέγχου, ενώ η τιμή του μετρικού για το σύνολο επικύρωσης είναι μόλις 0,01% μεγαλύτερη από την ελάχιστη τιμή που υπολογίστηκε για το σύνολο των δοκιμών.

Μετά την επιλογή του βέλτιστου συνδυασμού παραμέτρων εισόδου, η διαδικασία που ακολουθείται για την εύρεση της βέλτιστης διαμόρφωσης όσον αφορά τις υπόλοιπες υπερπαραμέτρους του νευρωνικού δικτύου είναι ίδια με τη διαδικασία που ακολουθήθηκε στην Ενότητα 6.2.1 για το φωτοβολταϊκό πάρκο της «Περδικούλας». Οι βέλτιστες τιμές των υπερπαραμέτρων του δικτύου αναζητήθηκαν στα ίδια εύρη τιμών (εξαιρείται ο ρυθμός μάθησης), με τη διαμόρφωση που κρίθηκε βέλτιστη να παρουσιάζεται στον Πίνακα 6.14, όπου καταγράφονται, επίσης, οι αντίστοιχες τιμές του μετρικού *MAPE*.

Σε αντίθεση με το μοντέλο MLP που αναπτύχθηκε για το φωτοβολταϊκό πάρκο της «Περδικούλας», η υλοποίηση της προεπεξεργασίας των διαθέσιμων ιστορικών δεδομένων με διαφορετικό τρόπο – κανονικοποίηση των χρονικών μεταβλητών εισόδου χρησιμοποιώντας όρους ημιτόνου και συνημίτονου – δεν οδήγησε σε βελτίωση της συμπεριφοράς του νευρωνικού δικτύου, ενώ αύξησε σημαντικά και το σφάλμα γενίκευσης (Test set *MAPE*). Επομένως, η βέλτιστη διαμόρφωση περιλαμβάνει την κανονικοποίηση του συνόλου των δεδομένων εισόδου, ανά κατηγορία, στο διάστημα $[0, 1]$, κάνοντας χρήση της εξίσωσης (4.1).

Πίνακας 6.14: Βέλτιστη διαμόρφωση υπερπαραμέτρων του μοντέλου MLP για το φωτοβολταϊκό πάρκο «Lampirini» και χρονικό ορίζοντα πρόβλεψης 225 λεπτά, μέθοδος «Trial and Error»

Νευρώνες εισόδου	12
Νευρώνες κρυφού στρώματος	30
Συνάρτηση ενεργοποίησης κρυφού στρώματος	Softsign
Αλγόριθμος βελτιστοποίησης	Nadam
Ρυθμός μάθησης	0,0040
Αριθμός εποχών	500
Mini-batch size	32
Training set MAPE (%)	8,03
Validation set MAPE (%)	7,75
Test set MAPE (%)	9,02

Σύμφωνα με τα στοιχεία του Πίνακα 6.14, ο αλγόριθμος βελτιστοποίησης που κρίθηκε βέλτιστος για τη συγκεκριμένη εφαρμογή του μοντέλου MLP είναι ο Nadam. Ο αλγόριθμος βελτιστοποίησης Nadam [64] αποτελεί επέκταση της μεθόδου Adam, την οποία συνδυάζει με τον αλγόριθμο επιταχυνόμενης κλίσης του Nesterov (Nesterov's accelerated gradient – NAG ή Nesterov momentum). Έτσι, σε αντίθεση με τη μέθοδο Adam, η οποία περιλαμβάνει έναν κλασικό όρο ορμής, ο αλγόριθμος βελτιστοποίησης Nadam αξιοποιεί την ορμή Nesterov, η οποία θεωρητικά, αλλά πολλές φορές και πρακτικά, είναι ανώτερη της κλασικής ορμής. Στη συνέχεια, αναζητήθηκε η βέλτιστη τιμή του ρυθμού μάθησης του αλγορίθμου Nadam, με τη διεξαγωγή δοκιμών για τιμές από 0,0005 έως 0,0050 με βήμα 0,0005.

Πρέπει, επίσης, να σημειωθεί ότι σε κάθε δοκιμή βελτιστοποίησης η τιμή του μετρικού *MAPE* που υπολογίζεται για το σύνολο επικύρωσης είναι μικρότερη από την αντίστοιχη τιμή που αφορά το σύνολο εκπαίδευσης. Δεδομένου ότι το νευρωνικό δίκτυο μαθαίνει με βάση τα δεδομένα εκπαίδευσης, ενώ τα δεδομένα επικύρωσης χρησιμοποιούνται για την αξιολόγησή του και του είναι άγνωστα, οι χαμηλότερες τιμές του *MAPE* στο σύνολο επικύρωσης συνιστούν ένα απροσδόκητο αποτέλεσμα. Το απρόσμενο αυτό αποτέλεσμα μπορεί να οφείλεται στον τρόπο διαχωρισμού του συνόλου μάθησης σε σύνολα εκπαίδευσης και επικύρωσης (Ενότητα 6.1), καθώς ενδέχεται οι ημέρες που αποτελούν το σύνολο επικύρωσης να προσφέρονται για την παραγωγή προβλέψεων μεγαλύτερης ακρίβειας. Το ενδεχόμενο αυτό υποστηρίζεται από το γεγονός ότι τα δεδομένα επικύρωσης παρουσιάζουν μεγαλύτερη συσχέτιση με την ενεργό ισχύ εξόδου συγκριτικά με τα δεδομένα εκπαίδευσης, για την πλειονότητα των χρησιμοποιούμενων παραμέτρων εισόδου.

Έτσι, πραγματοποιούνται επιπρόσθετες δοκιμές βελτιστοποίησης του συγκεκριμένου νευρωνικού δικτύου για διαφορετικό τρόπο διαχωρισμού των δεδομένων του συνόλου μάθησης. Συγκεκριμένα, το σύνολο μάθησης ορίζεται ως σύνολο εκπαίδευσης και διενεργούνται δοκιμές βελτιστοποίησης με τη μέθοδο Grid Search, όπου η αξιολόγηση της

απόδοσης του μοντέλου πραγματοποιείται με χρήση της μεθόδου διασταυρούμενης επικύρωσης για $k = 4$. Επομένως, κάθε διαμόρφωση υπερπαραμέτρων δοκιμάζεται και αξιολογείται συνολικά 4 φορές, αφού σε κάθε επιμέρους δοκιμή χρησιμοποιείται ως σύνολο επικύρωσης ένα διαφορετικό υποσύνολο του συνόλου εκπαίδευσης (ή μάθησης), το οποίο περιλαμβάνει 25% των διαθέσιμων δεδομένων εκπαίδευσης.

Στο πλαίσιο της μεθόδου Grid Search, κατασκευάζεται ένα πλέγμα αναζήτησης από το οποίο προκύπτουν οι συνδυασμοί υπερπαραμέτρων που αξιολογούνται. Οι τιμές που επιλέχθηκαν για κάθε εξεταζόμενη υπερπαραμέτρο, με σκοπό τη δημιουργία του πλέγματος αναζήτησης, είναι οι τιμές για τις οποίες το μοντέλο πρόβλεψης παρουσίασε την καλύτερη συμπεριφορά στο πλαίσιο της μεθόδου «Δοκιμή και Σφάλμα». Συγκεκριμένα, επιλέχθηκαν οι τιμές 30 και 33 για τον αριθμό των κρυφών νευρώνων, «softsign» και «ReLU» για τη συνάρτηση ενεργοποίησης του κρυφού στρώματος, «SGD» και «Nadam» για τον αλγόριθμο βελτιστοποίησης, 350, 400 και 500 για τον αριθμό εποχών και 32, 48 και 64 για το mini-batch size.

Από το Καρτεσιανό γινόμενο των παραπάνω συνόλων τιμών προκύπτουν 72 διαφορετικοί συνδυασμοί υπερπαραμέτρων, ενώ για κάθε δυνατή διαμόρφωση το νευρωνικό δίκτυο εκπαιδεύεται και αξιολογείται 4 φορές. Επομένως, η εκπαίδευση και αξιολόγηση του δικτύου επαναλαμβάνεται συνολικά 288 φορές, γεγονός που καθιστά την εφαρμογή της μεθόδου αναζήτησης πλέγματος μια ιδιαίτερα χρονοβόρα διαδικασία. Η βέλτιστη διαμόρφωση που προέκυψε από τις συγκεκριμένες δοκιμές περιλαμβάνει τις τιμές 33, «ReLU», «Nadam», 32 και 400, ενώ οι αντίστοιχες τιμές *MAPE* που υπολογίζονται είναι 8,28%, 10,13% και 9,49% για τα σύνολα εκπαίδευσης, επικύρωσης και ελέγχου. Το *MAPE* που αφορά τα σύνολα εκπαίδευσης και επικύρωσης αποτελεί τη μέση τιμή των 4 επιμέρους δοκιμών που διενεργούνται για κάθε διαμόρφωση, ενώ το *MAPE* για το σύνολο ελέγχου υπολογίζεται και πάλι με βάση τα σύνολα του Πίνακα 6.2.

Στη συνέχεια, η μέθοδος Grid Search εφαρμόζεται εκ νέου, με σκοπό την αναζήτηση του βέλτιστου ρυθμού μάθησης του optimizer Nadam. Το νέο πλέγμα αναζήτησης που κατασκευάζεται περιλαμβάνει τις τιμές 350, 400 και 500 για τον αριθμό εποχών, 32, 48 και 64 για το mini-batch size και 0.0020, 0.0025, 0.0030, 0.0035, 0.0040, 0.0045 και 0.0050 για τον ρυθμό μάθησης. Η βέλτιστη διαμόρφωση που προέκυψε από τις συγκεκριμένες δοκιμές αφορά τις τιμές 500 για τον αριθμό εποχών, 48 για το mini-batch size και 0,0040 για τον ρυθμό μάθησης του αλγορίθμου Nadam.

Στον Πίνακα 6.15 παρουσιάζονται τα αποτελέσματα των δοκιμών της βέλτιστης αυτής διαμόρφωσης. Ενώ για τις 3 διαιρέσεις του συνόλου μάθησης Split 1, 2 και 4, αλλά και για τις μέσες τιμές Mean, το *MAPE* που υπολογίζεται για το σύνολο επικύρωσης είναι μεγαλύτερο συγκριτικά με το *MAPE* στο training set, για τη διαίρεση Split 3 το Validation set *MAPE* είναι σημαντικά χαμηλότερο σε σχέση με το Training set *MAPE*. Επομένως, η ακρίβεια της παραγόμενης πρόβλεψης του μοντέλου επηρεάζεται σημαντικά από τη μέθοδο διαχωρισμού που εφαρμόζεται στο σύνολο μάθησης. Όπως φαίνεται από τα αποτελέσματα του Πίνακα 6.15, η μέθοδος διασταυρούμενης επικύρωσης μπορεί να οδηγήσει σε μια πληρέστερη αξιολόγηση του μοντέλου πρόβλεψης, καθώς χρησιμοποιεί διαφορετικά σύνολα επικύρωσης για κάθε επιμέρους δοκιμή μιας συγκεκριμένης διαμόρφωσης υπερπαραμέτρων.

Πίνακας 6.15: Μετρικά σφάλματος του μοντέλου MLP για το φωτοβολταϊκό πάρκο «Lamprini» και χρονικό ορίζοντα 225 λεπτά, μέθοδος Grid Search με διασταυρούμενη επικύρωση για $k = 4$

Training set <i>MAPE</i> (%)					Validation set <i>MAPE</i> (%)				
Split 1	Split 2	Split 3	Split 4	Mean	Split 1	Split 2	Split 3	Split 4	Mean
7,68	7,33	9,35	7,66	8,00	10,62	10,38	4,62	11,95	9,39

6.2.3 Φωτοβολταϊκό πάρκο «Lamprini» – Πρόβλεψη ανά λεπτό

Όσον αφορά το φωτοβολταϊκό πάρκο «Lamprini», το μοντέλο MLP χρησιμοποιείται, επίσης, για την παραγωγή προβλέψεων σε χρονικό ορίζοντα 15 λεπτών με χρονικό βήμα το ένα (1) λεπτό. Αρχικά, επιχειρείται η βελτιστοποίηση του συγκεκριμένου μοντέλου πρόβλεψης χρησιμοποιώντας, αποκλειστικά, ιστορικά δεδομένα του έτους 2020, οπότε η ικανότητα γενίκευσης των νευρωνικών δικτύων που προσομοιώνονται αξιολογείται βάσει των επιμέρους συνόλων ελέγχου του Πίνακα 6.3.

Αναφορικά με τον τρόπο διαχωρισμού του συνόλου μάθησης, η διενέργεια ορισμένων προκαταρκτικών δοκιμών κατέδειξε ότι ο τρόπος διαχωρισμού που περιγράφεται στην Ενότητα 6.1 οδηγεί ξανά σε τιμές του Validation set *MAPE* οι οποίες είναι μικρότερες συγκριτικά με τις αντίστοιχες τιμές που υπολογίζονται για το σύνολο εκπαίδευσης. Επομένως, αναζητήθηκε ένας διαφορετικός τρόπος διαχωρισμού των δεδομένων του συνόλου μάθησης, ώστε να υλοποιηθούν οι απαιτούμενες δοκιμές βελτιστοποίησης στο πλαίσιο της μεθόδου «Trial and Error». Συγκεκριμένα, ο διαχωρισμός των δεδομένων σε σύνολα εκπαίδευσης και επικύρωσης πραγματοποιείται με τυχαίο τρόπο, ενώ παράλληλα υλοποιείται με τέτοιο τρόπο, ώστε τα σύνολα που προκύπτουν να μπορούν να αναπαραχθούν σε διαφορετικές προσομοιώσεις. Έτσι, καθίσταται δυνατή η σύγκριση των αποτελεσμάτων που προκύπτουν από διαφορετικές δοκιμές βελτιστοποίησης.

Η πρώτη υπερπαραμέτρος που εξετάζεται είναι και πάλι ο αριθμός των νευρώνων εισόδου. Οι κατηγορίες εισόδου που μπορούν να χρησιμοποιηθούν ορίζονται στον Πίνακα 6.12, ενώ τα αποτελέσματα των δοκιμών παρουσιάζονται στον Πίνακα 6.16. Παρά το γεγονός ότι τα σύνολα εκπαίδευσης και επικύρωσης επιλέγονται τυχαία, υπάρχουν δοκιμές για τις οποίες το *MAPE* στο validation set είναι οριακά μικρότερο από το *MAPE* στο training set, ενώ για πολλές δοκιμές οι τιμές αυτές είναι ίσες ή σχεδόν ίσες. Σύμφωνα με τα αποτελέσματα του Πίνακα 6.16, οι συνδυασμοί παραμέτρων εισόδου που μπορούν να θεωρηθούν βέλτιστοι αντιστοιχούν στις δοκιμές με A/A 11, 17 αλλά και 9. Ο συνδυασμός παραμέτρων που τελικά επιλέχθηκε είναι αυτός που αντιστοιχεί στη δοκιμή 11, καθώς για τον συγκεκριμένο συνδυασμό επιτυγχάνεται η ελάχιστη τιμή *MAPE* στο σύνολο επικύρωσης με τον μικρότερο αριθμό παραμέτρων εισόδου.

Πίνακας 6.16: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου MLP για το φωτοβολταϊκό πάρκο «Lampirini» και χρονικό ορίζοντα πρόβλεψης 15 λεπτά

A/A	Νευρώνες εισόδου	Παράμετροι εισόδου	Training set MAPE (%)	Validation set MAPE (%)	Test set MAPE (%)
1	3	In1–In3	3,70	3,68	3,98
2	4	In1–In3, In5	3,68	3,69	3,99
3	4	In1–In3, In6	3,68	3,69	3,97
4	4	In1–In4	3,69	3,67	3,99
5	4	In1–In3, In12	3,68	3,68	3,96
6	5	In1–In3, In5, In6	3,67	3,67	3,94
7	6	In1–In5, In12	3,66	3,66	3,98
8	6	In1–In3, In5, In6, In12	3,68	3,68	3,94
9	6	In1–In6	3,65	3,65	3,92
10	6	In1–In4, In6, In12	3,69	3,69	3,98
11	7	In1–In6, In12	3,64	3,64	3,94
12	7	In1–In3, In5–In7, In12	3,68	3,70	3,96
13	7	In1–In3, In5, In6, In12, In13	3,65	3,65	3,97
14	7	In1–In3, In5, In6, In9, In12	3,72	3,73	3,94
15	7	In1–In3, In5, In6, In11, In12	3,69	3,70	3,96
16	8	In1–In3, In5–In7, In12, In13	3,71	3,73	3,99
17	8	In1–In6, In12, In13	3,64	3,64	3,94
18	8	In1–In6, In9, In12	3,67	3,69	3,97
19	8	In1–In6, In11, In12	3,66	3,67	3,96
20	8	In1–In7, In12	3,69	3,71	3,98
21	9	In1–In7, In12, In13	3,69	3,71	3,99
22	9	In1–In6, In9, In12, In13	3,67	3,69	4,01
23	10	In1–In7, In9, In12, In13	3,73	3,75	4,09
24	11	In1–In7, In9, In11–In13	3,78	3,81	4,05
25	12	In1–In7, In9–In13	3,74	3,77	4,08
26	13	In1–In13	3,66	3,68	4,00

Στη συνέχεια, ακολουθείται η διαδικασία που περιγράφεται με το διάγραμμα ροής του Σχήματος 6.1, ώστε να προσδιοριστούν οι βέλτιστες τιμές των υπόλοιπων υπερπαραμέτρων του μοντέλου. Η αναζήτηση του βέλτιστου αριθμού κρυφών νευρώνων πραγματοποιείται στο διάστημα [1, 30] με βήμα 1, ενώ οι βέλτιστες τιμές της συνάρτησης ενεργοποίησης του κρυφού στρώματος, του αλγορίθμου βελτιστοποίησης και του αριθμού εποχών αναζητούνται στο ίδιο εύρος τιμών με τις προηγούμενες Ενότητες.

Αντίθετα, η βέλτιστη τιμή της υπερπαραμέτρου mini-batch size επιλέγεται μεταξύ των τιμών 128, 256, 512, 768 και 1024. Η σημαντική αύξηση που παρουσιάζουν οι εξεταζόμενες τιμές του mini-batch size οφείλεται στο γεγονός ότι τα διαθέσιμα ιστορικά δεδομένα είναι πολλαπλάσια συγκριτικά με τις προηγούμενες Ενότητες, καθώς έχουν χρονική ανάλυση ενός (1) λεπτού. Συγκεκριμένα, το παρόν μοντέλο πρόβλεψης που πραγματοποιεί πρόβλεψη για χρονικό ορίζοντα 15 λεπτών αξιοποιεί 165000 διανύσματα εισόδου για την εκπαίδευσή του, ενώ τα βέλτιστα μοντέλα πρόβλεψης για χρονικό ορίζοντα 225 λεπτών εκπαιδεύτηκαν με 7981 και 7677 διανύσματα εισόδου, όσον αφορά τα φωτοβολταϊκά πάρκα «Περδικούλα» και «Lampirini» αντίστοιχα.

Παράλληλα, επεκτάθηκε το εύρος τιμών στο οποίο αναζητείται η βέλτιστη τιμή του ρυθμού μάθησης του αλγορίθμου βελτιστοποίησης που επιλέχθηκε (Nadam). Η αναζήτηση της βέλτιστης τιμής του πραγματοποιήθηκε στο διάστημα [0.0005, 0.0100] με βήμα 0.0005, ενώ εξετάστηκαν και οι τιμές 0.0150, 0.0200, 0.0500 και 0.1000. Διερευνήθηκε, επίσης, η επίδραση άλλων τρόπων προεπεξεργασίας των ιστορικών δεδομένων στη συμπεριφορά του μοντέλου, χωρίς ωστόσο να παρατηρηθεί βελτίωση της απόδοσής του.

Στον Πίνακα 6.17 παρουσιάζεται η βέλτιστη διαμόρφωση του μοντέλου, η οποία προκύπτει από τη διενέργεια των παραπάνω δοκιμών, ενώ καταγράφονται και οι αντίστοιχες τιμές του μετρικού σφάλματος. Ταυτόχρονα, παρουσιάζεται και η βέλτιστη διαμόρφωση που προέκυψε από τη μέθοδο Grid Search, για πλέγματα αναζήτησης που κατασκευάστηκαν με γνώμονα τις δοκιμές της μεθόδου «Trial and Error».

Πίνακας 6.17: Βέλτιστη διαμόρφωση υπερπαραμέτρων του μοντέλου MLP για το φωτοβολταϊκό πάρκο «Lampirini» και χρονικό ορίζοντα πρόβλεψης 15 λεπτά

	«Trial and Error»	Grid Search
Νευρώνες εισόδου	7	7
Νευρώνες κρυφού στρώματος	24	21
Συνάρτηση ενεργοποίησης κρυφού στρώματος	Softsign	Tanh
Αλγόριθμος βελτιστοποίησης	Nadam	Adam
Ρυθμός μάθησης	0,020	0,005
Αριθμός εποχών	400	450
Mini-batch size	512	256
Training set MAPE (%)	3,59	3,52
Validation set MAPE (%)	3,59	3,63
Test set MAPE (%)	3,72	3,57

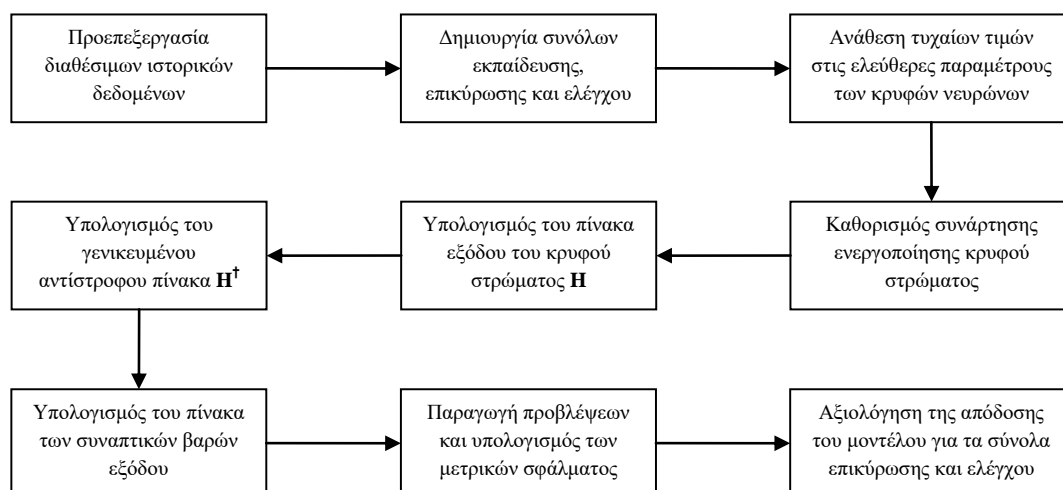
Τέλος, διερευνάται η απόδοση του μοντέλου MLP για ανά λεπτό πρόβλεψη στο φωτοβολταϊκό πάρκο «Lampirini», όταν το πλήθος των ιστορικών δεδομένων που χρησιμοποιούνται για την εκπαίδευση και την αξιολόγησή του επεκταθεί, ώστε να συμπεριλαμβάνει τα δεδομένα του έτους 2021. Συγκεκριμένα, η βέλτιστη διαμόρφωση του μοντέλου (Πίνακας 6.17, μέθοδος Grid Search) εκπαιδεύεται, αρχικά, κάνοντας χρήση των επιτρεπόμενων δεδομένων του έτους 2021. Στη συνέχεια, η διαδικασία της εκπαίδευσης επαναλαμβάνεται, περιλαμβάνοντας, πλέον, και τα δεδομένα του έτους 2020. Σε κάθε περίπτωση, η αξιολόγηση της απόδοσης του μοντέλου πραγματοποιείται για το αντίστοιχο σύνολο επικύρωσης, αλλά και για το σύνολο ελέγχου που ορίζεται στον Πίνακα 6.4.

Οι τιμές του μετρικού *MAPE* που υπολογίζονται όταν το νευρωνικό δίκτυο του μοντέλου MLP εκπαιδεύεται αποκλειστικά με δεδομένα του 2021 είναι 3,64%, 3,66% και 5,67% για τα σύνολα εκπαίδευσης, επικύρωσης και ελέγχου, αντίστοιχα. Οι αντίστοιχες τιμές που υπολογίζονται όταν το δίκτυο εκπαιδεύεται αξιοποιώντας ιστορικά δεδομένα τόσο του 2020 όσο και του 2021 είναι 3,65%, 3,60% και 5,68%. Η αύξηση του πλήθους των χρησιμοποιούμενων δεδομένων εκπαίδευσης, από 162303 σε 345703 διανύσματα εισόδου, έχει ως αποτέλεσμα μια μικρή μείωση όσον αφορά το Validation set *MAPE*. Ωστόσο, η μικρή αυτή μείωση δεν επαρκεί, ώστε να αντισταθμίσει τη σημαντική αύξηση που παρατηρείται στον απαιτούμενο χρόνο εκπαίδευσης ο οποίος σχεδόν διπλασιάζεται, καθώς αυξάνεται από 3' 16" σε 6' 22".

6.3 ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΤΟΥ ΜΟΝΤΕΛΟΥ ELM

Η διαδικασία που ακολουθείται με σκοπό την κατασκευή και την εκπαίδευση του μοντέλου ELM περιγράφεται σχηματικά με το διάγραμμα του Σχήματος 6.3. Σύμφωνα με το Σχήμα 6.3, η βελτιστοποίηση ενός νευρωνικού δικτύου που εκπαιδεύεται με τον αλγόριθμο ELM έγκειται, κατά κύριο λόγο, στη βέλτιστη επιλογή των παραμέτρων εισόδου του δικτύου, του αριθμού των κρυφών νευρώνων και της συνάρτησης ενεργοποίησης του κρυφού στρώματος. Μπορεί, επίσης, να διερευνηθεί η επιρροή που ασκούν στη συμπεριφορά του μοντέλου ο τρόπος προεπεξεργασίας των διαθέσιμων ιστορικών δεδομένων καθώς και ο τρόπος διαχωρισμού τους στα επιμέρους σύνολα.

Δεδομένου ότι ως συνάρτηση ενεργοποίησης του στρώματος εξόδου επιλέγεται η γραμμική συνάρτηση της εξίσωσης (5.8), η συνολική είσοδος του εκάστοτε νευρώνα εξόδου αποτελεί, ταυτόχρονα, την έξοδό του, δηλαδή αποτελεί την αντίστοιχη έξοδο του νευρωνικού δικτύου. Επομένως, η επιλογή της κατάλληλης συνάρτησης ενεργοποίησης του κρυφού στρώματος είναι ιδιαίτερα κρίσιμη. Στο πλαίσιο της παρούσας διπλωματικής εργασίας, οι τιμές της ενεργού ισχύος εξόδου κάθε εξεταζόμενου φωτοβολταϊκού πάρκου είναι, κατά κανόνα, κανονικοποιημένες στο διάστημα $[0, 1]$, με μόνη εξαίρεση τις δοκιμές που διενεργούνται χωρίς προεπεξεργασία των διαθέσιμων δεδομένων. Είναι, λοιπόν, επιθυμητό η συνάρτηση ενεργοποίησης του κρυφού στρώματος να περιορίζει την έξοδο των κρυφών νευρώνων στο συγκεκριμένο διάστημα. Έτσι, η πλειονότητα των διαθέσιμων συναρτήσεων ενεργοποίησης της διεπαφής Keras δεν ενδείκνυται για τη συγκεκριμένη εφαρμογή, γεγονός που πιστοποιείται μέσω δοκιμών. Η συνάρτηση που τελικά επιλέγεται ως συνάρτηση ενεργοποίησης του κρυφού στρώματος είναι η σιγμοειδής (εξίσωση (2.3)).



Σχήμα 6.3: Διαδικασία κατασκευής, εκπαίδευσης και αξιολόγησης του μοντέλου ELM

6.3.1 Φωτοβολταϊκό πάρκο της «Περδικούλας»

Αρχικά, το μοντέλο ELM εφαρμόζεται στο φωτοβολταϊκό πάρκο «Περδικούλα», για ορίζοντα πρόβλεψης 225 λεπτών με χρονικό βήμα τα 15 λεπτά, ώστε να συγκριθεί η απόδοσή του με την απόδοση του αντίστοιχου βέλτιστου μοντέλου MLP. Για τον σκοπό αυτό, αναζητείται η βέλτιστη διαμόρφωση του μοντέλου ELM, δηλαδή ο αριθμός νευρώνων εισόδου, ο αριθμός κρυφών νευρώνων και ο τρόπος προεπεξεργασίας των ιστορικών δεδομένων που συνεπάγονται την ελαχιστοποίηση του *MAPE* για το σύνολο επικύρωσης, αλλά και για το σύνολο ελέγχου. Η αναζήτηση της βέλτιστης αυτής διαμόρφωσης πραγματοποιείται μέσω δοκιμών, στο πλαίσιο της μεθόδου «Δοκιμή και Σφάλμα».

Η βέλτιστη τιμή του αριθμού νευρώνων εισόδου προσδιορίζεται μέσω της εύρεσης του βέλτιστου συνδυασμού παραμέτρων εισόδου. Οι παράμετροι εισόδου που εξετάζονται για το φωτοβολταϊκό πάρκο της «Περδικούλας» ορίζονται στον Πίνακα 6.5, ενώ η κανονικοποίηση των δεδομένων που χρησιμοποιούνται για την εκπαίδευση και την αξιολόγηση των νευρωνικών δικτύων του μοντέλου πραγματοποιείται ανά κατηγορία εισόδου στο διάστημα $[0, 1]$. Για κάθε εξεταζόμενο συνδυασμό παραμέτρων εισόδου, οι δοκιμές που διενεργούνται αφορούν ένα μεταβαλλόμενο πλήθος κρυφών νευρώνων, το οποίο λαμβάνει τιμές στο εύρος $[5, 200]$ με βήμα 5. Οι δοκιμές αυτές επαναλαμβάνονται συνολικά τρεις φορές, ενώ οι τιμές *MAPE* που επιλέγονται ως αντιπροσωπευτικές για κάθε συνδυασμό αντιστοιχούν στην ελάχιστη μέση τιμή που καταγράφεται για κάθε σύνολο. Ο αλγόριθμος ELM προσφέρει τη δυνατότητα να πραγματοποιηθεί ένα τόσο μεγάλο πλήθος δοκιμών, καθώς μειώνει δραστικά τον απαιτούμενο χρόνο εκπαίδευσης του δικτύου.

Τα αποτελέσματα των συγκεκριμένων δοκιμών παρουσιάζονται στον Πίνακα 6.18, όπου το σύνολο ελέγχου που χρησιμοποιείται ορίζεται στον Πίνακα 6.1, ενώ το σύνολο επικύρωσης αφορά κάθε τέταρτη ημέρα του συνόλου μάθησης.

Πίνακας 6.18: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου ELM για το φωτοβολταϊκό πάρκο της «Περδικούλας»

A/A	Νευρώνες εισόδου	Παράμετροι εισόδου	Training set MAPE (%)	Validation set MAPE (%)	Test set MAPE (%)
1	3	In1–In3	6,75	7,56	10,65
2	4	In1–In3, In7	6,66	7,32	10,44
3	4	In1–In3, In6	6,78	7,47	10,53
4	4	In1–In4	6,76	7,42	10,58
5	4	In1–In3, In5	6,66	7,37	10,51
6	5	In1–In3, In5, In7	6,71	7,36	10,69
7	5	In1–In3, In6, In7	6,72	7,35	10,30
8	5	In1–In4, In7	6,75	7,38	10,38
9	5	In1–In3, In7, In10	6,66	7,34	9,86
10	6	In1–In5, In7	6,77	7,39	10,63
11	6	In1–In3, In5–In7	6,76	7,35	10,45
12	6	In1–In3, In5, In7, In10	6,67	7,35	10,18
13	6	In1–In3, In7, In10, In11	6,71	7,36	10,03
14	6	In1–In3, In7, In9, In10	6,71	7,35	9,92
15	7	In1–In7	6,77	7,36	10,39
16	7	In1–In5, In7, In10	6,73	7,37	10,14
17	7	In1–In3, In5, In7, In9, In10	6,73	7,35	10,10
18	7	In1–In3, In5, In7, In10, In11	6,71	7,36	10,21
19	8	In1–In3, In5, In7–In10	6,75	7,35	10,09
20	8	In1–In3, In5, In7, In9, In10, In13	6,69	7,33	9,87
21	9	In1–In3, In5, In7, In9, In10, In12, In13	6,70	7,34	9,90
22	9	In1–In3, In5, In7, In9, In10, In13, In14	6,67	7,29	9,58
23	12	In1–In7, In9, In10, In12–In14	6,78	7,37	9,41
24	13	In1–In10, In12–In14	6,85	7,47	9,51
25	14	In1–In14	6,86	7,47	9,61

Σύμφωνα με τα αποτελέσματα του Πίνακα 6.18, ο συνδυασμός εισόδων που παρουσιάζει τη βέλτιστη συμπεριφορά για το σύνολο επικύρωσης αντιστοιχεί στη δοκιμή με A/A 22, ενώ η βέλτιστη συμπεριφορά του μοντέλου για το σύνολο ελέγχου εμφανίζεται κατά τη δοκιμή 23. Έτσι, για τους δύο αυτούς συνδυασμούς παραμέτρων εισόδου αναζητείται ο βέλτιστος αριθμός κρυφών νευρώνων στο διάστημα [200, 900] με βήμα 5. Ωστόσο, οι διαμορφώσεις που προέκυψαν από τις συγκεκριμένες δοκιμές δεν κατάφεραν να βελτιώσουν την απόδοση του μοντέλου.

Έτσι, εξετάζεται εάν η εφαρμογή ενός διαφορετικού τρόπου προεπεξεργασίας των ιστορικών δεδομένων – συγκεκριμένα, γίνεται κανονικοποίηση των χρονικών μεταβλητών εισόδου σε όρους ημιτόνου και συνημίτονου (sin/cos) – μπορεί να βελτιώσει τη συμπεριφορά του μοντέλου, αλλά τα αποτελέσματα που προκύπτουν δεν κρίνονται ικανοποιητικά. Οι τελευταίες δοκιμές βελτιστοποίησης αφορούν το πλήθος των χρησιμοποιούμενων δεδομένων, καθώς εξετάζεται η απόδοση του μοντέλου, όταν εκπαιδεύεται και αξιολογείται μόνο για δεδομένα του έτους 2020. Η βέλτιστη διαμόρφωση του δικτύου εξάγεται από τις συγκεκριμένες δοκιμές και περιλαμβάνει 9 νευρώνες εισόδου, οι οποίοι αντιστοιχούν στο συνδυασμό παραμέτρων της δοκιμής 22, και 200 κρυφούς νευρώνες. Το Validation set *MAPE* που υπολογίζεται για τη συγκεκριμένη διαμόρφωση είναι ίσο με 7,13%.

6.3.2 Φωτοβολταϊκό πάρκο «Lamprini» – Πρόβλεψη ανά 15 λεπτά

Η προσπάθεια βελτιστοποίησης του μοντέλου ELM, όταν αυτό εφαρμόζεται στο φωτοβολταϊκό πάρκο «Lamprini» για χρονικό ορίζοντα πρόβλεψης 225 λεπτών, ξεκινά και πάλι με τη διεξαγωγή δοκιμών που αφορούν τον προσδιορισμό του βέλτιστου αριθμού νευρώνων εισόδου. Τα δεδομένα που χρησιμοποιούνται για την εκπαίδευση και την αξιολόγηση του μοντέλου αφορούν αποκλειστικά το έτος 2020, ενώ το σύνολο ελέγχου συγκροτείται από τα 36 επιμέρους σύνολα του Πίνακα 6.2. Τα αποτελέσματα που προέκυψαν από τις παραπάνω δοκιμές παρουσιάζονται στον ακόλουθο πίνακα:

Πίνακας 6.19: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου ELM για το φωτοβολταϊκό πάρκο «Lamprini» και χρονικό ορίζοντα πρόβλεψης 225 λεπτά

A/A	Νευρώνες εισόδου	Παράμετροι εισόδου	Training set <i>MAPE</i> (%)	Validation set <i>MAPE</i> (%)	Test set <i>MAPE</i> (%)
1	3	In1–In3	9,30	9,08	9,93
2	4	In1–In3, In5	9,25	9,22	10,28
3	4	In1–In3, In6	9,19	9,31	10,24
4	4	In1–In4	9,49	9,40	10,72
5	4	In1–In3, In12	9,30	9,29	10,44
6	5	In1–In3, In5, In6	9,13	9,23	10,27
7	6	In1–In5, In12	9,33	9,20	10,34
8	6	In1–In3, In5, In6, In12	9,13	9,07	10,39

Πίνακας 6.19: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου ELM για το φωτοβολταϊκό πάρκο «Lampirini» και χρονικό ορίζοντα πρόβλεψης 225 λεπτά (συνέχεια)

A/A	Νευρώνες εισόδου	Παράμετροι εισόδου	Training set MAPE (%)	Validation set MAPE (%)	Test set MAPE (%)
9	6	In1–In6	9,23	9,22	10,41
10	6	In1–In4, In6, In12	9,28	9,10	10,41
11	7	In1–In6, In12	9,19	9,07	10,27
12	7	In1–In3, In5–In7, In12	9,06	9,04	10,22
13	7	In1–In3, In5, In6, In12, In13	9,19	9,06	10,40
14	7	In1–In3, In5, In6, In9, In12	9,11	9,07	10,40
15	7	In1–In3, In5, In6, In11, In12	9,24	9,13	10,47
16	8	In1–In3, In5–In7, In12, In13	9,13	9,06	10,19
17	8	In1–In6, In12, In13	9,27	9,09	10,32
18	8	In1–In3, In5, In6, In9, In12, In13	9,16	9,09	10,37
19	8	In1–In3, In5, In6, In11–In13	9,27	9,17	10,47
20	9	In1–In7, In12, In13	9,19	9,10	10,04
21	9	In1–In3, In5, In6, In9, In11–In13	9,25	9,17	10,53
22	10	In1–In3, In5–In7, In9, In11–In13	9,21	9,15	10,07
23	11	In1–In7, In9, In11–In13	9,22	9,17	10,04
24	12	In1–In7, In9–In13	9,30	9,10	9,88
25	12	In1–In9, In11–In13	9,23	9,20	10,24
26	13	In1–In13	9,29	9,09	9,85

Βάσει των δεδομένων του Πίνακα 6.19, που αντιστοιχούν στις βέλτιστες τιμές *MAPE* για N_h στο εύρος [5, 200] με βήμα 5, ο συνδυασμός παραμέτρων εισόδου που αντιστοιχεί στη δοκιμή 12 παρουσιάζει τις χαμηλότερες τιμές *MAPE* για τα σύνολα εκπαίδευσης και επικύρωσης, με τις τιμές αυτές να αφορούν νευρωνικά δίκτυα που διαθέτουν 195 και 135 κρυφούς νευρώνες, αντίστοιχα. Παράλληλα, η ελάχιστη τιμή του μετρικού *MAPE* όσον αφορά το σύνολο ελέγχου υπολογίζεται όταν χρησιμοποιείται το σύνολο των διαθέσιμων κατηγοριών εισόδου. Έτσι, για τους δύο συγκεκριμένους συνδυασμούς εισόδου αναζητείται η αντίστοιχη βέλτιστη τιμή του αριθμού των κρυφών νευρώνων του δικτύου, στο διευρυμένο εύρος τιμών [5, 900] με βήμα 5. Η διαμόρφωση που επιλέγεται ως βέλτιστη, βάσει των

παραπάνω δοκιμών, διαθέτει 13 νευρώνες εισόδου (δοκιμή 26) και 170 κρυφούς νευρώνες, καθώς κρίνεται ότι η εν λόγω διαμόρφωση παρουσιάζει την καλύτερη δυνατή ισορροπία ανάμεσα στην ελαχιστοποίηση του σφάλματος επικύρωσης (Validation set *MAPE* ίσο με 9,19%) και την ελαχιστοποίηση του σφάλματος γενίκευσης (Test set *MAPE* ίσο με 9,85%).

Τέλος, διερευνάται η συμπεριφορά του μοντέλου πρόβλεψης ELM για την εφαρμογή διαφορετικού, σε σχέση με τον πρότυπο τρόπο που περιγράφεται στην Ενότητα 4.3, τρόπου προεπεξεργασίας των δεδομένων εισόδου. Οι χρονικές μεταβλητές εισόδου «DoY» και «t» κανονικοποιούνται σε όρους ημιτόνου (sin) και συνημίτονου (cos), αντικαθιστώντας τις κλασικές παραμέτρους «DoY» και «t» με τους 4 όρους που υπολογίζονται με τις εξισώσεις (6.2) και (6.3). Το νευρωνικό δίκτυο που είχε κριθεί βέλτιστο εκπαιδεύεται και αξιολογείται για τη νέα αυτή διαμόρφωση, ενώ η διαδικασία επαναλαμβάνεται συνολικά 3 φορές, με τις μέσες τιμές των αποτελεσμάτων των τριών επιμέρους δοκιμών να συνιστούν τα ζητούμενα μετρικά σφάλματος. Έτσι, η τιμή του μετρικού *MAPE* που, τελικά, υπολογίζεται είναι ίση με 8,81% για το σύνολο επικύρωσης και 9,72% για το σύνολο ελέγχου. Επομένως, η χρήση του τρόπου προεπεξεργασίας sin/cos για τις χρονικές παραμέτρους οδηγεί σε βελτίωση της ακρίβειας του παρόντος μοντέλου πρόβλεψης ELM.

6.3.3 Φωτοβολταϊκό πάρκο «Lamprini» – Πρόβλεψη ανά λεπτό

Οι δοκιμές βελτιστοποίησης που διενεργούνται στην παρούσα διπλωματική εργασία ολοκληρώνονται με την περίπτωση του φωτοβολταϊκού πάρκου «Lamprini» για χρονικό ορίζοντα πρόβλεψης 15 λεπτών. Αρχικά, αναζητείται ο βέλτιστος συνδυασμός παραμέτρων εισόδου, οι οποίες επιλέγονται από τις διαθέσιμες κατηγορίες του Πίνακα 6.12. Τα αποτελέσματα των συγκεκριμένων δοκιμών καταγράφονται στον ακόλουθο πίνακα:

Πίνακας 6.20: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου ELM για το φωτοβολταϊκό πάρκο «Lamprini» και χρονικό ορίζοντα πρόβλεψης 15 λεπτά

A/A	Νευρώνες εισόδου	Παράμετροι εισόδου	Training set <i>MAPE</i> (%)	Validation set <i>MAPE</i> (%)	Test set <i>MAPE</i> (%)
1	3	In1–In3	4,11	4,09	3,96
2	4	In1–In3, In5	4,03	4,03	4,04
3	4	In1–In3, In6	4,08	4,09	4,21
4	4	In1–In4	4,12	4,09	3,77
5	4	In1–In3, In12	4,04	4,03	3,90
6	5	In1–In3, In5, In6	4,05	4,05	4,07
7	6	In1–In5, In12	4,02	4,01	4,06
8	6	In1–In3, In5, In6, In12	4,02	4,02	3,88
9	6	In1–In6	4,08	4,08	4,01
10	6	In1–In4, In6, In12	4,03	4,03	3,93

Πίνακας 6.20: Δοκιμές βελτιστοποίησης όσον αφορά τον αριθμό των νευρώνων εισόδου του μοντέλου ELM για το φωτοβολταϊκό πάρκο «Lampirini» και χρονικό ορίζοντα πρόβλεψης 15 λεπτά (συνέχεια)

A/A	Νευρώνες εισόδου	Παράμετροι εισόδου	Training set MAPE (%)	Validation set MAPE (%)	Test set MAPE (%)
11	7	In1–In6, In12	4,03	4,03	3,75
12	7	In1–In3, In5–In7, In12	4,01	4,04	3,83
13	7	In1–In3, In5, In6, In12, In13	4,04	4,04	3,86
14	7	In1–In3, In5, In6, In9, In12	4,04	4,07	3,94
15	7	In1–In3, In5, In6, In11, In12	4,04	4,06	3,69
16	8	In1–In3, In5–In7, In12, In13	4,03	4,05	3,92
17	8	In1–In6, In12, In13	4,06	4,06	3,81
18	8	In1–In6, In9, In12	4,05	4,08	3,98
19	8	In1–In6, In11, In12	4,05	4,07	3,72
20	8	In1–In7, In12	4,03	4,05	3,80
21	9	In1–In7, In12, In13	4,05	4,07	3,84
22	9	In1–In6, In9, In12, In13	4,08	4,10	4,00
23	9	In1–In3, In5–In7, In9, In12, In13	4,06	4,09	4,21
24	10	In1–In7, In9, In12, In13	4,07	4,10	4,18
25	11	In1–In7, In9, In11–In13	4,10	4,13	4,20
26	12	In1–In7, In9–In13	4,16	4,19	4,51
27	13	In1–In13	4,17	4,20	4,57

Οι τιμές που καταγράφονται στον Πίνακα 6.20 αφορούν, επίσης, δοκιμές βελτιστοποίησης που πραγματοποιούνται για μεταβαλλόμενο αριθμό κρυφών νευρώνων. Συγκεκριμένα, κάθε δοκιμή υλοποιείται για N_h που λαμβάνει τιμές στο διάστημα [5, 200] με βήμα 5, ενώ οι τιμές που τελικά επιλέγονται και παρουσιάζονται στον Πίνακα 6.20 αντιστοιχούν στην ελάχιστη τιμή που παρατηρήθηκε για κάθε σύνολο. Σύμφωνα με αυτές τις τιμές, η διαμόρφωση που εμφανίζει το μικρότερο MAPE στο σύνολο επικύρωσης περιλαμβάνει 6 νευρώνες εισόδου (δοκιμή 7, για $N_h = 185$).

Ωστόσο, παρατηρούνται αποτελέσματα δοκιμών τα οποία εμφανίζουν πολύ μικρή απόκλιση όσον αφορά το Validation set MAPE, ενώ παράλληλα εμφανίζουν σημαντικά καλύτερη συμπεριφορά για το σύνολο ελέγχου (δοκιμές 8 και 11). Επομένως, κατά τις

δοκιμές βελτιστοποίησης του N_h εξετάζονται και οι συνδυασμοί παραμέτρων εισόδου που αντιστοιχούν στις συγκεκριμένες δοκιμές.

Αξίζει, επίσης, να σημειωθεί ότι, σε αντίθεση με προηγούμενες περιπτώσεις για τις οποίες διενεργήθηκαν δοκιμές βελτιστοποίησης του αριθμού των νευρώνων εισόδου, οι δοκιμές που αξιοποίησαν τον μεγαλύτερο αριθμό παραμέτρων εισόδου (δοκιμές 26 και 27) παρουσίασαν τη χειρότερη συμπεριφορά και για τα τρία εξεταζόμενα σύνολα δεδομένων.

Σύμφωνα με τις δοκιμές που πραγματοποιήθηκαν για την εύρεση του βέλτιστου αριθμού κρυφών νευρώνων, η βέλτιστη διαμόρφωση του μοντέλου αποτελείται από 6 νευρώνες εισόδου (παραμέτροι δοκιμής 8) και 220 κρυφούς νευρώνες, καθώς τα μετρικά σφάλματος που υπολογίστηκαν για τη συγκεκριμένη διαμόρφωση είναι 4,00% για τα σύνολα εκπαίδευσης και επικύρωσης και 3,99% για το σύνολο ελέγχου. Πρέπει, ωστόσο, να σημειωθεί ότι η αναζήτηση του βέλτιστου N_h έγινε στο διάστημα [5, 300], με βήμα 5, καθώς για τιμές μεγαλύτερες του 300 δεν υπάρχει αρκετή μνήμη, ώστε να εκπαιδευτεί το μοντέλο πρόβλεψης, γεγονός που οφείλεται στον πολύ μεγάλο όγκο των διαθέσιμων ιστορικών δεδομένων. Στη συνέχεια, πραγματοποιήθηκαν δοκιμές με εφαρμογή της μεθόδου προεπεξεργασίας \sin/\cos , όσον αφορά τις χρονικές μεταβλητές εισόδου, από τις οποίες προέκυψε αύξηση του σφάλματος πρόβλεψης.

Τέλος, διερευνάται η απόδοση του μοντέλου ELM για ανά λεπτό πρόβλεψη στο φωτοβολταϊκό πάρκο «Lampirini», όταν το πλήθος των ιστορικών δεδομένων που χρησιμοποιούνται για την εκπαίδευση και την αξιολόγησή του επεκταθεί σε δεδομένα του 2021. Συγκεκριμένα, η βέλτιστη διαμόρφωση του μοντέλου που προέκυψε για δεδομένα του 2020 εκπαιδεύεται κάνοντας χρήση των επιτρεπόμενων δεδομένων του έτους 2021, ενώ, στη συνέχεια, η διαδικασία της εκπαίδευσης επαναλαμβάνεται, περιλαμβάνοντας, πλέον, και τα επιτρεπόμενα δεδομένα του έτους 2020.

Οι τιμές του μετρικού $MAPE$ που υπολογίζονται όταν το νευρωνικό δίκτυο του μοντέλου ELM εκπαιδεύεται αποκλειστικά με δεδομένα του 2021 είναι 4,10%, 4,12% και 6,33% για τα σύνολα εκπαίδευσης, επικύρωσης και ελέγχου, αντίστοιχα. Οι αντίστοιχες τιμές που υπολογίζονται όταν το δίκτυο εκπαιδεύεται αξιοποιώντας ιστορικά δεδομένα τόσο του 2020 όσο και του 2021 είναι 4,10%, 4,06% και 6,37%. Η αύξηση του πλήθους των δεδομένων εκπαίδευσης οδηγεί σε μια μικρή μείωση όσον αφορά το Validation set $MAPE$ και, παράλληλα, σε μια αύξηση περίπου 30'' στον απαιτούμενο χρόνο εκπαίδευσης. Η αύξηση αυτή δεν είναι αρκετά μεγάλη, ώστε να καταστήσει το μοντέλο που χρησιμοποιεί δεδομένα τόσο του 2020 όσο και του 2021 μία μη αποδοτική επιλογή.

6.4 ΣΥΓΚΡΙΣΗ ΤΗΣ ΑΠΟΔΟΣΗΣ ΤΩΝ ΒΕΛΤΙΣΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Οι δοκιμές που πραγματοποιήθηκαν στις Ενότητες 6.2 και 6.3 αποσκοπούν στην εύρεση της βέλτιστης διαμόρφωσης των μοντέλων πρόβλεψης MLP και ELM σε τρεις διαφορετικές περιπτώσεις. Η 1^η εξεταζόμενη περίπτωση αφορά το φωτοβολταϊκό πάρκο της «Περδικούλας», προβλέψεις σε ορίζοντα 225 λεπτών (χρονικό βήμα 15 λεπτά) και δεδομένα ελέγχου (επιβεβαίωσης) που αφορούν το έτος 2020 (Πίνακας 6.1). Η 2^η περίπτωση που εξετάζεται αφορά το φωτοβολταϊκό πάρκο «Lampirini», προβλέψεις σε ορίζοντα 225 λεπτών

(χρονικό βήμα 15 λεπτά) και σύνολο ελέγχου που περιλαμβάνει δεδομένα του 2020 (Πίνακας 6.2). Η 3^η περίπτωση αφορά, επίσης, το πάρκο «Lampirini», αλλά προβλέψεις που παράγονται σε χρονικό ορίζοντα 15 λεπτών ανά 1 λεπτό, ενώ ως σύνολο ελέγχου χρησιμοποιούνται τα επιμέρους σύνολα του Πίνακα 6.3. Η 1^η και η 2^η περίπτωση εντάσσονται στην κατηγορία της βραχυπρόθεσμης πρόβλεψης, ενώ η 3^η περίπτωση συνιστά πολύ βραχυπρόθεσμη πρόβλεψη της φωτοβολταϊκής παραγωγής.

Στη συνέχεια, συγκρίνονται οι διαμορφώσεις των νευρωνικών δικτύων που κρίθηκαν βέλτιστες για κάθε περίπτωση που μελετήθηκε. Αρχικά, πραγματοποιούνται συγκρίσεις ανά περίπτωση με βάση το μοντέλο πρόβλεψης που χρησιμοποιείται για την παραγωγή των ζητούμενων προβλέψεων, ενώ, στη συνέχεια, οι συγκρίσεις αφορούν τον προσδιορισμό της επίδρασης του χρονικού ορίζοντα στην ακρίβεια της παραγόμενης πρόβλεψης. Για κάθε σύγκριση, λαμβάνεται υπόψη το μετρικό σφάλματος Test set *MAPE* του εκάστοτε μοντέλου πρόβλεψης, αλλά και το Validation set *MAPE*, το οποίο θεωρείται επίσης αντιπροσωπευτικό του σφάλματος γενίκευσης.

6.4.1 Σύγκριση βάσει του μοντέλου πρόβλεψης

Στον ακόλουθο πίνακα παρουσιάζονται οι βέλτιστες διαμορφώσεις ανά περίπτωση και ανά μοντέλο πρόβλεψης, καθώς και τα αντίστοιχα μετρικά σφάλματος:

Πίνακας 6.21: Βέλτιστες διαμορφώσεις ανά εξεταζόμενη περίπτωση και ανά μοντέλο πρόβλεψης

Εξεταζόμενη περίπτωση	Περίπτωση 1 ^η		Περίπτωση 2 ^η		Περίπτωση 3 ^η	
	MLP	ELM	MLP	ELM	MLP	ELM
Μοντέλο πρόβλεψης	MLP	ELM	MLP	ELM	MLP	ELM
Νευρώνες εισόδου	14	9	12	13	7	6
Νευρώνες κρυφού στρώματος	28	200	30	170	21	220
Συνάρτηση ενεργοποίησης κρυφού στρώματος	Softsign	Sigmoid	Softsign	Sigmoid	Tanh	Sigmoid
Συνάρτηση ενεργοποίησης στρώματος εξόδου	Sigmoid	–	Sigmoid	–	Sigmoid	–
Αλγόριθμος βελτιστοποίησης	Adam	–	Nadam	–	Adam	–
Ρυθμός μάθησης	0,0015	–	0,0040	–	0,0050	–
Αριθμός εποχών	300	–	500	–	450	–
Mini-batch size	32	–	32	–	256	–
Κανονικοποίηση δεδομένων	sin/cos	min/max	min/max	sin/cos	min/max	min/max
Πλήθος διανυσμάτων εισόδου εκπαίδευσης	7981	7981	7677	7673	220001	165000
Χρόνος εκπαίδευσης	1' 35"	1"	2' 39"	1"	3' 47"	16"

Πίνακας 6.21: Βέλτιστες διαμορφώσεις ανά εξεταζόμενη περίπτωση και ανά μοντέλο πρόβλεψης (συνέχεια)

Εξεταζόμενη περίπτωση	Περίπτωση 1 ^η		Περίπτωση 2 ^η		Περίπτωση 3 ^η	
	MLP	ELM	MLP	ELM	MLP	ELM
Μοντέλο πρόβλεψης						
Training set MAPE (%)	5,82	6,47	8,03	9,19	3,52	4,00
Validation set MAPE (%)	6,29	7,13	7,75	8,81	3,63	4,00
Test set MAPE (%)	10,10	9,93	9,02	9,72	3,57	3,99

Όσον αφορά την κανονικοποίηση των δεδομένων, η τιμή min/max αναφέρεται στη μέθοδο κανονικοποίησης μεγίστου-ελαχίστου που περιγράφεται με την εξίσωση (4.1), η οποία εφαρμόζεται σε όλες τις κατηγορίες εισόδου, ενώ η τιμή sin/cos αναφέρεται στη μέθοδο κανονικοποίησης των χρονικών κατηγοριών εισόδου DoY και t με χρήση όρων ημιτόνου και συνημίτονου, σύμφωνα με τις εξισώσεις (6.2) και (6.3). Κατά την εφαρμογή της μεθόδου sin/cos όλες οι υπόλοιπες κατηγορίες εισόδου κανονικοποιούνται με τη μέθοδο min/max. Σε κάθε περίπτωση, η εφαρμογή κάποιας μεθόδου κανονικοποίησης οδήγησε σε βελτίωση της συμπεριφοράς του μοντέλου, συγκριτικά με υλοποιήσεις που χρησιμοποιούσαν ανεπεξέργαστα δεδομένα.

Για τις δύο πρώτες περιπτώσεις που εξετάστηκαν, το πλήθος των διανυσμάτων εισόδου του συνόλου εκπαίδευσης είναι το ίδιο ή σχεδόν ίδιο, ανάλογα με τις παραμέτρους εισόδου που χρησιμοποιούνται, για τα δύο μοντέλα πρόβλεψης. Αντίθετα, στην 3^η περίπτωση το αντίστοιχο πλήθος που αφορά το μοντέλο MLP είναι κατά 25% μεγαλύτερο συγκριτικά με το μοντέλο ELM. Ωστόσο, επειδή η συγκεκριμένη βέλτιστη διαμόρφωση προέρχεται από την εφαρμογή της μεθόδου Grid Search, σε κάθε μία από τις 4 επαναλήψεις που πραγματοποιούνται, στο πλαίσιο της διασταυρούμενης επικύρωσης για $k = 4$, η εκπαίδευση του δικτύου γίνεται για ένα, διαφορετικό κάθε φορά, 75% των συνολικών διανυσμάτων εισόδου. Παράλληλα, ο χρόνος εκπαίδευσης που καταγράφεται στον Πίνακα 6.21 αφορά μία επανάληψη, με το συνολικό χρόνο να ανέρχεται σε 15' 08".

Σύμφωνα με τα αποτελέσματα του Πίνακα 6.21, τα βέλτιστα μοντέλα MLP παρουσιάζουν και για τις τρεις περιπτώσεις που εξετάστηκαν καλύτερη συμπεριφορά συγκριτικά με τα αντίστοιχα μοντέλα ELM, καθώς οι υπολογιζόμενες, ανά περίπτωση, τιμές του MAPE είναι μικρότερες και για τα τρία εξεταζόμενα σύνολα δεδομένων (εκπαίδευσης, επικύρωσης και ελέγχου), με μοναδική εξαίρεση το σύνολο ελέγχου της 1^{ης} περίπτωσης. Το πλεονέκτημα των μοντέλων ELM έγκειται, όπως αναμενόταν, στον χρόνο που απαιτείται για την εκπαίδευσή τους, ο οποίος είναι εξαιρετικά μικρότερος συγκριτικά με τα μοντέλα MLP. Δεδομένου ότι οι αποκλίσεις μεταξύ των τιμών του μετρικού MAPE για κάθε περίπτωση δεν είναι εξαιρετικά μεγάλες, τα μοντέλα ELM θα μπορούσαν να εκπαιδευτούν και, στη συνέχεια, να χρησιμοποιηθούν για την παραγωγή προβλέψεων σε περιπτώσεις όπου υπάρχει πίεση χρόνου, θυσιάζοντας κάποιο μικρό ποσοστό ακρίβειας.

Τέλος, αξίζει να σημειωθεί ότι όλες οι βέλτιστες διαμορφώσεις του Πίνακα 6.21 παρουσίασαν καλύτερη συμπεριφορά συγκριτικά με το αντίστοιχο, για κάθε περίπτωση, μοντέλο Persistence, το οποίο αποτελεί το σημείο αναφοράς για την αξιολόγηση των μοντέλων. Δεδομένου ότι η ακρίβεια της μεθόδου Persistence μειώνεται καθώς αυξάνεται ο

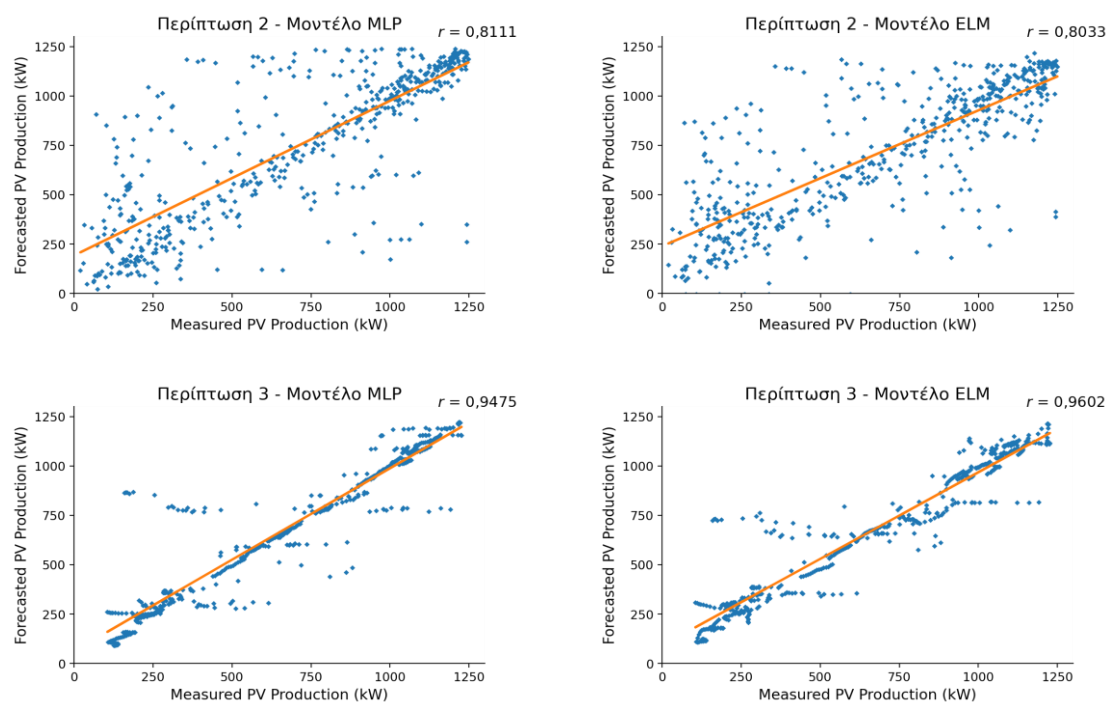
χρονικός ορίζοντας, οι τιμές του *MAPE* που υπολογίστηκαν για τις περιπτώσεις 1 και 2 (ορίζοντας πρόβλεψης 225 λεπτών) κυμαίνονται από 20%–25%.

Αντίθετα, για χρονικούς ορίζοντες πρόβλεψης που εμπίπτουν στην πολύ βραχυπρόθεσμη πρόβλεψη (nowcasting), η μέθοδος Persistence παρουσιάζει πολύ καλύτερη συμπεριφορά. Αρκετές μελέτες έδειξαν ότι η δημιουργία μοντέλων που υπερτερούν της μεθόδου Persistence για τέτοιους χρονικούς ορίζοντες είναι ιδιαίτερα δύσκολη [38]. Ωστόσο, τα βέλτιστα μοντέλα πρόβλεψης της 3^{ης} περίπτωσης υπερτερούν της μεθόδου Persistence, για την οποία υπολογίζεται Test set *MAPE* ίσο με 4,51%.


6.4.2 Σύγκριση βάσει του χρονικού ορίζοντα πρόβλεψης

Ο χρονικός ορίζοντας της παραγόμενης πρόβλεψης είναι ένας παράγοντας που επηρεάζει σημαντικά την ακρίβεια του χρησιμοποιούμενου μοντέλου. Τα μοντέλα πρόβλεψης των περιπτώσεων 2 και 3 αφορούν το ίδιο φωτοβολταϊκό πάρκο («Lamprini»), εκπαιδεύονται χρησιμοποιώντας δεδομένα του ίδιου έτους (2020), ενώ τα σύνολα ελέγχου τους αφορούν τις ίδιες ημέρες του έτους (Πίνακες 6.2 και 6.3). Ωστόσο, τα μοντέλα πρόβλεψης που αντιστοιχούν στην 3^η περίπτωση, και σε χρονικό ορίζοντα πρόβλεψης 15 λεπτών, εμφανίζουν σαφώς καλύτερη συμπεριφορά σε σύγκριση με τα αντίστοιχα μοντέλα της περίπτωση 2 (ορίζοντας πρόβλεψης 225 λεπτών).

Η επίδραση του χρονικού ορίζοντα στην παραγόμενη πρόβλεψη φαίνεται και στα επόμενα σχήματα:



Σχήμα 6.4: Ευθεία γραμμικής παλινδρόμησης και συσχέτιση μεταξύ της φωτοβολταϊκής παραγωγής που μετρήθηκε και της προβλεπόμενης φωτοβολταϊκής παραγωγής ανά μοντέλο πρόβλεψης (φωτοβολταϊκό πάρκο «Lamprini»)



Σχήμα 6.5: Ευθεία γραμμικής παλινδρόμησης και συσχέτιση μεταξύ της φωτοβολταϊκής παραγωγής που μετρήθηκε και της προβλεπόμενης φωτοβολταϊκής παραγωγής ανά μοντέλο πρόβλεψης (φωτοβολταϊκό πάρκο «Περδικούλα»)

Όπως φαίνεται στα Σχήματα 6.4 και 6.5, η συσχέτιση μεταξύ των μετρήσεων της παραγόμενης φωτοβολταϊκής ισχύος, όσον αφορά τα δεδομένα των συνόλων ελέγχου που αντιστοιχούν σε κάθε περίπτωση, και της αντίστοιχης φωτοβολταϊκής ισχύος στην έξοδο του εκάστοτε μοντέλου πρόβλεψης είναι σημαντικά ισχυρότερη στην περίπτωση 3, δηλαδή για χρονικό ορίζοντα 15 λεπτών. Επομένως, τα μοντέλα πρόβλεψης που χρησιμοποιούνται για την παραγωγή προβλέψεων σε χρονικό ορίζοντα 15 λεπτών προσεγγίζουν καλύτερα την επιθυμητή συμπεριφορά που καλούνται να μοντελοποιήσουν τα αντίστοιχα νευρωνικά δίκτυα.

Το ίδιο συμπέρασμα εξάγεται και μέσω του υπολογισμού του συντελεστή προσδιορισμού (coefficient of determination – R^2) μεταξύ της επιθυμητής και της προβλεπόμενης φωτοβολταϊκής παραγωγής για τα δεδομένα των συνόλων ελέγχου. Ο συντελεστής προσδιορισμού αποτελεί ένα μέτρο της ικανότητας του εκάστοτε μοντέλου να πραγματοποιήσει προβλέψεις για άγνωστα σε αυτό δεδομένα και δίνεται από την ακόλουθη σχέση:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (6.4)$$

όπου n είναι ο αριθμός των συνολικών δειγμάτων, y_i είναι η πραγματική τιμή του i -οστού

δείγματος, \hat{y}_i είναι η αντίστοιχη τιμή που προβλέπεται για το i -οστό δείγμα, $\bar{y} = \frac{1}{n} \cdot \sum_{i=1}^n y_i$

και $\sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n e_i^2$.

Οι τιμές του R^2 που υπολογίστηκαν καταγράφονται, ανά περίπτωση και ανά μοντέλο πρόβλεψης, στον Πίνακα 6.22. Οι τιμές που αντιστοιχούν στην 3^η περίπτωση είναι οι τιμές που προσεγγίζουν περισσότερο το ένα (1), το οποίο αποτελεί την καλύτερη δυνατή τιμή του συγκεκριμένου συντελεστή.

Πίνακας 6.22: Συντελεστής προσδιορισμού για το σύνολο ελέγχου ανά εξεταζόμενη περίπτωση και ανά μοντέλο πρόβλεψης

Εξεταζόμενη περίπτωση	Περίπτωση 1		Περίπτωση 2		Περίπτωση 3	
	MLP	ELM	MLP	ELM	MLP	ELM
Μοντέλο πρόβλεψης						
R^2	0,41	0,48	0,61	0,63	0,90	0,92

ΕΠΙΛΟΓΟΣ

7.1 ΣΥΝΟΨΗ ΤΗΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία πραγματεύεται τη βραχυπρόθεσμη πρόβλεψη φωτοβολταϊκής παραγωγής με χρήση τεχνητών νευρωνικών δικτύων. Αρχικά, γίνεται μια εισαγωγή σε βασικές έννοιες των τεχνητών νευρωνικών δικτύων, όπως το μαθηματικό μοντέλο των νευρώνων τους, η αρχιτεκτονική, η εκπαίδευση και οι υπερπαραμέτροί τους. Στη συνέχεια, μελετάται το θέμα της πρόβλεψης φωτοβολταϊκής παραγωγής, αναλύονται τα διαθέσιμα ιστορικά δεδομένα και περιγράφονται τα αναπτυσσόμενα μοντέλα πρόβλεψης.

Στο πλαίσιο της παρούσας διπλωματικής εργασίας, αναπτύσσονται δύο διακριτά μοντέλα πρόβλεψης, τα οποία εκτελούν βραχυπρόθεσμη και πολύ βραχυπρόθεσμη πρόβλεψη της φωτοβολταϊκής παραγωγής, για χρονικούς ορίζοντες 225 και 15 λεπτών αντίστοιχα. Το πρώτο μοντέλο πρόβλεψης βασίζεται σε ένα νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης (feedforward), το οποίο εκπαιδεύεται με τον κλασικό αλγόριθμο backpropagation σε συνδυασμό με κάποιον επιλεγμένο αλγόριθμο βελτιστοποίησης. Το δεύτερο μοντέλο στηρίζεται, επίσης, σε ένα feedforward νευρωνικό δίκτυο, το οποίο εκπαιδεύεται με τον αλγόριθμο Extreme Learning Machine.

Για την εκπαίδευση και την αξιολόγηση των παραπάνω μοντέλων πρόβλεψης, χρησιμοποιούνται ιστορικά δεδομένα δύο διαφορετικών φωτοβολταϊκών πάρκων. Το φωτοβολταϊκό πάρκο της «Περδικούλας» διαθέτει πληθώρα μετρήσεων, οι οποίες δίνονται με χρονική ανάλυση 15 λεπτά. Το φωτοβολταϊκό πάρκο «Lampirini» διαθέτει μικρότερο πλήθος παραμέτρων εισόδου, οι οποίες, ωστόσο, δίνονται με χρονική ανάλυση ένα (1) λεπτό, γεγονός που προσφέρει μεγαλύτερη ευελιξία όσον αφορά την παραγωγή προβλέψεων. Έτσι, ενώ για το φωτοβολταϊκό πάρκο της «Περδικούλας» παράγονται προβλέψεις για χρονικό ορίζοντα 225 λεπτών με βήμα 15 λεπτά, για το φωτοβολταϊκό πάρκο «Lampirini» μπορούν να παραχθούν προβλέψεις για χρονικό ορίζοντα τόσο 225 όσο και 15 λεπτών με βήμα 15 λεπτά και 1 λεπτό, αντίστοιχα.

Σε κάθε περίπτωση, τα μοντέλα πρόβλεψης που εκπαιδεύονται βάσει δεδομένων των συγκεκριμένων φωτοβολταϊκών πάρκων διαθέτουν πληθώρα υπερπαραμέτρων, οι οποίες επηρεάζουν την απόδοση των μοντέλων και, ως εκ τούτου, πρέπει να ρυθμιστούν με σκοπό την επίτευξη της βέλτιστης απόδοσης. Η διαδικασία βελτιστοποίησης πραγματοποιείται ανά εξεταζόμενη περίπτωση και ανά μοντέλο πρόβλεψης, ώστε να βρεθούν οι αντίστοιχες βέλτιστες διαμορφώσεις υπερπαραμέτρων. Η αναζήτηση των βέλτιστων αυτών διαμορφώσεων υλοποιείται με τη διενέργεια δοκιμών.

Οι βέλτιστες διαμορφώσεις που προκύπτουν συγκρίνονται μεταξύ τους στη βάση του χρησιμοποιούμενου μοντέλου πρόβλεψης, αλλά και βάσει του χρονικού ορίζοντα. Σκοπός των συγκεκριμένων συγκρίσεων είναι η εξαγωγή συμπερασμάτων όσον αφορά (i) το μοντέλο

πρόβλεψης που παρουσιάζει την καλύτερη συμπεριφορά και (ii) την επίδραση του χρονικού ορίζοντα της παραγόμενης πρόβλεψης στην ακρίβεια του μοντέλου.

7.2 ΣΥΜΠΕΡΑΣΜΑΤΑ

Οι βέλτιστες διαμορφώσεις ανά εξεταζόμενη περίπτωση και ανά μοντέλο πρόβλεψης καταγράφονται στον Πίνακα 6.21. Σύμφωνα με τα μετρικά σφάλματος που υπολογίζονται για τα εξεταζόμενα σύνολα των συγκεκριμένων διαμορφώσεων, το μοντέλο MLP – το οποίο εκπαιδεύεται με επαναληπτική αναπροσαρμογή των συναπτικών βαρών και των πολώσεων των νευρώνων του, στο πλαίσιο του αλγορίθμου της προς τα πίσω διάδοσης του σφάλματος (backpropagation) – υπερτερεί έναντι του μοντέλου ELM, όσον αφορά την ακρίβεια της παραγόμενης πρόβλεψης. Μάλιστα, το μοντέλο MLP εμφανίζει καλύτερη συμπεριφορά ανεξάρτητα από τον τρόπο διαχωρισμού που χρησιμοποιείται για τη διαίρεση του εκάστοτε συνόλου μάθησης. Συγκεκριμένα, στην 1^η περίπτωση που εξετάζεται το σύνολο επικύρωσης περιλαμβάνει κάθε τέταρτη ημέρα του έτους, ενώ στην 2^η περίπτωση το μοντέλο MLP υπερτερεί και για τρόπο διαχωρισμού ίδιο με την 1^η περίπτωση και για τυχαίο διαχωρισμό στο πλαίσιο της μεθόδου διασταυρούμενης επικύρωσης που υλοποιείται με τη μέθοδο αναζήτησης πλέγματος. Όσον αφορά την 3^η περίπτωση, το μοντέλο MLP υπερτερεί τόσο όταν έχει προκύψει από την εφαρμογή της μεθόδου Grid Search όσο και για τυχαίο τρόπο διαχωρισμού που εφαρμόζεται στο πλαίσιο της μεθόδου «Trial and Error».

Το πλεονέκτημα του μοντέλου ELM έγκειται στην ταχύτητα με την οποία ολοκληρώνεται η εκπαίδευσή του. Σε αντίθεση με το μοντέλο MLP, ο αλγόριθμος μάθησης Extreme Learning Machine δεν εφαρμόζει επαναληπτική αναπροσαρμογή των ελεύθερων παραμέτρων του νευρωνικού δικτύου, αλλά τις υπολογίζει με τρόπο αναλυτικό, σε ένα χρονικό βήμα. Έτσι, ο χρόνος που απαιτείται για την εκπαίδευση και την αξιολόγηση του μοντέλου μειώνεται δραστικά σε σύγκριση με το αντίστοιχο μοντέλο MLP. Το χαρακτηριστικό αυτό φάνηκε ιδιαίτερα χρήσιμο κατά τη διαδικασία της βελτιστοποίησης, όπου είναι απαραίτητη η διεξαγωγή πληθώρας δοκιμών· συχνά, για πολύ μεγάλο πλήθος δεδομένων εκπαίδευσης. Παράλληλα, το γεγονός ότι η απόκλιση που παρατηρείται μεταξύ των βέλτιστων μοντέλων ELM και των βέλτιστων μοντέλων MLP δεν είναι ιδιαίτερα μεγάλη σημαίνει ότι τα μοντέλα ELM μπορούν να χρησιμοποιηθούν για περιπτώσεις που απαιτούν ελαχιστοποίηση του συνολικού χρόνου εκτέλεσης του κώδικα.

Όσον αφορά τον χρονικό ορίζοντα της πρόβλεψης, από τους Πίνακες 6.21, 6.22 αλλά και τα Σχήματα 6.4, 6.5 φαίνεται ότι η αύξηση του χρονικού ορίζοντα της πρόβλεψης, στην προκειμένη περίπτωση από 15 σε 225 λεπτά, οδηγεί σε σημαντική μείωση της ακρίβειας των μοντέλων πρόβλεψης που χρησιμοποιούνται. Η μείωση αυτή, η οποία παρατηρείται και για τη μέθοδο Persistence, οφείλεται, ενδεχομένως, στην αύξηση της μεταβλητότητας μετεωρολογικών παραγόντων, όπως η νεφοκάλυψη, οι οποίοι εμφανίζουν ισχυρή συσχέτιση με την ένταση της προσπίπτουσας ηλιακής ακτινοβολίας και, επομένως, στην αύξηση της μεταβλητότητας της ίδιας της ηλιακής ακτινοβολίας. Δεδομένου ότι η ένταση της ηλιακής ακτινοβολίας παρουσιάζει σταθερά την ισχυρότερη συσχέτιση με την παραγόμενη φωτοβολταϊκή ισχύ, μια αύξηση όσον αφορά την εγγενή της μεταβλητότητα αναμένεται να επηρεάσει αρνητικά την ακρίβεια της πρόβλεψης.

Τέλος, οι δοκιμές που πραγματοποιήθηκαν με σκοπό τη βελτιστοποίηση των μοντέλων πρόβλεψης κατέδειξαν τη σημασία της κατάλληλης προεπεξεργασίας των διαθέσιμων ιστορικών δεδομένων, καθώς όλες οι βέλτιστες διαμορφώσεις που προέκυψαν περιλαμβάνουν κάποια μέθοδο κανονικοποίησης δεδομένων. Παράλληλα, από τις δοκιμές αυτές προέκυψε ότι μια σημαντική αύξηση του πλήθους των διανυσμάτων εισόδου εκπαίδευσης, χρησιμοποιώντας ιστορικά δεδομένα του 2019 και του 2020 για το φωτοβολταϊκό πάρκο της «Περδικούλας» ή δεδομένα του 2020 και του 2021 για ανά λεπτό πρόβλεψη στο φωτοβολταϊκό πάρκο «Lampirini», δεν οδηγεί σε αντίστοιχα σημαντική βελτίωση της συμπεριφοράς των εξεταζόμενων μοντέλων πρόβλεψης.

7.3 ΜΕΛΛΟΝΤΙΚΕΣ ΕΠΕΚΤΑΣΕΙΣ

Παρά το γεγονός ότι διενεργήθηκε πληθώρα δοκιμών βελτιστοποίησης αναφορικά με τις υπερπαραμέτρους του μοντέλου MLP, θα μπορούσαν να διεξαχθούν περαιτέρω δοκιμές σχετικά με τον βαθμό συνδεσιμότητας του νευρωνικού δικτύου και τον ρυθμό μάθησης του αλγορίθμου βελτιστοποίησης. Όσον αφορά τον βαθμό συνδεσιμότητας του δικτύου, θα μπορούσε να εφαρμοστεί κάποιος κατάλληλος αλγόριθμος κλαδέματος, με σκοπό την απαλοιφή συναπτικών βαρών τα οποία κρίνονται αμελητέα, ενώ στο πλαίσιο του αλγορίθμου βελτιστοποίησης, θα μπορούσε να χρησιμοποιηθεί μεταβαλλόμενος ρυθμός μάθησης. Συγκεκριμένα, αντί να οριστεί ως ρυθμός μάθησης κάποια σταθερή τιμή, ορίζεται ένα πρόγραμμα ρυθμού μάθησης (learning rate schedule), το οποίο μειώνει ή προσαρμόζει τον αρχικό ρυθμό μάθησης, κατά τη διάρκεια της εκπαίδευσης του νευρωνικού δικτύου, μέσω συγκεκριμένων υπερπαραμέτρων [21]. Για τη βελτιστοποίηση των υπερπαραμέτρων του μοντέλου MLP, θα μπορούσε, επίσης, να χρησιμοποιηθεί κάποια αυτοματοποιημένη τεχνική βελτιστοποίησης υπερπαραμέτρων, πέραν της μεθόδου Grid Search.

Όσον αφορά το μοντέλο πρόβλεψης ELM, μία πιθανή επέκταση της παρούσας διπλωματικής εργασίας θα μπορούσε να είναι η βελτιστοποίηση του μοντέλου, ρυθμίζοντας κατάλληλα τις ελεύθερες παραμέτρους των νευρώνων του κρυφού στρώματος, ώστε να επιλεγούν οι τιμές που συνεπάγονται τη βέλτιστη απόδοση του μοντέλου. Η ρύθμιση αυτή μπορεί να γίνει με χρήση του αλγορίθμου Particle Swarm Optimization ή παραλλαγών του, όπως οι Crazy Particle Swarm Optimization (CRPSO) και Accelerated Particle Swarm Optimization (APSO) [57].

Τέλος, τα διαθέσιμα ιστορικά δεδομένα των φωτοβολταϊκών πάρκων «Περδικούλα» και «Lampirini» θα μπορούσαν να χρησιμοποιηθούν για την παραγωγή πιθανοτικών προβλέψεων. Τα μοντέλα πρόβλεψης που αναπτύσσονται στην παρούσα διπλωματική εργασία είναι αιτιοκρατικά μοντέλα, καθώς παράγουν σημειακές προβλέψεις. Σε αντίθεση με τα αιτιοκρατικά μοντέλα, τα πιθανοτικά μοντέλα παρέχουν επιπρόσθετη γνώση σχετικά με τις παραγόμενες προβλέψεις, όπως τα άνω και κάτω όρια των πιθανών προβλέψεων, το επίπεδο εμπιστοσύνης για κάθε πρόβλεψη ή ένα εύρος πιθανών τιμών με την αντίστοιχη συνάρτηση πυκνότητας πιθανότητας. Επομένως, με χρήση κατάλληλων μεθόδων πιθανοτικής πρόβλεψης (Bootstrapping, Lower Upper Bound Estimate – LUBE) μπορούν να παραχθούν πιθανοτικές προβλέψεις, χρησιμοποιώντας τα διαθέσιμα ιστορικά δεδομένα των δύο φωτοβολταϊκών πάρκων που μελετήθηκαν.

ΒΙΒΛΙΟΓΡΑΦΙΑ

8.1 ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] IEA, “Renewable Energy Market Update - May 2022,” Paris, 2022. Accessed: Jul. 28, 2022. [Online]. Available: <https://www.iea.org/reports/renewable-energy-market-update-may-2022>
- [2] IRENA, “Renewable Power Generation Costs in 2019,” International Renewable Energy Agency, Abu Dhabi, 2020.
- [3] S. S. Haykin, *Neural networks and learning machines*, 3rd ed. Upper Saddle River, NJ: Pearson Education, 2009.
- [4] P. S. Georgilakis, “Classification and Forecasting,” in *Spotlight on Modern Transformer Design*, London: Springer London, 2009, pp. 157–217. doi: 10.1007/978-1-84882-667-0_4.
- [5] D. Hammerstrom, “Neural networks at work,” *IEEE Spectr.*, vol. 30, no. 6, pp. 26–32, Jun. 1993, doi: 10.1109/6.214579.
- [6] D. Hammerstrom, “Working with neural networks,” *IEEE Spectr.*, vol. 30, no. 7, pp. 46–53, Jul. 1993, doi: 10.1109/6.222230.
- [7] S. A. Kalogirou, “Artificial neural networks in renewable energy systems applications: a review,” *Renew. Sustain. Energy Rev.*, vol. 5, no. 4, pp. 373–401, Dec. 2001, doi: 10.1016/S1364-0321(01)00006-5.
- [8] A. K. Jain, Jianchang Mao, and K. M. Mohiuddin, “Artificial neural networks: a tutorial,” *Computer (Long Beach, Calif.)*, vol. 29, no. 3, pp. 31–44, Mar. 1996, doi: 10.1109/2.485891.
- [9] I. A. Basheer and M. Hajmeer, “Artificial neural networks: fundamentals, computing, design, and application,” *J. Microbiol. Methods*, vol. 43, no. 1, pp. 3–31, Dec. 2000, doi: 10.1016/S0167-7012(00)00201-3.
- [10] W. S. McCulloch and W. Pitts, “A logical calculus of the ideas immanent in nervous activity,” *Bull. Math. Biophys.*, vol. 5, no. 4, pp. 115–133, Dec. 1943, doi: 10.1007/BF02478259.
- [11] D. O. Hebb, *The organization of behavior: A neuropsychological theory*. New York: Wiley, 1949.
- [12] F. Rosenblatt, “The perceptron: A probabilistic model for information storage and organization in the brain.,” *Psychol. Rev.*, vol. 65, no. 6, pp. 386–408, 1958, doi: 10.1037/h0042519.
- [13] B. Widrow and M. E. Hoff, “Adaptive Switching Circuits,” in *1960 IRE WESCON Convention Record, Part 4*, 1960, pp. 96–104.
- [14] J. J. Hopfield, “Neural networks and physical systems with emergent collective computational abilities.,” *Proc. Natl. Acad. Sci.*, vol. 79, no. 8, pp. 2554–2558, Apr. 1982, doi: 10.1073/pnas.79.8.2554.
- [15] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning Internal Representations by Error Propagation,” in *Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Volume 1: Foundations*, D. E. Rumelhart and J. L. McClelland, Eds. Cambridge, MA: MIT Press, 1986, pp. 318–362.
- [16] P. J. Werbos, “Beyond Regression: New Tools for Prediction and Analysis in the

- Behavioral Sciences,” Ph.D. dissertation, Committee on Appl. Math., Harvard Univ., Cambridge, MA, 1974.
- [17] Γ. Κονταξής και Ν. Χατζηαργυρίου, *Κέντρα Ελέγχου Ενέργειας*. Αθήνα: Εθνικό Μετσόβιο Πολυτεχνείο, 2003.
- [18] D. Anderson and G. McNeill, “Artificial neural networks technology,” *Kaman Sci. Corp.*, vol. 258, no. 6, pp. 1–83, 1992.
- [19] G. A. Carpenter and S. Grossberg, “The ART of adaptive pattern recognition by a self-organizing neural network,” *Computer (Long. Beach. Calif.)*, vol. 21, no. 3, pp. 77–88, Mar. 1988, doi: 10.1109/2.33.
- [20] T. Kohonen, “Self-organized formation of topologically correct feature maps,” *Biol. Cybern.*, vol. 43, no. 1, pp. 59–69, 1982, doi: 10.1007/BF00337288.
- [21] Y. Bengio, “Practical Recommendations for Gradient-Based Training of Deep Architectures,” in *Neural Networks: Tricks of the Trade: Second Edition*, G. Montavon, G. B. Orr, and K.-R. Müller, Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, pp. 437–478. doi: 10.1007/978-3-642-35289-8_26.
- [22] L. Yang and A. Shami, “On hyperparameter optimization of machine learning algorithms: Theory and practice,” *Neurocomputing*, vol. 415, pp. 295–316, Nov. 2020, doi: 10.1016/j.neucom.2020.07.061.
- [23] G. Zhang, B. Eddy Patuwo, and M. Y. Hu, “Forecasting with artificial neural networks: The state of the art,” *Int. J. Forecast.*, vol. 14, no. 1, pp. 35–62, Mar. 1998, doi: 10.1016/S0169-2070(97)00044-7.
- [24] G. Cybenko, “Approximation by superpositions of a sigmoidal function,” *Math. Control. Signals, Syst.*, vol. 2, no. 4, pp. 303–314, Dec. 1989, doi: 10.1007/BF02551274.
- [25] “Overview: Weather, Global Warming and Climate Change,” NASA Global Climate Change and Global Warming: Vital Signs of the Planet. Accessed: Jul. 20, 2022. [Online]. Available: <https://climate.nasa.gov/global-warming-vs-climate-change/>
- [26] “The Causes of Climate Change,” NASA Global Climate Change and Global Warming: Vital Signs of the Planet. Accessed: Jul. 20, 2022. [Online]. Available: <https://climate.nasa.gov/causes/>
- [27] IPCC, “Framing and Context,” in *Global Warming of 1.5°C: IPCC Special Report on Impacts of Global Warming of 1.5°C above Pre-industrial Levels in Context of Strengthening Response to Climate Change, Sustainable Development, and Efforts to Eradicate Poverty*, Cambridge: Cambridge University Press, 2022, pp. 49–92. doi: 10.1017/9781009157940.003.
- [28] “Climate Change Evidence: How Do We Know?,” NASA Global Climate Change and Global Warming: Vital Signs of the Planet. Accessed: Jul. 21, 2022. [Online]. Available: <https://climate.nasa.gov/evidence/>
- [29] “The Effects of Climate Change,” NASA Global Climate Change and Global Warming: Vital Signs of the Planet. Accessed: Jul. 23, 2022. [Online]. Available: <https://climate.nasa.gov/effects/>
- [30] UNFCCC, “Adoption of the Paris Agreement,” 21st Conference of the Parties, Paris: United Nations, 2015.
- [31] “The Paris Agreement,” unfccc.int. Accessed: Jul. 26, 2022. [Online]. Available: <https://unfccc.int/process-and-meetings/the-paris-agreement/the-paris-agreement>
- [32] IPCC, “Mitigation Pathways Compatible with 1.5°C in the Context of Sustainable Development,” in *Global Warming of 1.5°C: IPCC Special Report on Impacts of Global Warming of 1.5°C above Pre-industrial Levels in Context of Strengthening Response to Climate Change, Sustainable Development, and Efforts to Eradicate Poverty*, Cambridge: Cambridge University Press, 2022, pp. 93–174. doi: 10.1017/9781009157940.004.
- [33] IEA, “Key World Energy Statistics 2021,” IEA, Paris, 2021. Accessed: Jul. 27, 2022. [Online]. Available: <https://www.iea.org/reports/key-world-energy-statistics-2021>

- [34] J. M. Morales, A. J. Conejo, H. Madsen, P. Pinson, and M. Zugno, “Introduction,” in *Integrating Renewables in Electricity Markets: Operational Problems*, Boston, MA: Springer US, 2014, pp. 1–13. doi: 10.1007/978-1-4614-9411-9_1.
- [35] C. Mac Domhnaill and L. Ryan, “Towards renewable electricity in Europe: Revisiting the determinants of renewable electricity in the European Union,” *Renew. Energy*, vol. 154, pp. 955–965, Jul. 2020, doi: 10.1016/j.renene.2020.03.084.
- [36] Eurostat, “Electricity production capacities for renewables and wastes,” Apr. 21, 2022, Eurostat. [Online]. Available: https://ec.europa.eu/eurostat/databrowser/view/NRG_INF_EPCRW/default/table?lang=en&category=nrg.nrg_quant.nrg_quanta.nrg_inf
- [37] Eurostat, “Share of energy from renewable sources,” Apr. 20, 2022, Eurostat. [Online]. Available: https://ec.europa.eu/eurostat/databrowser/view/NRG_IND_REN/default/table?lang=en&category=nrg.nrg_quant.nrg_quanta.nrg_ind.nrg_ind_share
- [38] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca, F. J. Martinez-de-Pison, and F. Antonanzas-Torres, “Review of photovoltaic power forecasting,” *Sol. Energy*, vol. 136, pp. 78–111, Oct. 2016, doi: 10.1016/j.solener.2016.06.069.
- [39] M. Q. Raza, M. Nadarajah, and C. Ekanayake, “On recent advances in PV output power forecast,” *Sol. Energy*, vol. 136, pp. 125–144, Oct. 2016, doi: 10.1016/j.solener.2016.06.073.
- [40] I. González-Aparicio and A. Zucker, “Impact of wind power uncertainty forecasting on the market integration of wind energy in Spain,” *Appl. Energy*, vol. 159, pp. 334–349, Dec. 2015, doi: 10.1016/j.apenergy.2015.08.104.
- [41] 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,” *Renew. Sustain. Energy Rev.*, vol. 81, pp. 912–928, Jan. 2018, doi: 10.1016/j.rser.2017.08.017.
- [42] Π. Σ. Γεωργιλιάκης, *Σύγχρονα Συστήματα Μεταφοράς και Διανομής Ηλεκτρικής Ενέργειας*. Αθήνα: Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών (ΣΕΑΒ), 2015. [Online]. Available: <https://repository.kallipos.gr/handle/11419/2013>
- [43] J. M. Morales, A. J. Conejo, H. Madsen, P. Pinson, and M. Zugno, “Renewable Energy Sources—Modeling and Forecasting,” in *Integrating Renewables in Electricity Markets: Operational Problems*, Boston, MA: Springer US, 2014, pp. 15–56. doi: 10.1007/978-1-4614-9411-9_2.
- [44] M. N. Akhter, S. Mekhilef, H. Mokhlis, and N. Mohamed Shah, “Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques,” *IET Renew. Power Gener.*, vol. 13, no. 7, pp. 1009–1023, Mar. 2019, doi: 10.1049/iet-rpg.2018.5649.
- [45] 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,” *Renew. Sustain. Energy Rev.*, vol. 124, p. 109792, May 2020, doi: 10.1016/j.rser.2020.109792.
- [46] J. Zhang, A. Florita, B.-M. Hodge, S. Lu, H. F. Hamann, V. Banunarayanan, and A. M. Brockway, “A suite of metrics for assessing the performance of solar power forecasting,” *Sol. Energy*, vol. 111, pp. 157–175, Jan. 2015, doi: 10.1016/j.solener.2014.10.016.
- [47] B. Hassibi and D. Stork, “Second order derivatives for network pruning: Optimal Brain Surgeon,” in *Advances in Neural Information Processing Systems*, 1992, vol. 5. [Online]. Available: <https://proceedings.neurips.cc/paper/1992/file/303ed4c69846ab36c2904d3ba8573050-Paper.pdf>
- [48] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning representations by back-propagating errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, Oct. 1986, doi: 10.1038/323533a0.

- [49] R. Rojas, “The Backpropagation Algorithm,” in *Neural Networks*, Berlin, Heidelberg: Springer Berlin Heidelberg, 1996, pp. 149–182. doi: 10.1007/978-3-642-61068-4_7.
- [50] P. S. Georgilakis, “Transformer Design Optimization,” in *Spotlight on Modern Transformer Design*, London: Springer London, 2009, pp. 331–376. doi: 10.1007/978-1-84882-667-0_7.
- [51] G. I. Diaz, A. Fokoue-Nkoutche, G. Nannicini, and H. Samulowitz, “An effective algorithm for hyperparameter optimization of neural networks,” *IBM J. Res. Dev.*, vol. 61, no. 4/5, pp. 9:1-9:11, Jul. 2017, doi: 10.1147/JRD.2017.2709578.
- [52] J. Bergstra and Y. Bengio, “Random Search for Hyper-Parameter Optimization,” *J. Mach. Learn. Res.*, vol. 13, no. 2, pp. 281–305, 2012, [Online]. Available: <http://jmlr.org/papers/v13/bergstral2a.html>
- [53] T. Kluyver, B. Ragan-Kelley, F. Pérez, B. Granger, M. Bussonnier, J. Frederic, K. Kelley, J. Hamrick, J. Grout, S. Corlay, P. Ivanov, D. Avila, S. Abdalla, C. Willing, and Jupyter Development Team, “Jupyter Notebooks – a publishing format for reproducible computational workflows,” in *Positioning and Power in Academic Publishing: Players, Agents and Agendas*, F. Loizides and B. Schmidt, Eds. IOS Press, 2016, pp. 87–90. doi: 10.3233/978-1-61499-649-1-87.
- [54] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, “Extreme learning machine: a new learning scheme of feedforward neural networks,” in *2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No.04CH37541)*, 2004, vol. 2, pp. 985–990. doi: 10.1109/IJCNN.2004.1380068.
- [55] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, “Extreme learning machine: Theory and applications,” *Neurocomputing*, vol. 70, no. 1–3, pp. 489–501, Dec. 2006, doi: 10.1016/j.neucom.2005.12.126.
- [56] D. Serre, “Norms,” in *Matrices: Theory and Applications*, New York, NY: Springer New York, 2010, pp. 127–148. doi: 10.1007/978-1-4419-7683-3_7.
- [57] M. K. Behera, I. Majumder, and N. Nayak, “Solar photovoltaic power forecasting using optimized modified extreme learning machine technique,” *Eng. Sci. Technol. an Int. J.*, vol. 21, no. 3, pp. 428–438, Jun. 2018, doi: 10.1016/j.jestch.2018.04.013.
- [58] J. Kennedy and R. Eberhart, “Particle swarm optimization,” in *Proceedings of ICNN’95 - International Conference on Neural Networks*, 1995, vol. 4, pp. 1942–1948. doi: 10.1109/ICNN.1995.488968.
- [59] C. Zaiontz, “Real Statistics Resource Pack software (Release 8.3.1).” [Online]. Available: <https://www.real-statistics.com/>
- [60] F. Chollet and others, “Keras.” 2015. [Online]. Available: <https://keras.io>
- [61] T. Szandała, “Review and Comparison of Commonly Used Activation Functions for Deep Neural Networks,” in *Bio-inspired Neurocomputing*, A. K. Bhoi, P. K. Mallick, C.-M. Liu, and V. E. Balas, Eds. Singapore: Springer Singapore, 2021, pp. 203–224. doi: 10.1007/978-981-15-5495-7_11.
- [62] D. P. Kingma and J. Ba, “Adam: A Method for Stochastic Optimization,” in *3rd International Conference on Learning Representations, ICLR 2015, San Diego, CA, USA, May 7-9, 2015, Conference Track Proceedings*, 2015. [Online]. Available: <http://arxiv.org/abs/1412.6980>
- [63] R. Rawat, K. Vora, M. Manry, and G. Eapi, “Multi-variable Neural Network Forecasting Using Two Stage Feature Selection,” in *2014 13th International Conference on Machine Learning and Applications*, Dec. 2014, pp. 243–250. doi: 10.1109/ICMLA.2014.45.
- [64] T. Dozat, “Incorporating Nesterov Momentum into Adam,” in *4th International Conference on Learning Representations, Workshop Track*, 2016.