



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

**Πρόβλεψη αιολικής παραγωγής με τη χρήση τεχνητών
νευρωνικών δικτύων**

Διπλωματική Εργασία

Συρανίδης Γεώργιος

Επιβλέπων: Μπαργιώτας Δημήτριος

Μάρτιος 2024



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ


**Πρόβλεψη αιολικής παραγωγής με τη χρήση τεχνητών
νευρωνικών δικτύων**

Διπλωματική Εργασία

Συρανίδης Γεώργιος

Επιβλέπων: Μπαργιώτας Δημήτριος

Μάρτιος 2024



UNIVERSITY OF THESSALY
SCHOOL OF ENGINEERING
DEPARTMENT OF ELECTRICAL AND COMPUTER ENGINEERING

Wind power forecasting using artificial neural networks

Diploma Thesis

Syranidis Georgios

Supervisor: Bargiotas Dimitrios

March 2024

Εγκρίνεται από την Επιτροπή Εξέτασης:

Επιβλέπων **Μπαργιώτας Δημήτριος**

Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Μέλος **Σπυρίδων Λουτρίδης**

Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Μέλος **Ασπασία Δασκαλοπούλου**

Αναπληρώτρια Καθηγήτρια, Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον επιβλέποντα Καθηγητή κ. Δημήτριο Μπαργιώτα και τον αείμνηστο Επίκουρο Καθηγητή Ιωάννη Παναπακίδη για την καθοδήγηση και την συμβολή του στην ολοκλήρωση της διπλωματικής εργασίας. Οφείλω εξίσου να ευχαριστήσω τον υποψήφιο διδάκτορα κ. Γεώργιο Γούση για τις πολύτιμες συμβουλές του σχετικά με τον κλάδο, καθώς και όλους τους διδάσκοντες του προπτυχιακού προγράμματος για τις γνώσεις που παρείχαν και για την συνεργασία που υπήρξε.

ΥΠΕΥΘΥΝΗ ΔΗΛΩΣΗ ΠΕΡΙ ΑΚΑΔΗΜΑΪΚΗΣ ΔΕΟΝΤΟΛΟΓΙΑΣ ΚΑΙ ΠΝΕΥΜΑΤΙΚΩΝ ΔΙΚΑΙΩΜΑΤΩΝ

«Με πλήρη επίγνωση των συνεπειών του νόμου περί πνευματικών δικαιωμάτων, δηλώνω ρητά ότι η παρούσα διπλωματική εργασία, καθώς και τα ηλεκτρονικά αρχεία και πηγαίοι κώδικες που αναπτύχθηκαν ή τροποποιήθηκαν στα πλαίσια αυτής της εργασίας, αποτελεί αποκλειστικά προϊόν προσωπικής μου εργασίας, δεν προσβάλλει κάθε μορφής δικαιώματα διανοητικής ιδιοκτησίας, προσωπικότητας και προσωπικών δεδομένων τρίτων, δεν περιέχει έργα/εισφορές τρίτων για τα οποία απαιτείται άδεια των δημιουργών/δικαιούχων και δεν είναι προϊόν μερικής ή ολικής αντιγραφής, οι πηγές δε που χρησιμοποιήθηκαν περιορίζονται στις βιβλιογραφικές αναφορές και μόνον και πληρούν τους κανόνες της επιστημονικής παράθεσης. Τα σημεία όπου έχω χρησιμοποιήσει ιδέες, κείμενο, αρχεία ή/και πηγές άλλων συγγραφέων, αναφέρονται ευδιάκριτα στο κείμενο με την κατάλληλη παραπομπή και η σχετική αναφορά περιλαμβάνεται στο τμήμα των βιβλιογραφικών αναφορών με πλήρη περιγραφή. Δηλώνω επίσης ότι τα αποτελέσματα της εργασίας δεν έχουν χρησιμοποιηθεί για την απόκτηση άλλου πτυχίου. Αναλαμβάνω πλήρως, ατομικά και προσωπικά, όλες τις νομικές και διοικητικές συνέπειες που δύναται να προκύψουν στην περίπτωση κατά την οποία αποδειχθεί, διαχρονικά, ότι η εργασία αυτή ή τμήμα της δεν μου ανήκει διότι είναι προϊόν λογοκλοπής».

Ο Δηλών

Συρανίδης Γεώργιος

Διπλωματική Εργασία

Πρόβλεψη αιολικής παραγωγής με τη χρήση τεχνητών νευρωνικών δικτύων

Συρανίδης Γεώργιος

Περίληψη

Η διαρκώς αυξανόμενη απαίτηση ηλεκτρικής ενέργειας για την κάλυψη της τεχνολογικής επέκτασης σε παγκόσμια κλίμακα έχει στρέψει την επιστημονική κοινότητα στην ανάπτυξη βιώσιμων μέσων παραγωγής της. Στο επίκεντρο αυτής της προσπάθειας βρίσκονται, μεταξύ άλλων, και οι ανανεώσιμες πηγές ενέργειας, όπως η ηλιακή και η αιολική, που διαθέτουν ανεξάντλητους πόρους. Ειδικότερα, η αιολική ενέργεια είναι μια από τις ευρέως εκμεταλλεύσιμες εναλλακτικές μορφές ενέργειας, γεγονός που γίνεται σαφές μέσω της διαρκούς αύξησης της εγκατεστημένης ισχύος σε Ευρωπαϊκή και παγκόσμια κλίμακα.

Παρά την σημαντικότητα της αιολικής ενέργειας, πρέπει να αναφερθούν ζητήματα που προκύπτουν λόγω της διακοπτότητας και μεταβλητότητας της. Στο πλαίσιο της διατήρησης και βελτίωσης της αξιοπιστίας των συστημάτων ηλεκτρικής ενέργειας, γίνεται προσπάθεια αντιστάθμισης αυτών των χαρακτηριστικών. Κύριο εργαλείο αντιμετώπισης αυτών είναι η ανάπτυξη και εφαρμογή μεθόδων πρόβλεψης αιολικής ισχύος. Σε παγκόσμιο επίπεδο, εδώ και δεκάδες έτη, έχουν προταθεί και εφαρμοστεί ποικίλα μοντέλα πρόβλεψης. Ειδικότερα λόγω της τεχνολογικής ανάπτυξης των τελευταίων ετών, η χρήση τεχνικών μηχανικής μάθησης φαίνεται να αποτελεί σημαντικό εργαλείο πρόβλεψης. Μέσω μαθηματικών και προγραμματιστικών μοντέλων πρόβλεψης στοχεύεται η οργάνωση της ηλεκτροπαραγωγής και η βέλτιστη κατανομή πόρων. Η ανάπτυξη νευρωνικών δικτύων, ικανών να μοντελοποιούν την μεταβλητότητα του ανέμου, έχει επιφέρει σημαντική πρόοδο στο τομέα της πρόβλεψης.

Στόχος της παρούσας εργασίας είναι να εξεταστεί η συνεισφορά των νευρωνικών δικτύων στην ανάπτυξη μοντέλων πρόβλεψης αιολικής ισχύος. Συγκεκριμένα, αναπτύχθηκαν νευρωνικά δίκτυα διαφόρων ειδών, ώστε να εξεταστεί η απόδοσή τους για πραγματικές προβλέψεις από αιολικό πάρκο στην Ελλάδα. Χρησιμοποιώντας συνελκτικά δίκτυα, δίκτυα μακράς βραχυπρόθεσμης μνήμης και συνδυασμό αυτών, εξετάστηκε η εγκυρότητα των παραγομένων προβλέψεων, σε σύγκριση με τα αντίστοιχα αποτελέσματα της μεθόδου παραμένουσας τιμής. Η αξιολόγηση πραγματοποιήθηκε σε δύο άξονες, στις σημειακές προβλέψεις και στις

πιθανοτικές. Αυτό σχετίζεται με το είδος των εξαγόμενων δεδομένων και η σημασία της κάθε μίας ποικίλει ανάλογα με τον εκάστοτε στόχο της πρόβλεψης. Οι προβλέψεις που λήφθηκαν από τα νευρωνικά δίκτυα ήταν πιο ακριβείς και αξιόπιστες σε σχέση με την συγκρινόμενη μέθοδο. Τόσο με γνώμονα τις σημειακές τιμές, όσο και με τις πιθανοτικές, τα τελικά μοντέλα προέβλεψαν αποδοτικά την ωριαία παραγωγή. Τέλος, αναλύονται συμπεράσματα με γνώμονα την τρέχουσα βιβλιογραφία και την έρευνα ως προς την εξέλιξη των μοντέλων και την πρόοδο του τομέα.

Λέξεις-κλειδιά:

αιολική ενέργεια, πρόβλεψης παραγωγής ενέργειας, πιθανοτική πρόβλεψη, σημειακή πρόβλεψη, νευρωνικά δίκτυα, πιθανοτική πρόβλεψη παραγωγής ενέργειας

Diploma Thesis

Wind power forecasting using artificial neural networks

Syranidis Georgios

Abstract

The ever-increasing demand for electricity to meet technological expansion on a global scale has directed the scientific community to develop sustainable means of its production. At the center of this effort are, among others, renewable energy sources, such as solar and wind, which have inexhaustible resources. In particular, wind energy is one of the widely exploitable alternative forms of energy, a fact that becomes clear through the continuous increase of installed capacity on a European and global scale.

Despite the importance of wind energy, issues arising due to its intermittency and variability must be mentioned. In the context of maintaining and improving the reliability of electrical power systems, an attempt is made to compensate for these characteristics. The main tool for dealing with these is the development and application of wind power forecasting methods. Globally, for decades, various forecasting models have been proposed and applied. In particular due to the technological development of recent years, the use of machine learning techniques appears to be an important predictive tool. Through mathematical and programming prediction models, the organization of electricity production and the optimal allocation of resources are targeted. The development of neural networks capable of modeling wind variability has brought about significant progress in the field of forecasting.

The aim of this thesis is to examine the contribution of neural networks to the development of wind power forecasting models. In particular, neural networks of various kinds were developed in order to examine their performance for real wind farm forecasts in Greece. Using convolutional networks, long short-term memory networks and a combination of these, the validity of the predictions produced was examined. The evaluation was carried out on two axes, point forecast and probabilistic one. This is related to the type of data extracted and the importance of each one varies depending on the goal of the prediction. The predictions received from the neural networks were more accurate and reliable than the compared one method. Both based on point values and probabilistic ones, the final model effectively predicted hourly production. Finally, conclusions are analyzed with guided by current literature

and research as to the evolution of models and the progress of the sector.

Keywords:

wind power, forecasting wind power, point forecasts, probabilistic forecasts, neural networks, probabilistic wind power prediction

Πίνακας περιεχομένων

Ευχαριστίες	ix
Περίληψη	xii
Abstract	xiv
Πίνακας περιεχομένων	xvii
Κατάλογος σχημάτων	xxi
Κατάλογος πινάκων	xxiii
Συντομογραφίες	xxv
1 Εισαγωγή	1
1.1 Εισαγωγή	1
1.2 Σημασία και είδη της πρόβλεψης	1
1.3 Μεταβαλλόμενη τιμή της ενέργειας	2
1.4 Χρονική κατηγοριοποίηση προβλέψεων	3
1.5 Αξιολόγηση της πρόβλεψης	5
1.5.1 Αξιολόγηση σημειακής πρόβλεψης	5
1.5.2 Αξιολόγηση πιθανοτικής πρόβλεψης	6
2 Σημειακά Μοντέλα	9
2.1 Φυσική Προσέγγιση	9
2.2 Στατιστική Προσέγγιση	11
2.2.1 Μοντέλα Χρονοσειρών	11
2.2.2 Στατιστική προσέγγιση με χρήση τεχνητής νοημοσύνης	12

3	Πιθανοτικά Μοντέλα	17
3.1	Παραμετρική Προσέγγιση	17
3.2	Μη Παραμετρική προσέγγιση	18
3.2.1	Πιθανοτική μέθοδος παραμένουσας τιμής	18
3.2.2	Παλινδρόμηση ποσοστημορίου (Quantile Regression)	18
3.2.3	Εκτίμηση Πυκνότητας Πυρήνα (Kernel Density Estimation)	20
3.2.4	Εκτίμηση Άνω και Κάτω ορίου	21
3.2.5	Μέθοδοι Αυτοδύναμης Εκκίνησης (Bootstrapping)	22
4	Μαθηματική θεμελίωση μοντέλου πρόβλεψης	23
4.1	Εισαγωγή	23
4.2	Μηχανική Μάθηση	24
4.2.1	Συχνά προβλήματα	24
4.3	Είσοδοι μοντέλων πρόβλεψης	25
4.4	Αλγόριθμοι βελτιστοποίησης	27
4.4.1	Στοχαστική κλίση καθόδου (SGD)	27
4.4.2	Αλγόριθμος προσαρμοστικής κλίσης (ADAGRAD)	27
4.4.3	Αλγόριθμος προσαρμοστικής στιγμιαίας εκτίμησης (ADAM)	28
4.5	Συναρτήσεις Ενεργοποίησης	29
4.6	Συνελκτικά Νευρωνικά Δίκτυα	31
4.7	Αναδρομικά Νευρωνικά Δίκτυα	31
4.7.1	Πρόβλημα μηδενιζόμενων κλίσεων	32
4.7.2	Δίκτυα μακράς-βραχύχρονης μνήμης	33
5	Ανάπτυξη μοντέλου πρόβλεψης αιολικής ισχύος	37
5.1	Λογισμικά	37
5.2	Αναπτυχθέντα μοντέλα πρόβλεψης	38
5.3	Μεθοδολογία αξιολόγησης δικτύων	42
5.4	Διαθέσιμα δεδομένα εισόδου	44
5.5	Παραμετροποίηση μοντέλων	46
5.6	Αποτελέσματα ωριαίας πρόβλεψης	48
5.6.1	Αποτελέσματα σημειακής πρόβλεψης	48
5.6.2	Αποτελέσματα πιθανοτικής πρόβλεψης	56

5.6.3	Τροποποίηση διαστήματος κατανομής	63
6	Συμπεράσματα	65
6.1	Σύνοψη και συμπεράσματα	66
6.2	Μελλοντικές επεκτάσεις	66
	Βιβλιογραφία	69

Κατάλογος σχημάτων

1.1	Κατηγοριοποίηση των προς ανάλυση μοντέλων πρόβλεψης	3
1.2	CWC για διάφορες τιμές η για PINAW=40%	8
2.1	Σχηματική αναπαράσταση μοντέλου φυσικής προσέγγισης «Previento» [1].	10
2.2	Σχηματική αναπαράσταση ενδεικτικού μοντέλου στατιστικής προσέγγισης.	11
2.3	Μη γραμμικό μοντέλο νευρώνα [2]	13
2.4	Πλήρως διασυνδεδεμένο νευρωνικό δίκτυο με 2 κρυφά επίπεδα [2]	14
3.1	Παράδειγμα ωριαίας πιθανοτικής πρόβλεψης ως προς 5 εκατοστημόρια . .	19
3.2	Συμβολική αναπαράσταση νευρωνικού δικτύου για εύρεση Άνω και Κάτω ορίου του ΔΠ	21
4.1	Σχηματική απεικόνιση των διαθέσιμων μετρήσεων (ταχύτητα ανέμου ως από- σταση από το μηδέν, γωνία πρόσπτωσης και κανονικοποιημένη παραγόμενη ισχύς ως χρωματική κλίματα).	26
4.2	Γραφική αναπαράσταση συχνότερων συναρτήσεων ενεργοποίησης	29
4.3	Πλήρως συνδεδεμένο αναδρομικό δίκτυο 2 εισόδων, με 2 κρυφούς νευρώνες και ένα νευρώνα εξόδου. Οι συνδέσεις ανάδρασης επισημαίνονται με χρώμα [2].	33
4.4	Σχηματική αναπαράσταση LSTM κόμβου.	35
5.1	Ενδεικτική κατανομή Γάμμα - τα διάφορα διαστήματα κάλυψης φαίνονται με χρώμα.	39
5.2	Γραφική αναπαράσταση συνελκτικού δικτύου	41
5.3	Γραφική αναπαράσταση δικτύου LSTM	42
5.4	Γραφική αναπαράσταση δικτύου CNN-LSTM	43
5.5	Γραφική αναπαράσταση δικτύου LSTM-CNN	43

5.6	Αυτοσυσχέτιση μετρήσεων ισχύος βήματος μίας ώρας	46
5.7	Γραφική αναπαράσταση μηνιαίας ανάλυσης σφάλματος μεθόδου Persistence και νευρωνικών δικτύων - MAE (kW) και MARNE (%)	50
5.8	Κατανομή σφαλμάτων μέσω της μεθόδου παραμένουσας τιμής για ωριαία πρόβλεψη αιολικής ενέργειας.	52
5.9	Κατανομή σφαλμάτων (kW) μέσω δικτύου LSTM για ωριαία πρόβλεψη αιολικής ενέργειας.	53
5.10	Κατανομή σφαλμάτων (kW) μέσω δικτύου CNN για ωριαία πρόβλεψη αιολικής ενέργειας.	53
5.11	Κατανομή σφαλμάτων (kW) μέσω δικτύου CNN-LSTM για ωριαία πρόβλεψη αιολικής ενέργειας.	54
5.12	Κατανομή σφαλμάτων (kW) μέσω δικτύου LSTM-CNN για ωριαία πρόβλεψη αιολικής ενέργειας.	54
5.13	Ιστόγραμμα συχνότητας σφαλμάτων (kW) τριών τροποποιήσεων των εποχών εκπαίδευσης LSTM δικτύων για ωριαία πρόβλεψη αιολικής ενέργειας.	55
5.14	Μηνιαία ανάλυση πιθανοτικής απόδοσης - PICP(%) και PINAW(%)	58
5.15	Πραγματική μέτρηση (kW) και προβλεπόμενη μέση τιμή CNN Δικτύου για το διάστημα 14/1/2019-16/1/2019.	59
5.16	Πραγματική μέτρηση (kW) και προβλεπόμενη μέση τιμή LSTM Δικτύου για το διάστημα 14/1/2019-16/1/2019.	59
5.17	Διαστήματα πρόβλεψης, μέση και πραγματική τιμή παραγωγής (kW) CNN δικτύου τον 10/2019	60
5.18	Διαστήματα πρόβλεψης, μέση και πραγματική τιμή παραγωγής (kW) LSTM δικτύου τον 10/2019	60
5.19	Διαστήματα πρόβλεψης, μέση και πραγματική τιμή παραγωγής (kW) CNN-LSTM δικτύου τον 10/2019	61
5.20	Διαστήματα πρόβλεψης, μέση και πραγματική τιμή παραγωγής (kW) LSTM-CNN δικτύου τον 10/2019	61

Κατάλογος πινάκων

1.1	Χρονική κατηγοριοποίηση προβλέψεων.	4
3.1	Αποτελέσματα χρήσης νευρωνικών δικτύου με χρήση αλγόριθμου Particle Swarm Optimization (PSO) [3]	22
5.1	Αποτελέσματα δικτύων CNN-LSTM και CNN για εισαγωγή ή μη της τρέχουσας ταχύτητας και διεύθυνσης ανέμου σαν είσοδο δικτύου.	46
5.2	Σημειακά σφάλματα όλων των διαθέσιμων μοντέλων	49
5.3	Μηνιαία ανάλυση σημειακού σφάλματος ενδοωριαίας πρόβλεψης νευρωνικών δικτύων - Δίνονται τα MAE (kW) και MARNE (%).	51
5.4	Πιθανοτικά αποτελέσματα όλων των διαθέσιμων μοντέλων	56
5.5	Μηνιαία ανάλυση πιθανοτικού σφάλματος ωριαίας πρόβλεψης νευρωνικών δικτύων - PICP(%) και PINAW(%).	62
5.6	Αποτελέσματα πιθανοτικής πρόβλεψης LSTM-CNN δικτύου για διάφορα ποσοστά κάλυψης της κατανομής - PICP(%) και PINAW(%).	64

Συντομογραφίες

ΑΠΕ	Ανανεώσιμες Πηγές Ενέργειας
βλ.	βλέπε
ΔΠ	Διάστημα πρόβλεψης
κ.α.	και άλλα
κ.λπ.	και λοιπά
ΣΗΕ.	Σύστημα Ηλεκτρικής Ενέργειας
ACE	Absolute coverage error
ADAGRAD	Adaptive gradient
ADAM	Adaptive moment estimation
ANN	Artificial neural network
AR	Autoregressive
ARIMA	Auto regressive integrated moving average
CNN	Convolutional neural network
CWC	Coverage Width Criterion
FFBP	Feed-forward back propagation
KDE	Kernel Density Estimation
LSTM	Long-shortterm memory
LUBE	Lower upper bound estimation
MA	Moving average
MAE	Mean absolute error
MAPE	Mean absolute percentage error
MARNE	Mean Absolute Range Normalized Error
MSE	Mean squared error
NWP	Numerical Weather Prediction
PICP	Prediction interval coverage probability

PINAW	Prediction interval nominal average width
PSO	Particle swarm optimization
QR	Quantile regression
RBF	Radial basis function
ReLU	Rectified linear unit
RMSE	Root-mean-square error
SGD	Stochastic gradient descent
SVM	Support Vector Machines

Κεφάλαιο 1

Εισαγωγή

1.1 Εισαγωγή

Οι Ανανεώσιμες Πηγές Ενέργειας, και ιδιαιτέρως η Αιολική Ενέργεια, βρίσκονται πλέον στο επίκεντρο των ενεργειακών ζητημάτων σε παγκόσμιο επίπεδο. Η ταχεία αύξηση των ενεργειακών αναγκών των περισσότερων χωρών σε συνδυασμό με την ανάγκη μείωσης και απεξάρτησης από συμβατικά καύσιμα, όπως το φυσικό αέριο και ο άνθρακας, οδηγούν σε αυξημένη ανάγκη χρήσης ΑΠΕ [4]. Η αιολική ενέργεια, όντας μια ευκόλως εκμεταλλεύσιμη μορφή ενέργειας, αποτελεί το ταχύτερα αναπτυσσόμενο μέσο παραγωγής ηλεκτρικής ισχύος. Στην Ευρώπη, κατά το 2020, η συνολική εγκατεστημένη αιολική ισχύς έφτασε τα 220 GW, καλύπτοντας το 16.4% της ζήτησης ηλεκτρικής ισχύος [5]. Με βάση τους ευρωπαϊκούς στόχους για το κλίμα, αναμένεται να ανέλθει στα 397 GW έως το 2030, καλύπτοντας το 30% της ζήτησης στην Ευρωπαϊκή Ένωση [6]. Παρόλα αυτά, λόγω της στοχαστικής φύσης του ανέμου, η ένταξη αιολικής ενέργειας στο δίκτυο δημιουργεί τεχνικές δυσκολίες. Στην προσπάθεια αντιμετώπισης αυτών και βελτιστοποίησης της παραγωγής αιολικής ισχύος, αναπτύσσονται μέθοδοι πρόβλεψης της.

1.2 Σημασία και είδη της πρόβλεψης

Η ένταξη συστημάτων παραγωγής ηλεκτρικής ισχύος μέσω αιολικής ενέργειας σε ένα υπάρχον Σύστημα Ηλεκτρικής Ενέργειας προϋποθέτει την διατήρηση της αξιοπιστίας και της ομαλής λειτουργίας του. Κάθε ΣΗΕ οφείλει να παρέχει στους καταναλωτές ηλεκτρική ενέργεια με το ελάχιστο δυνατό κόστος και τις ελάχιστες οικολογικές επιπτώσεις, εξασφα-


λίζοντας σταθερή τάση, σταθερή συχνότητα και υψηλή αξιοπιστία τροφοδότησης. Συνεπώς, η εκμετάλλευση της αιολικής ενέργειας πρέπει να γίνεται με τέτοιο τρόπο ώστε να διατηρούνται τα παραπάνω χαρακτηριστικά του ΣΗΕ [7]. Σε αντίθεση με άλλους, συμβατικούς, τρόπους παραγωγής ηλεκτρικής ισχύος (για παράδειγμα ατμομηχανές, υδροηλεκτρικά φράγματα, πυρηνική ενέργεια κ.λπ.), η αιολική ενέργεια δεν μπορεί να προγραμματιστεί και να ρυθμιστεί από τους διαχειριστές του ΣΗΕ. Συνεπώς, οφείλουν να λάβουν υπόψιν την τυχαιότητα και την μεταβλητότητα του ανέμου ώστε να διατηρήσουν την αξιοπιστία του δικτύου μέσω μεθόδων πρόβλεψης της αιολικής ενέργειας. Τα μοντέλα πρόβλεψης που έχουν αναπτυχθεί για την αντιμετώπιση αυτού του ζητήματος ομαδοποιούνται βάσει των δεδομένων που παρέχουν στον χρήστη σε **Σημειακά** και **Πιθανοτικά**. Στο Σχήμα 1.1 παρουσιάζεται η κατηγοριοποίηση των μεθόδων που θα αναλυθεί μετέπειτα.

Τα Σημειακά Μοντέλα (Deterministic ή Point forecasts) είναι ευρέως χρησιμοποιούμενα εδώ και δεκάδες χρόνια, παρέχοντας σημειακά δεδομένα εξόδου (single-valued) για την προβλεπόμενη μεταβλητή. Σε γενικές γραμμές είναι απλούστερα στην υλοποίηση και χρήση τους και η αξιολόγηση τους βασίζεται στην απόκλιση μεταξύ των προβλεπόμενων και των πραγματικών τιμών με χρήση απλών στατιστικών δεικτών.

Τα Πιθανοτικά Μοντέλα βρίσκονται στο επίκεντρο της έρευνας στον τομέα της πρόβλεψης αιολικής ενέργειας, παρέχοντας πληροφορία σχετικά με την αβεβαιότητα της πρόβλεψης τους μέσω ενός συνόλου πιθανών καταστάσεων που μπορεί να προκύψουν με τις αντίστοιχες πιθανότητες τους. Λόγω αυτής της πληροφορίας, πλεονεκτούν σημαντικά στην αγορά ενέργειας σε σχέση με τα σημειακά μοντέλα [8, 9].

1.3 Μεταβλλόμενη τιμή της ενέργειας

1. Το κόστος παραγωγής της ηλεκτρικής ενέργειας διαφέρει πολλές φορές ανάλογα με την τεχνολογία που χρησιμοποιείται. Για παράδειγμα, τα ηλιακά πάρκα στις ΗΠΑ έχουν κόστος παραγωγής 23\$/MWh, τα αιολικά έχουν κόστος 27\$/MWh, ενώ το κόστος για μια συμβατική μονάδα ορυκτών καυσίμων ανέρχεται περίπου στα 44\$/MWh [10].
2. Το φορτίο του συστήματος μεταβάλλεται από ώρα σε ώρα.
3. Η ηλεκτρική ενέργεια δεν μπορεί να αποθηκευτεί με οικονομικό τρόπο γι αυτό το λόγο πρέπει να καταναλώνεται τη στιγμή που παράγεται.



Σχήμα 1.1: Κατηγοριοποίηση των προς ανάλυση μοντέλων πρόβλεψης

4. Πολύ συχνά προκαλούνται ανισορροπίες μεταξύ της προσφοράς και της ζήτησης εξαιτίας συμβάντων όπως ξαφνική απώλεια μονάδων, του δικτύου ή ακραία φαινόμενα.
5. Η λειτουργία των μονάδων διέπεται από τεχνικούς περιορισμούς. Κάποιες φορές όταν το φορτίο είναι πολύ χαμηλό, η τιμή στην αγορά μηδενίζεται ή γίνεται ακόμα και αρνητική. Αυτό συμβαίνει διότι είναι οικονομικότερο να μείνει μια μονάδα σε λειτουργία παρά να κλείσει και να επαναλειτουργήσει αργότερα.

1.4 Χρονική κατηγοριοποίηση προβλέψεων

Τα διάφορα μοντέλα που αναπτύσσονται αποσκοπούν σε πρόβλεψη της αιολικής ενέργειας σε διαφορετικές μελλοντικές στιγμές. Η περίοδος που μεσολαβεί μεταξύ της πρόβλεψης εξόδου και της πραγματικής μέτρησης ορίζεται ως ορίζοντας πρόβλεψης. Αναλόγως του χρονικού ορίζοντα τους, κατηγοριοποιούμε τις προβλέψεις σε Άμεσες, Βραχυπρόθεσμες, Μεσοπρόθεσμες και Μακροπρόθεσμες, όπως φαίνονται στον Πίνακα 1.1 [11, 12]. Με βάση τα διάφορα ζητήματα που προκύπτουν λόγω της χρήσης αιολικής ενέργειας, ο χρονικός ορίζοντας πρόβλεψης διαφόρων μοντέλων εξυπηρετεί διαφορετικές ανάγκες, μεταξύ των οποίων είναι η διαχείριση και επέκταση του δικτύου, η οργάνωση αγορών ηλεκτρικής ενέργειας και η συντήρηση του δικτύου. Να σημειωθεί πως οι χρονικοί ορίζοντες ταξινόμησης των μοντέλων δεν είναι αυστηρά καθορισμένοι στην βιβλιογραφία, και το ακριβές χρονικό εύρος κάθε κατηγορίας συχνά διαφέρει. Γενικά, ως Άμεσες θεωρούνται προβλέψεις

με ορίζοντα έως 1 ώρα και χρησιμεύουν στην εσωτερική ρύθμιση Α/Γ για απότομες μεταβολές ανέμου, στον έλεγχο αποθήκευσης φωτοβολταϊκών κ.λπ. Για ορίζοντα πρόβλεψης άνω της μίας ώρας χρησιμοποιούνται Βραχυπρόθεσμες προβλέψεις, ώστε να καθοριστεί η ημερήσια τιμή πώλησης στην αγορά ηλεκτρικής ενέργειας και αντίστοιχα οικονομικά ζητήματα αποστολής φορτίου. Μεσοπρόθεσμες προβλέψεις παρέχουν δεδομένα για μερικές ώρες έως και 1 εβδομάδα μπροστά και είναι ιδιαίτερες σημαντικές για την λήψη αποφάσεων ένταξης ή μη μονάδων παραγωγής στο ΣΗΕ και τον προγραμματισμό συντήρησης αιολικών ή ηλιακών σταθμών. Τέλος, οι μελέτες σκοπιμότητας κατασκευής νέων πάρκων ηλεκτρικής παραγωγής (ηλιακά, αιολικά κ.α.) και οι μακροχρόνιες αποφάσεις σχετικά με την μετάδοση και διανομή ενέργειας απαιτούν Μακροπρόθεσμα Μοντέλα Πρόβλεψης, τα οποία παρέχουν μικρότερη ακρίβεια λόγω της διακύμανσης του καιρού σε σχέση με τα προηγούμενα, αλλά μεγαλύτερο χρονικό ορίζοντα. Ερευνητικά είναι εμφανές πως η ακρίβεια των παραγόμενων προβλέψεων σχετίζεται άμεσα με τον ορίζοντα πρόβλεψης του εκάστοτε μοντέλου. Διατηρώντας τις υπόλοιπες παραμέτρους σταθερές, η αύξηση του ορίζοντα μειώνει την ακρίβεια τόσο των πιθανοτικών όσο και των σημειακών μοντέλων. Συνεπώς, με βάση όσα προαναφέρθηκαν γίνεται εμφανής η σημασία της εύρεσης του ιδανικού μοντέλου ανά περίπτωση για την στάθμιση σφάλματος και ορίζοντα πρόβλεψης [13].

Πίνακας 1.1: Χρονική κατηγοριοποίηση προβλέψεων.

Είδος	Ορίζοντας Πρόβλεψης	Παράδειγμα Εφαρμογής
Άμεσες	Μερικά λεπτά έως 1 ώρα	Εσωτερικές ρυθμίσεις της Α/Γ στις απότομες μεταβολές ανέμου
Βραχυπρόθεσμες	1 ώρα έως αρκετές ώρες	Ημερήσια τιμή πώλησης στην αγορά ηλεκτρικής ενέργειας
Μεσοπρόθεσμες	Αρκετές ώρες έως 1 εβδομάδα	Ένταξη ή μη μονάδων παραγωγής (Unit Commitment)
Μακροπρόθεσμες	1 εβδομάδα έως 1 έτος ή παραπάνω	Μελέτη σκοπιμότητας κατασκευής νέων πάρκων

1.5 Αξιολόγηση της πρόβλεψης

Η αξιολόγηση ενός μοντέλου είναι αναπόσπαστο τμήμα της ανάπτυξης και λειτουργίας του, τόσο για την βελτίωση του, όσο και για την σύγκριση του με άλλα μοντέλα. Δεδομένου ότι τα σημειακά και τα πιθανοτικά μοντέλα παράγουν διαφορετικού είδους πληροφορία, ο τρόπος αξιολόγησης τους διαφέρει.

1.5.1 Αξιολόγηση σημειακής πρόβλεψης

Όπως αναλύθηκε προηγουμένως, τα σημειακά μοντέλα, παράγουν σημειακές τιμές προβλεπόμενης παραγωγής ή ταχύτητας ανέμου. Λόγω της απλότητας του τελικού αποτελέσματος τους, η αξιολόγηση τους μπορεί να γίνει με απλούς δείκτες σφάλματος [8, 14]. Για πραγματική τιμή x_{obs} και προβλεπόμενη τιμή x_{pred} το σφάλμα ορίζεται ως εξής:

$$e_n = x_{pred} - x_{obs}$$

Βάση αυτού ορίζουμε τους συνηθέστερους δείκτες για N προβλέψεις. Αρχικά, το Μέσο Απόλυτο σφάλμα (Mean absolute error), ως μέση τιμή των απόλυτων τιμών των σφαλμάτων:

$$MAE = \frac{1}{N} \sum_{n=1}^N |e_n| \quad (1.1)$$

Το Μέσο Τετραγωνικό Σφάλμα (Mean square error), ως μέση τιμή του τετραγώνου των σφαλμάτων, το οποίο αξιολογεί τις τετραγωνικές αποκλίσεις των προβλεπόμενων τιμών από τις πραγματικές:

$$MSE = \frac{1}{N} \sum_{n=1}^N e_n^2 \quad (1.2)$$

Το Τυπικό Σφάλμα (Root mean square error), ως τετραγωνική ρίζα του MSE το οποίο είναι προτιμότερο του προηγουμένου καθώς άμεσα συγκρίσιμο με το x_{obs} και έχει τις ίδιες μονάδες μέτρησης:

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N e_n^2} \quad (1.3)$$

Το Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (Mean absolute percentage error), ως χαρακτηριστικό της ακρίβειας της πρόβλεψης:

$$MAPE = \frac{100}{N} \sum_{n=1}^N \left| \frac{e_n}{x_{n,obs}} \right| \% \quad (1.4)$$

Το μέσο κανονικοποιημένο σφάλμα απόλυτου εύρους (Mean Absolute Range Normalized Error) ως:

$$MARNE = \frac{1}{N} \sum_{n=1}^N \frac{|e_n|}{\max(x_{pred})} \cdot 100\% \quad (1.5)$$

1.5.2 Αξιολόγηση πιθανοτικής πρόβλεψης

Σε αντίθεση με τα σημειακά μοντέλα, η αξιολόγηση των πιθανοτικών μοντέλων είναι πιο περίπλοκη. Εφόσον μας παρέχουν επιπλέον πληροφορία για την αβεβαιότητα της πρόβλεψης, δεν είναι εφικτό να αξιολογηθούν με όσα αναφέραμε προηγουμένως. Βασικά αξιολογητικά κριτήρια ενός τέτοιου μοντέλου είναι η *Αξιοπιστία*, η *Αιχμηρότητα* και η *Ανάλυση* του.

Η αξιοπιστία σχετίζεται με την στατιστική συνέπεια μεταξύ της πρόβλεψης και της πραγματικής τιμής και ποσοτικοποιείται μέσω της πιθανότητας κάλυψης του διαστήματος πρόβλεψης (*PICP* - Prediction interval coverage probability). Δεδομένων N προβλέψεων όπου $x_{i,obs}$ η εκάστοτε πραγματική τιμή και $[L_x, U_x]$ το εκάστοτε διάστημα πρόβλεψης του μοντέλου, ορίζεται ο δείκτης:

$$PICP = \frac{1}{N} \sum_{i=1}^N c_i, \text{ όπου } c_i = \begin{cases} 1, & \text{αν } x_{i,obs} \in [L_x, U_x]. \\ 0, & \text{διαφορετικά.} \end{cases} \quad (1.6)$$

Κατ' ουσίαν, δίνεται η πιθανότητα να περιέχεται η πραγματική τιμή παραγόμενης ισχύος στο διάστημα πρόβλεψης που υπολογίσθηκε από το μοντέλο. Η πιθανότητα αυτή συχνά παρουσιάζεται σε σύγκριση με την ονομαστική πιθανότητα κάλυψης του διαστήματος $(1 - \alpha)$, η οποία ορίζεται από τον εκάστοτε ερευνητή και αντιπροσωπεύει την ιδανική αξιοπιστία του μοντέλου. Συνεπώς, ορίζεται το Μέσο Σφάλμα Κάλυψης (*ACE* - Average coverage error) ως:

$$ACE = PICP - 100(1 - \alpha)\% \quad (1.7)$$

Στα πλαίσια της βελτίωσης του μοντέλου, σκοπός είναι το Μέσο Σφάλμα Κάλυψης να πλησιάσει το μηδέν, ώστε να αυξηθεί η αξιοπιστία των προβλέψεων.

Η αξιοπιστία, παρότι είναι σημαντικό χαρακτηριστικό του μοντέλου, δεν επαρκεί για το χαρακτηρισμό της ποιότητας του, καθώς λαμβάνει υπόψη μόνο την πιθανότητα επιτυχίας του μοντέλου και όχι το εύρος της πρόβλεψης. Ως εκ τούτου, είναι σημαντικός ο προσδιορισμός της αιχμηρότητας του. Το εύρος του διαστήματος πρόβλεψης μπορεί να χαρακτηριστεί από το

Σταθμισμένο Μέσο Πλάτος των ΔΠ (*PINAW* - Prediction interval nominal average width). Αν R το εύρος των παρατηρήσεων, τότε:

$$PINAW = \frac{1}{NR} \sum_{i=1}^N (U_i - L_i) \quad (1.8)$$


Το τελευταίο είναι αδιάστατο μέγεθος που αναπαριστά το μέσο εύρος των ΔΠ ως ποσοστό του εύρους των παρατηρήσεων. Αποσκοπούμε σε όσο το δυνατόν μικρότερο εύρος, δηλαδή αυξημένη αιχμηρότητα, ώστε να περιοριστούν τα πιθανά αποτελέσματα. Η αύξηση της αιχμηρότητας οφείλεται να γίνει με προσοχή καθώς ενδέχεται να μειώσει την αξιοπιστία του μοντέλου. Αν λάβουμε υπόψη όλα τα παραπάνω, μπορούμε να αξιολογήσουμε ταυτοχρόνως την αξιοπιστία και την αιχμηρότητα με βάση το Κριτήριο Κάλυψης Πλάτους (*CWC* - Coverage Width Criterion). Για προβλεπόμενη πιθανότητα κάλυψης μ και παράμετρο ελέγχου η , ισχύει:

$$CWC = PINAW(1 + \gamma(PICP, \mu)e^{-\eta(PICP - \mu)}) \quad (1.9)$$

$$\gamma(PICP, \mu) = \begin{cases} 1, & \text{αν } PICP \geq \mu. \\ 0, & \text{διαφορετικά.} \end{cases} \quad (1.10)$$

Η παράμετρος η χρησιμοποιείται ως *συντελεστής ποινής* (*penalty factor*) ώστε να μεγιστοποιήσει την διαφορά μεταξύ των *PICP* και μ , όταν το μοντέλο δεν επιτυγχάνει την προβλεπόμενη αξιοπιστία. Η επιλογή της επηρεάζει σημαντικά την βελτιστοποίηση του μοντέλου και συχνά γίνεται με εμπειρικό τρόπο. Μικρές τιμές μπορεί να μην επαρκούν στην επίτευξη την προβλεπόμενης αξιοπιστίας, ενώ πολύ μεγάλες μπορεί να εμποδίζουν την βελτίωση του μοντέλου. Παρατηρούμε, επίσης, πως τα επιτυχή ΔΠ ($PICP \geq \mu$) αξιολογούνται βάσει μόνο του εύρους τους, καθώς το *CWC* ισούται του *PINAW*. Αυτό επιτρέπει την μερική αξιολόγηση τους ώστε να μην ανταμείβονται για την επιπρόσθετη ακρίβεια τους. Στο Σχήμα 1.2 παρουσιάζεται η διακύμανση του *CWC* για διάφορες τιμές του συντελεστή ποινής.

Η Ανάλυση είναι εγγενές χαρακτηριστικό ενός συστήματος πρόβλεψης, εξαρτάται από την δομή του συστήματος και σχετίζεται με το ελάχιστο χρονικό διάστημα για το οποίο μπορεί να προβλέψει. Πιο συγκεκριμένα, έστω ότι το σύνολο των παρατηρήσιμων τιμών χωρίζονται σε ένα πεπερασμένο πλήθος συνόλων O_i . Αν για κάθε σύνολο O_i παρέχεται ξεχωριστό διαφορετικό σύνολο προβλέψεων F_i τότε θεωρείται πως το μοντέλο έχει τέλεια ανάλυση. Σε αντίθεση με την αξιοπιστία και την αιχμηρότητα, η ανάλυση του μοντέλου δεν μπορεί να βελτιωθεί στατιστικά, παρά μόνο μέσω προσθήκης επιπλέον πληροφορίας σχετικά με την



Σχήμα 1.2: CWC για διάφορες τιμές η για PINAW=40%

χρονική εξέλιξη των υπό μελέτη μετρήσεων. Να σημειωθεί πως η ανάλυση ενός μοντέλου δεν ορίζεται άμεσα από την χρονική κατηγοριοποίησή του, αλλά με βάση το πλήθος των χρονικών τμημάτων εντός του συνολικού χρονικού ορίζοντα του. Για παράδειγμα, μοντέλα μακροπρόθεσμης πρόβλεψης ενός έτους, ενδέχεται να έχουν διαφορετική χρονική ανάλυση [8, 15, 16].

Κεφάλαιο 2


Σημειακά Μοντέλα

Τα σημειακά μοντέλα πρόβλεψης αιολικής ισχύος διακρίνονται συνήθως σε μοντέλα βασισμένα σε φυσικές εξισώσεις και μοντέλα βασισμένα σε στατιστικές μεθόδους. Τα πρώτα λαμβάνουν υπόψη μετεωρολογικά δεδομένα, όπως η ταχύτητα του ανέμου και η κατεύθυνσή του, καθώς και χαρακτηριστικά του αιολικού πάρκου, για να προβλέψουν την αιολική ισχύ. Αντιθέτως, τα μοντέλα βασισμένα σε στατιστικές μεθόδους χρησιμοποιούν στατιστικές μεθόδους χρονοσειρών ή μηχανικής μάθησης για να μοντελοποιήσουν τα μοτίβα και τις σχέσεις μεταξύ των μετρήσεων και των μετεωρολογικών συνθηκών, προκειμένου να προβλέψουν την παραγωγή αιολικής ισχύος. Και οι δύο κατηγορίες παρέχουν αξιόπιστες προβλέψεις για την παραγωγή ενέργειας από αιολικές εγκαταστάσεις, και ιστορικά έχουν εφαρμοστεί σε πολλές περιπτώσεις.

2.1 Φυσική Προσέγγιση

Τα μοντέλα που βασίζονται στη φυσική προσέγγιση του προβλήματος της πρόβλεψης της αιολικής ισχύος χρησιμοποιούν μετεωρολογικά δεδομένα σε συνδυασμό με τα τοπολογικά χαρακτηριστικά του εδάφους που βρίσκεται το αιολικό πάρκο. Η απόκτηση των μετεωρολογικών δεδομένων συνήθως πραγματοποιείται μέσω *μοντέλων αριθμητικής πρόβλεψης καιρού (Numerical Weather Prediction - NWP)*. Σκοπός αυτών είναι η λύση διαφορικών εξισώσεων που περιγράφουν τις μεταβολές της ατμόσφαιρας, βασισμένα σε θερμοδυναμικά και ρευστοδυναμικά μοντέλα, για την πρόβλεψη θερμοκρασίας, υγρασίας, πίεσης, ταχύτητας ανέμου κ.λπ. Τα αποτελέσματα αυτών των μοντέλων συνδυάζονται με τοπολογικά χαρακτηριστικά του πάρκου, όπως το υψόμετρο και η τραχύτητα του εδάφους, ώστε να γίνει βαθμονόμηση


της ταχύτητας του ανέμου στην τοποθεσία και το ύψος των ανεμογεννητριών. Έπειτα, μέσω της καμπύλης ισχύος της ανεμογεννήτριας μπορεί να υπολογιστεί η προβλεπόμενη παραγόμενη ισχύς. Χαρακτηριστικό μοντέλο φυσικής προσέγγισης είναι το μοντέλο Previento, που φαίνεται στο Σχήμα 2.1 [1]. Αξίζει να σημειωθεί τα μοντέλα αριθμητικής πρόβλεψης καιρού, λόγω της πολυπλοκότητάς τους, απαιτούν υψηλό υπολογιστικό κόστος. Επίσης, δεν μπορούν να αποδώσουν ταυτόχρονα υψηλή χωρική και χρονική ανάλυση στις προβλέψεις τους. Μοντέλα NWP χαμηλής χρονικής ανάλυσης χρησιμοποιούνται για άμεσες προβλέψεις αιολικής ισχύος [17].



Σχήμα 2.1: Σχηματική αναπαράσταση μοντέλου φυσικής προσέγγισης «Previento» [1].

2.2 Στατιστική Προσέγγιση

Η στατιστική προσέγγιση στοχεύει στην πρόβλεψη της αιολικής ενέργειας χωρίς περαιτέρω φυσικές θεωρήσεις και παραμετροποιήσεις της ροής του ανέμου στην επιλεγμένη περιοχή. Σε αντίθεση, δηλαδή, με την φυσική προσέγγιση, δεν χρησιμοποιούνται τα τοπολογικά χαρακτηριστικά του πάρκου και η προσαρμογή των δεδομένων στην πλήμνη της ανεμογεννήτριας. Αυτό επιτυγχάνεται μέσω συσχέτισης των τιμών βοηθητικών μεταβλητών, όπως η ταχύτητα του ανέμου και η παραγόμενη ισχύς, με δεδομένα από αριθμητικές προβλέψεις καιρού, όπως φαίνεται επιγραμματικά στο Σχήμα 2.2. Η στατιστική προσέγγιση μπορεί να εφαρμοστεί είτε μέσω μοντέλων χρονοσειράς είτε μέσω τεχνητής νοημοσύνης. Κάθε μία από τις μεθόδους εμφανίζει διαφορετικά πλεονεκτήματα και με βάση την τρέχουσα βιβλιογραφία δεν υπάρχει κοινώς αποδεκτή βέλτιστη μέθοδος για κάθε περίπτωση [18].



Σχήμα 2.2: Σχηματική αναπαράσταση ενδεικτικού μοντέλου στατιστικής προσέγγισης.

2.2.1 Μοντέλα Χρονοσειρών

Στην παρούσα υποκατηγορία μοντέλων αξίζει να αναλυθεί η **Μέθοδος Παραμένουσας Τιμής**. Η συγκεκριμένη μέθοδος προβλέπει πως, δεδομένης μίας χρονοσειράς y_n , η προβλεπόμενη τιμή δίνεται ως $y_n = y_{n+1}$. Δηλαδή, θεωρεί πως η τιμή για την μελλοντική στιγμή $n + 1$ θα παραμείνει σταθερή. Για προβλέψεις μικρού χρονικού ορίζοντα παρέχει ικανοποιητικά αποτελέσματα και συχνά χρησιμοποιείται ως σημείο αναφοράς για αξιολόγηση νέων μοντέλων [19]. Η συγκεκριμένη μέθοδος μπορεί να επεκταθεί και στα πιθανοτικά μοντέλα ως σημείο αναφοράς, όπως θα αναλυθεί μετέπειτα. Επιπροσθέτως, σημαντική έμφαση έχει δοθεί στα **Αυτοπαλινδρομικά Μοντέλα**. Τα μοντέλα αυτοπαλινδρόμησης συνδέουν γραμμικά την μελλοντική τιμή y_t μίας χρονοσειράς με παλαιότερες τιμές της, $Y\{Y_1, \dots, Y_{t-p}\}$

[20]. Ένα μοντέλο αυτοπαλινδρόμησης τάξης p , , αναπαρίσταται ως:

$$AR(p) : Y_t = C + \sum_{i=1}^p \phi_i Y_{t-i} + \epsilon_t$$

όπου ϕ_i συντελεστές αυτοσυσχέτισης του μοντέλου, ϵ_t λευκός θόρυβος και C σταθερά. Στην πρόβλεψη αιολικής ενέργειας συχνά χρησιμοποιούνται μοντέλα αυτοπαλινδρόμησης συνδυαστικά με μοντέλα κινητού μέσου όρου (Moving Average – MA). Τα τελευταία συνδέουν γραμμικά την παρατήρηση $\{y_t\}$ της χρονοσειράς και το σφάλμα του μοντέλου σε q προηγούμενες περιόδους. Αυτό εκφράζεται αλγεβρικά ως:

$$MA(q) : Y_t = C - \sum_{i=1}^q \theta_i \epsilon_{t-i}$$

Συνεπώς, ο συνδυασμός αυτών ορίζεται ως μοντέλο αυτοπαλινδρόμησης κινητού μέσου όρου και εκτιμά την μελλοντική τιμή της χρονοσειράς ως:

$$ARMA(p, q) : Y_t = C + \sum_{i=1}^p \phi_i Y_{t-i} + \epsilon_t - \sum_{i=1}^q \theta_i \epsilon_{t-i}$$

Το πρώτο μέρος της εξίσωσης παρέχει πληροφορία για τις προηγούμενες τιμές της χρονοσειράς (π.χ. παραχθείσα ισχύ) έως και την χρονική στιγμή $t - 1$ μέσω του AR και το δεύτερο αντιπροσωπεύει τα προηγούμενα σφάλματα ώστε να βελτιωθεί η ακρίβεια της πρόβλεψης. Η κατασκευή τέτοιων μοντέλων απαιτεί αρχικά την επιλογή της τάξης (p, q) του μοντέλου, δηλαδή το πλήθος παλαιότερων τιμών που θα εφαρμοστεί στην αυτοπαλινδρόμηση και το πλήθος των παλαιότερων σφαλμάτων αντίστοιχα. Έπειτα, μπορεί να γίνει η εκτίμηση των παραμέτρων του μοντέλου, ώστε εν τέλει να προβλεφθεί η νέα τιμή της χρονοσειράς [21].

Τα μοντέλα $ARMA$ παράγουν ικανοποιητικά αποτελέσματα για την ανάλυση και πρόβλεψη στάσιμων χρονοσειρών, δηλαδή όσων η μέση τιμή μ και η διακύμανση σ^2 είναι σταθερές στον χρόνο. Παρόλα αυτά, στην πρόβλεψη αιολικής ενέργειας, οι χρονοσειρές σπανίως εμφανίζουν στασιμότητα. Για την διασφάλιση της στασιμότητας χρησιμοποιούνται ολοκληρωμένα αυτοπαλινδρομικά μοντέλα κινητού μέσου όρου (Auto Regressive Integrated Moving Average ($ARIMA(p, d, q)$)). Στα συγκεκριμένα, αντί της αρχικής χρονοσειράς, χρησιμοποιείται η d -τάξης παράγωγος της, η οποία για $d = 1$ εκφράζεται ως [8]:


$$Y_t = X_t - X_{t-1}$$

2.2.2 Στατιστική προσέγγιση με χρήση τεχνητής νοημοσύνης

Ο κλάδος της τεχνητής νοημοσύνης, λόγω της ευρύτητας του, εφαρμόζεται με ποικίλους τρόπους στα μοντέλα που αναλύονται. Συγκεκριμένα, η δυνατότητα των νευρωνικών

δικτύων (Artificial neural network – ANN) να μοντελοποιήσουν μη γραμμικές σχέσεις και να προβλέπουν μελλοντικές καταστάσεις, έχει οδηγήσει πολλούς ερευνητές στην ανάπτυξη μοντέλων βασισμένα σε αυτά.

Ένα τυπικό νευρωνικό δίκτυο αποτελείται από ένα πλήθος διασυνδεδεμένων νευρώνων, διατεταγμένους σε επίπεδα. Στο Σχήμα 2.3 φαίνεται σχηματικά η τυπική δομή ενός μη γραμμικού νευρώνα. Κάθε νευρώνας k εκφράζεται μαθηματικά ως μία συνάρτηση μεταφοράς, που μεταφέρει το βεβαρημένο άθροισμα εισόδων x_i και μίας πόλωσης b_k στο επόμενο επίπεδο μέσω κάποιας συνάρτησης ενεργοποίησης ϕ .




Σχήμα 2.3: Μη γραμμικό μοντέλο νευρώνα [2]

Τα δεδομένα εισέρχονται στο δίκτυο στο επίπεδο εισόδου και εξέρχονται στο επίπεδο εξόδου, μέσω ενός ή περισσότερων κρυφών επιπέδων, όπως φαίνεται στο Σχήμα 2.4 [2]. Ανάλογα με το είδος των δεδομένων και την φύση του προβλήματος, η ακριβής δομή του δικτύου διαφέρει (πλήρως ή μερικώς διασυνδεδεμένα, ανατροφοδοτούμενα κ.λπ.), δίνοντας στον χρήστη σημαντική ευελιξία στην προσαρμογή στο εκάστοτε πρόβλημα.

Κατά την ανάπτυξη μοντέλων πρόβλεψης με νευρωνικά δίκτυα είναι απαραίτητος ο καθορισμός των εξής παραμέτρων:

1. Είσοδος: πλήθος και ποιοτικά χαρακτηριστικά
2. Δομή δικτύου: πλήθος επιπέδων και νευρώνων, είδος διασύνδεσης κ.λπ.
3. Εκπαίδευση: μέθοδος και κριτήρια ολοκλήρωσης της.



Σχήμα 2.4: Πλήρως διασυνδεδεμένο νευρωνικό δίκτυο με 2 κρυφά επίπεδα [2]

4. Έξοδος: πλήθος και ποιοτικά χαρακτηριστικά.

Έχοντας ολοκληρωθεί η υλοποίηση και η εκπαίδευση του δικτύου, είναι πλέον εφικτή η πρόβλεψη της αιολικής ενέργειας. Παρακάτω θα εξετάσουμε μερικά παραδείγματα χρήσης NN για πρόβλεψη αιολικής ενέργειας.

Στο [22], οι ερευνητές συνέκριναν τέσσερα διαφορετικά μοντέλα ωριαίας πρόβλεψης της ταχύτητας του ανέμου, έχοντας ως είσοδο τις ταχύτητες των προηγούμενων 2 ή 3 ωρών. Δύο εκ των τεσσάρων μοντέλων αποτελούνταν από τρία επίπεδα (με εισόδους τις 3 προηγούμενες ώρες) και τα υπόλοιπα ήταν δύο επιπέδων (με εισόδους τις 2 ή 3 προηγούμενες ώρες αντίστοιχα). Με κριτήρια το μέσο τετραγωνικό και το μέσο απόλυτο σφάλμα, το μοντέλο 2 επιπέδων – 2 εισόδων εμφάνισε σημαντικά καλύτερες επιδόσεις σε σχέση με τα υπόλοιπα. Σημειώνεται, επίσης, ότι η υψηλή απόδοση του απλούστερου μοντέλου σχετίζεται με την σταθερότητα του ανέμου στην υπό μελέτη περιοχή. Δίκτυα ακτινικών συναρτήσεων βάσης χρησιμοποιήθηκαν στο [23] για την πρόβλεψη της παραγόμενης ισχύος σε χρονικό ορίζοντα 10 λεπτών. Έχοντας ως είσοδο την παραχθείσα ισχύ στις χρονικές στιγμές t , $t - 10$ και $t - 20$, η παραγόμενη ισχύς υπολογίστηκε με μέσο απόλυτο σφάλμα $\approx 0.3\%$, παρέχοντας ακρίβεια και αξιοπιστία στην πρόβλεψη.

Οι Li και Shi [24] συνέκριναν 3 διαφορετικά είδη τεχνητών νευρωνικών δικτύων για πρόβλεψη της ταχύτητας του ανέμου σε ορίζοντα μίας ώρας σε 2 τοποθεσίες. Συγκεκριμένα, ένα δίκτυο πρόσθιας τροφοδότησης με οπισθοδιάδοση (FFBP), ένα δίκτυο ακτινικών συναρτήσεων βάσης (RBF) και ένα δίκτυο ADALINE. Τα τεχνητά νευρωνικά δίκτυα που εκπαιδεύτηκαν με διαφορετικές εισόδους ή με διαφορετικούς ρυθμούς εκμάθησης απέδω-

σαν διαφορετική ακρίβεια στην πρόβλεψη τους. Ακόμη και με το ίδιο σύνολο δεδομένων ανέμου από μια συγκεκριμένη τοποθεσία, η επιλογή του βέλτιστου μοντέλου εξαρτάται από διαφορετικά κριτήρια αξιολόγησης. Με διαφορετικά δεδομένα ταχύτητας, η επιλογή γίνεται πιο ασυνεπής, ακόμη και όσον αφορά τα ίδια αξιολογητικά κριτήρια. Ως εκ τούτου, προτείνεται ο συνδυασμός προβλέψεων από διαφορετικά μοντέλα νευρωνικών δικτύων για να αντιμετωπιστεί το ζήτημα της ασυνέπειας στην επιλογή μοντέλου.

Περαιτέρω χρήση του κλάδου της τεχνητής νοημοσύνης, πλην των νευρωνικών δικτύων, εντοπίζεται στις Μηχανές Διανυσμάτων Υποστήριξης. Οι μηχανές διανυσμάτων υποστήριξης (Support Vector Machines - SVM) είναι ένα σύνολο αλγορίθμων μηχανικής μάθησης που χρησιμοποιούνται για ταξινόμηση και γραμμική ή μη παλινδρόμηση δεδομένων. Δοθέντος ενός δείγματος απόφασης, η μηχανή διανυσμάτων υποστήριξης κατασκευάζει ένα υπερεπίπεδο ως επιφάνεια απόφασης με σκοπό να μεγιστοποιήσει το περιθώριο διαχωρισμού των θετικών και αρνητικών παραδειγμάτων. Ως αποτέλεσμα, είναι ένα εξαιρετικό εργαλείο για ταξινόμηση καθώς και παλινδρόμηση και πρόβλεψη [2, 8].

Κεφάλαιο 3

Πιθανοτικά Μοντέλα

Τα Πιθανοτικά μοντέλα βρίσκονται στο επίκεντρο της έρευνας στον τομέα της πρόβλεψης αιολικής ενέργειας, παρέχοντας στον χρήστη πληροφορία σχετικά με την αβεβαιότητα της πρόβλεψης και δίνοντας ένα εύρος πιθανών μελλοντικών καταστάσεων. Αποτελούν, δηλαδή, την «επέκταση» των σημειακών μοντέλων της αιολικής ισχύος με δυνατότητα να παρέχουν πολλαπλά σημεία με καθορισμένη πιθανότητα έκαστο. Τα Πιθανοτικά μοντέλα ταξινομούνται σε παραμετρικά και μη παραμετρικά [8].

3.1 Παραμετρική Προσέγγιση

Το κύριο χαρακτηριστικό κάθε παραμετρικής προσέγγισης είναι η ύπαρξη μιας αρχικής υπόθεσης για την κατανομή που μοντελοποιείται. Σύμφωνα με το [20], η απλούστερη παραμετρική προσέγγιση για κατασκευή Διαστημάτων Πρόβλεψης (ΔΠ) θέτει σαν αρχική υπόθεση πως το σφάλμα πρόβλεψης ακολουθεί κανονική κατανομή με μηδενικό μέσο και γνωστή διακύμανση. Σημαντικό πλεονέκτημα της παραμετρικής προσέγγισης είναι η απλότητα της. Δεδομένης της υπόθεσής ότι η αναμενόμενη έξοδος ακολουθεί κάποια προκαθορισμένη κατανομή, η επεξεργασία των δεδομένων και η αξιολόγηση του μοντέλου γίνονται ευκολότερα. Σε γενικές γραμμές, διάφορες κατανομές έχουν προταθεί στην βιβλιογραφία, με την κανονική και την βήτα κατανομή να είναι οι πιο διαδεδομένες [18].

3.2 Μη Παραμετρική προσέγγιση

3.2.1 Πιθανοτική μέθοδος παραμένουσας τιμής

Η μέθοδος της παραμένουσας τιμής που αναλύθηκε στις σημειακές προβλέψεις, μπορεί να επεκταθεί για την παραγωγή πιθανοτικών προβλέψεων. Η παρούσα μέθοδος υποθέτει ότι η παραγωγή θα ακολουθήσει κανονική κατανομή και λαμβάνει την τελευταία πραγματική μέτρηση ως προβλεπόμενη μέση τιμή και την τυπική απόκλιση μέσω των προηγούμενων μετρήσεων [25]. Για ιστορικές μετρήσεις παραγωγής $\{P_1, P_2, \dots, P_N\}$, η τυπική απόκλιση n προηγούμενων δειγμάτων δίνεται ως:

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (P_i - \mu)^2} \quad (3.1)$$

όπου μ η προηγούμενη μέτρηση δοθείσα ως μέση τιμή της κατανομής. Ορίζοντας ένα διάστημα εμπιστοσύνης α της κατανομής, λαμβάνεται η τυπική τιμή z (z-score), ώστε να υπολογιστεί το εύρος της προβλεπόμενης παραγωγής ως $P_{t+1} \pm z \cdot \sigma$.

Η παρούσα μέθοδος θεωρείται μη παραμετρική προσέγγιση, εφόσον δεν βασίζεται στην εκτίμηση των παραμέτρων ενός προκαθορισμένου στατιστικού μοντέλου. Αντίθετα, χρησιμοποιεί την ιστορική μεταβλητότητα των δεδομένων για να δημιουργήσει διαστήματα πρόβλεψης γύρω από την προβλεπόμενη παραγωγή. Παρότι αποδίδει ικανοποιητικά σε μικρούς χρονικούς ορίζοντες πρόβλεψης, σημαντικό μειονέκτημα της είναι πως η απόδοση δεν βελτιώνεται με την αύξηση των διαθέσιμων ιστορικών δεδομένων. Τέλος, αντίστοιχα με τη σημειακή μέθοδο, χρησιμοποιείται συχνά ως μοντέλο σύγκρισης και αξιολόγησης νέων μεθόδων, ειδικότερα για διαστήματα έως και 1 ώρα μπροστά [26, 27].

3.2.2 Παλινδρόμηση ποσοστημορίου (Quantile Regression)

Σκοπός της συγκεκριμένης τεχνικής είναι ο υπολογισμός ενός πεπερασμένου αριθμού ποσοστημορίων της πιθανοτικής κατανομής της παραγόμενης αιολικής ισχύος για την κατασκευή διαστημάτων πρόβλεψης.

Για μια τυχαία μεταβλητή Y , το ποσοστημόριο q_α ορίζεται ως η τιμή για την οποία η πιθανότητα η τυχαία μεταβλητή να λάβει τιμή μικρότερη ή ίση του q_α ισούται με α . Αν Y η αιολική ισχύς και X_k με $(k = 1, 2, \dots, n)$ ένα σύνολο βοηθητικών μεταβλητών (π.χ. παλαιότερες τιμές ισχύος, ταχύτητα ανέμου από NWP), η δεσμευμένη συνάρτηση κατανομής

$F(y)$ και το ποσοστημόριο q_α ορίζονται ως:

$$F(y) = P(Y \leq y | X_1 = x_1, \dots, X_k = x_k)$$

$$q_\alpha = \min\{y | F(y) \geq \alpha\}$$

Συνεπώς ορίζεται η γραμμική εξίσωση παλινδρόμησης,

$$q_\alpha(x_1, \dots, x_k) = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$$


Τα ποσοστημόρια υπολογίζονται μέσω εκτίμησης των συντελεστών παλινδρόμησης β , και συνεπώς το ποσοστημόριο δίνεται από σφάλμα παλινδρόμησης:

$$\min E\{L_\alpha(y, q_\alpha) | X_1 = x_1, \dots, X_k = x_k\},$$

όπου L_α είναι η συνάρτηση ελέγχου για παρατηρήσεις y :

$$L_\alpha(y, q_\alpha) = \begin{cases} \alpha(y - q_\alpha) & , y - q_\alpha > 0 \\ (\alpha - 1)(y - q_\alpha) & , y - q_\alpha \leq 0 \end{cases}$$

Συνεπώς, τα διαστήματα πρόβλεψης δίνονται από τα υπολογισθέντα ποσοστημόρια [28, 29]. Στο Σχήμα 3.1 φαίνεται ένα παράδειγμα πρόβλεψης τέτοιου μοντέλου, όπου σε κάθε πρόβλεψη υπολογίζονται 5 εκατοστημόρια. Στην τελευταία πρόβλεψη, το 95^ο και το 5^ο δίνει ένα διάστημα πρόβλεψης περίπου [0.4, 2.5] MWh με 90% πιθανότητα κάλυψης.



Σχήμα 3.1: Παράδειγμα ωριαίας πιθανοτικής πρόβλεψης ως προς 5 εκατοστημόρια

Στο [28] χρησιμοποιήθηκε τοπική παλινδρόμηση ποσοστημορίου (LQR) για τον υπολογισμό δέκα διαφορετικών εκατοστημορίων για την πρόβλεψη παραγόμενης ισχύος. Ως δεδομένα εισόδου χρησιμοποιήθηκαν ιστορικά δεδομένα παραγωγής σε συνδυασμό με δεδομένα από NWP και η αξιολόγηση των ΔΠ έγινε με βάση της αιχμηρότητα τους. Η επιλογή

των καλύτερων μοντέλων έγινε μέσω cross-validation με βάση την απόδοση κάθε μοντέλου. Το μοντέλο LQR Hirlam10 παρείχε ΔΠ με υψηλότερη αιχμηρότητα σε σχέση με το LQR Climate. Επίσης, απέδωσε καλύτερα ως προς την αβεβαιότητα των προβλέψεων για χρονικό ορίζοντα άνω των 47 ωρών. Παρόλα αυτά, και στις 2 περιπτώσεις το εύρος των ΔΠ ήταν μεγαλύτερο από το επιθυμητό.

Στο [29] εφαρμόστηκε παλινδρόμηση εκατοστημορίου μέσω νευρωνικών δικτύων (QRNN) για πρόβλεψη παραγόμενης αιολικής ισχύος από 10 αιολικά πάρκα σε βάθος 72 ωρών. Επίσης, για την βελτίωση των προβλέψεων ελέγχθηκε η ένταξη της μεθόδου Deep Quantile Regression στο αρχικό μοντέλο. Συμπερασματικά, το μοντέλο DQR ήταν το πιο αξιόπιστο, παρέχοντας στενότερα ΔΠ σε σχέση με το αρχικό μοντέλο και τα μοντέλα αναφοράς, ενώ απαιτούσε σημαντικά μικρότερο υπολογιστικό χρόνο.

3.2.3 Εκτίμηση Πυκνότητας Πυρήνα (Kernel Density Estimation)

Δεδομένης μίας τυχαίας μεταβλητής, η μέθοδος Εκτίμησης Πυκνότητας Πυρήνα υπολογίζει την δεσμευμένη συνάρτηση πυκνότητας-πιθανότητας της. Ως μη παραμετρική προσέγγιση, μπορεί να υπολογίζει απευθείας την πυκνότητα της μεταβλητής χωρίς καμία υπόθεση για την κατανομή της. Για κάθε τιμή της δοθείσας μεταβλητής τοποθετείται μια συνάρτηση πυρήνα ώστε να προσδιορίσει την συνεισφορά της στην συνολική πιθανοτική πυκνότητα. Η τελική πρόβλεψη πυκνότητας πυρήνα δίνεται από το άθροισμα των εκάστοτε συναρτήσεων πυρήνα [30, 31]. Ο εκτιμητής πυρήνα ορίζεται ως:

$$\hat{f}(x) = \frac{1}{N|H|} \sum_{i=1}^n K(H^{-1}(x - x_i))$$


Όπου H , το εύρος ζώνης, ένας dd πίνακας που ελέγχει την εξομάλυνση της εκτίμησης, μια σωστά επιλεγμένη συνάρτηση πυρήνα. Η επιλογή της κατάλληλης συνάρτησης πυρήνα με βάση το είδος της τυχαία μεταβλητής θεωρείται ένα από τα κρίσιμα βήματα της συγκεκριμένης μεθόδου. Ο πίνακας H έχει καθοριστικό ρόλο στην ακρίβεια της συνάρτησης πυκνότητας-πιθανότητας.

Στο [31] προβλέφθηκε η παραγωγή αιολικής ισχύος τριών αιολικών πάρκων με δεδομένα 18 μηνών από NWP. Ελέγχθηκαν 16 μεταβλητές μεταξύ των οποίων ήταν η ταχύτητα και η διεύθυνση του ανέμου σε διάφορα σημεία, η θερμοκρασία, η υγρασία κ.α. Οι ημερήσιες προβλέψεις έγιναν για χρονικό ορίζοντα 0-16 ωρών με χρονική ανάλυση 3 ωρών. Κατά την αρχική αξιολόγηση του μοντέλου, τα δεδομένα ταχύτητας και διεύθυνσης παρείχαν την

σημαντικότερη πληροφορία για την τελική πρόβλεψη. Τα αποτελέσματα συγκρίθηκαν με δύο ακόμα πιθανοτικά μοντέλα (Quantile Regression Forest, B-spline Quantile Regression). Στις περισσότερες περιπτώσεις το μοντέλο KDE παρείχε καλύτερη αξιοπιστία, αν και παρατηρήθηκε σημαντική διακύμανση μεταξύ των τριών πάρκων. Σημειώνεται, επίσης, πως ο υπολογιστικός χρόνος ήταν συγκρίσιμος με τα άλλα πιθανοτικά και σημειακά μοντέλα.

3.2.4 Εκτίμηση Άνω και Κάτω ορίου

Η συγκεκριμένη μέθοδος (Lower Upper Bound Estimation - LUBE) αποσκοπεί στον άμεσο υπολογισμό του άνω και κάτω ορίου της προβλεπόμενης παραγωγής μέσω τεχνητής νοημοσύνης [32]. Παλαιότερες υλοποιήσεις που βασίζονται σε νευρωνικά δίκτυα για την κατασκευή των ΔΠ, δημιουργούν πλήθος σημειακών προβλέψεων και, με βάση την κατανομή τους, υπολογίζεται η μέση τιμή και η διακύμανση τους ώστε να κατασκευαστεί το ΔΠ. Σε αντίθεση με αυτές τις μεθόδους, η μέθοδος LUBE επιτυγχάνει την άμεση κατασκευή του Διαστήματος Πρόβλεψης όπως φαίνεται στο Σχήμα 3.2, μειώνοντας το υπολογιστικό κόστος.



Σχήμα 3.2: Συμβολική αναπαράσταση νευρωνικού δικτύου για εύρεση Άνω και Κάτω ορίου του ΔΠ

Στο [3], νευρωνικά δίκτυα χρησιμοποιήθηκαν για την κατασκευή ΔΠ ενώ για την βελτιστοποίηση του δικτύου χρησιμοποιήθηκε ο αλγόριθμος Particle Swarm Optimization (PSO). Με βάση τον Πίνακα 3.1, τα αποτελέσματα συγκρίθηκαν με αυτά των στατιστικών μοντέλων ARIMA, Εκθετικής Εξομάλυνσης (ES) και Παραμένουσας Τιμής. Ως προς την αιχμηρότητα, το νέο μοντέλο είχε καλύτερη απόδοση, ενώ ως προς την αξιοπιστία απέδωσε καλύτερα από

Πίνακας 3.1: Αποτελέσματα χρήσης νευρωνικών δικτύου με χρήση αλγόριθμου Particle Swarm Optimization (PSO) [3]

	<i>PICP (%)</i>	<i>PINAW (%)</i>	<i>CWC (%)</i>
LUBE (median)	<i>91.80</i>	72.57	72.57
ARIMA	<i>91.44</i>	<i>75.58</i>	<i>75.58</i>
ES	92.71	<i>78.45</i>	<i>78.45</i>
Persistent	<i>88.81 < μ_{nom}</i>	<i>74.43</i>	<i>209.16</i>

* βέλτιστη τιμή

** $\mu_{nom} = 90\%$

όλα εκτός της Εκθετικής Εξομάλυνσης. Συνολικά, παρείχε καλύτερης ποιότητας ΔΠ σε μικρότερο υπολογιστικό χρόνο.

3.2.5 Μέθοδοι Αυτοδύναμης Εκκίνησης (Bootstrapping)

Η μέθοδος Bootstrap βασίζεται στην δημιουργία νέων δειγμάτων ίδιου μεγέθους με το αρχικό δείγμα, μέσω δειγματοληψίας με επανάθεση από το αρχικό δείγμα. Η συγκεκριμένη τεχνική αναδειγματοληψίας πλεονεκτεί στην ακρίβεια των ΔΠ, απαιτώντας όμως υψηλό υπολογιστικό κόστος [8].

Στο [33] εφαρμόστηκε ένα είδος αυτοδύναμης εκκίνησης (Moving block bootstrap) για βραχυπρόθεσμη πρόβλεψη αιολικής ισχύος. Ως είσοδοι χρησιμοποιήθηκαν μόνο ιστορικά δεδομένα ισχύος για την πρόβλεψη σε βάθος 5, 10, 15 και 30 λεπτών. Τα αποτελέσματα συγκρίθηκαν με εκείνα ενός μοντέλου Εκτίμησης Άνω Κάτω ορίου. Συνολικά, για προβλέψεις κάτω των 10 λεπτών απέδωσε καλύτερα το μοντέλο MMB, ενώ στις υπόλοιπες περιπτώσεις απέδωσε καλύτερα το μοντέλο LUBE.

Κεφάλαιο 4

Μαθηματική θεμελίωση μοντέλου πρόβλεψης

4.1 Εισαγωγή

Αναλύοντας την τρέχουσα βιβλιογραφία, είναι εμφανές πως η τεχνητή νοημοσύνη και τα εργαλεία που προσφέρει, αποτελούν πολλά υποσχόμενη λύση στο πρόβλημα της πρόβλεψης. Η ανάπτυξη ενός τέτοιου αλγορίθμου θα πρέπει να προσφέρει δυναμικότητα και προσαρμοστικότητα ως προς την ανάλυση χρονοσειρών, ταυτόχρονα με αξιοπιστία.

Λόγω της άμεσης εξάρτησης του παραγομένου φορτίου από ευμετάβλητες εξωτερικές παραμέτρους, όπως οι καιρικές συνθήκες και οι τιμές της αγοράς, η σύνδεση δεδομένων εισόδου και εξόδου οφείλει να είναι δυναμική και να επιτρέπει την τροποποίηση για να προσαρμοστεί στις νέες συνθήκες. Την ίδια στιγμή πρέπει να διατηρείται η αξιοπιστία του μοντέλου, λαμβάνοντας υπόψη πιθανούς παράγοντες που επιδρούν στην παραγωγή. Οφείλει, επίσης, να πληροί σχετικές προϋποθέσεις που περιλαμβάνουν διαφορετικές περιοχές του συστήματος ισχύος, διαφορετικό επίπεδο φόρτισης, χρονική στιγμή κ.α.

Στο παρόν Κεφάλαιο θα αναπτυχθούν τα μοντέλα, οι τεχνικές και τα χαρακτηριστικά νευρωνικών δικτύων που χρησιμοποιήθηκαν για την πρόβλεψη αιολικής παραγωγής, καθώς και σχετικά προβλήματα που προκύπτουν στο εν λόγω ζήτημα.

4.2 Μηχανική Μάθηση

Η μηχανική μάθηση, ούσα υποπεδίο της τεχνητής νοημοσύνης, εστιάζει στην ανάπτυξη αλγορίθμων και μοντέλων που επιτρέπουν στους υπολογιστές να μαθαίνουν από δεδομένα και να λαμβάνουν προβλέψεις ή αποφάσεις χωρίς να είναι ρητά προγραμματισμένοι εκ των προτέρων. Μέσω της χρήσης αλγορίθμων για την εκμάθηση μοτίβων και σχέσεων στα αρχικά δεδομένα, επιτυγχάνεται η λήψη προβλέψεων ή αποφάσεων σχετικά με νέα μελλοντικά δεδομένα. Οι τρεις κύριοι τύποι μηχανικής μάθησης είναι:

1. Επιτηρούμενη Μάθηση, όπου ο αλγόριθμος μηχανικής μάθησης εκπαιδεύεται σε ένα σύνολο δεδομένων, όπου παρέχεται η σωστή έξοδος για κάθε είσοδο. Συνεπώς, ο αλγόριθμος μαθαίνει να αντιστοιχίζει εισόδους σε εξόδους και μπορεί να κάνει προβλέψεις για νέα δεδομένα.
2. Μη επιτηρούμενη μάθηση, όπου ο αλγόριθμος εκπαιδεύεται σε ένα σύνολο δεδομένων χωρίς να παρέχονται πληροφορίες επιθυμητής εξόδου και μαθαίνει να εντοπίζει μοτίβα ή σχέσεις στα δεδομένα. Συχνά χρησιμοποιείται σε εργασίες ομαδοποίησης/συσταδοποίησης, όπου κατηγοριοποιούνται δεδομένα χωρίς να είναι εκ των προτέρων γνωστές οι πιθανές ομάδες.
3. Ενισχυτική μάθηση, όπου ο αλγόριθμος μαθαίνει να λαμβάνει αποφάσεις με βάση ένα "σήμα ανταμοιβής", το οποίο παρέχεται ως ανατροφοδότηση με βάση τις ενέργειες που γίνονται από τον αλγόριθμο, με σκοπό την ανάπτυξη μιας στρατηγικής ενεργειών.

4.2.1 Συχνά προβλήματα

Το σημαντικότερο και συχνότερο ζήτημα που αντιμετωπίζεται κατά την ανάπτυξη νευρωνικών δικτύων είναι ο *συμβιβασμός μεταξύ προσέγγισης και εκτίμησης (bias-variance trade-off ή approximation–estimation trade-off)*. Ο συγκεκριμένος συμβιβασμός αφορά την εύρεση ενός μοντέλου που είναι αρκετά πολύπλοκο ώστε να μοντελοποιεί τις σχέσεις των δεδομένων, αλλά όχι υπερβολικά πολύπλοκο ώστε να ταιριάζει υπερβολικά με τα δεδομένα εκπαίδευσης και να αποτυγχάνει να γενικευτεί σε μελλοντικά δεδομένα.

Το *σφάλμα προσέγγισης (approximation error)* ενός συστήματος μηχανικής μάθησης περιγράφει την διαφορά μεταξύ της πραγματικής συνάρτησης που καθορίζει τα δεδομένα εισόδου και του μοντέλου αυτής, που δημιουργεί ο αλγόριθμος. Δημιουργείται καθώς είναι

αδύνατη η τέλεια μοντελοποίηση της πραγματικής κατάστασης, έχοντας ως είσοδο πεπερασμένο πλήθος δεδομένων και παραμέτρων. Δηλαδή, μας παρέχει ένα μέτρο της απόδοσης που χάνεται λόγω χρήσης ενός πεπερασμένου δείγματος εκπαίδευσης.

Το *σφάλμα εκτίμησης* είναι η διαφορά μεταξύ της αναμενόμενης τιμής των προβλέψεων του μοντέλου και της πραγματικής τιμής που προσπαθεί να εκτιμήσει. Είναι ένα μέτρο του πόσο καλά το μοντέλο είναι σε θέση να αποτυπώσει την υποκείμενη δομή των δεδομένων και να κάνει ακριβείς προβλέψεις. Το σφάλμα εκτίμησης είναι ένας τύπος μεροληψίας που είναι εγγενής στις παραδοχές και τη δομή του μοντέλου.

Εφόσον υπάρχει ένα πεπερασμένο πλήθος δεδομένων, μπορούμε να συμβιβάσουμε το σφάλμα εκτίμησης για χαμηλό σφάλμα προσέγγισης, ή το αντίθετο, αλλά όχι και τα δύο. Σε ενδεχόμενο που το μοντέλο είναι πολύ απλό για την περίπτωση και δεν αντικατοπτρίζει την πολυπλοκότητα των δεδομένων, έχουμε *υποπροσαρμογή (underfitting)*. Δηλαδή, το μοντέλο δεν καταγράφει όλα τα υπάρχοντα μοτίβα, οδηγώντας σε κακή απόδοση τόσο στα δεδομένα εκπαίδευσης όσο και στα δεδομένα αξιολόγησης. Αντίθετα, ορίζεται η *υπερπροσαρμογή (overfitting)*, όπου το μοντέλο ταιριάζει με μεγάλη ακρίβεια στα δεδομένα εκπαίδευσης αλλά αποδίδει κακώς σε νέα δεδομένα.


4.3 Είσοδοι μοντέλων πρόβλεψης

Κατά το αρχικό στάδιο ανάπτυξης μοντέλων πρόβλεψης μέσω νευρωνικών δικτύων, η επιλογή και αξιολόγηση των διαθέσιμων δεδομένων που θα δοθούν στο μοντέλο έχει σημαντική επίπτωση στον σχεδιασμό και στην απόδοση του. Σε γενικές γραμμές, η εσφαλμένη επιλογή εισόδων μπορεί να οδηγήσει σε σφάλματα πρόβλεψης που αυξάνουν το χρόνο, το κόστος και την υπολογιστική πολυπλοκότητα. Συνεπώς, ακόμα και πολύπλοκα μοντέλα μπορεί να οδηγηθούν σε ιδιαίτερος χαμηλή απόδοση. Η επιλογή δεδομένων αφορά τόσο τα ποσοτικά χαρακτηριστικά τους, όσο και τα ποιοτικά. Προφανώς, η συνηθέστερη είσοδος στον τομέα της αιολικής παραγωγής είναι η ταχύτητα του ανέμου, εφόσον η διαθέσιμη αιολική ενέργεια P σχετίζεται με την ταχύτητα ως εξής [34]:

$$P = \frac{1}{2} \rho \pi R^2 C_p u^3$$

Εκτός της ταχύτητας, σημαντικός παράγοντας που επηρεάζει την παραγόμενη ενέργεια είναι η κατεύθυνση του ανέμου. Παρότι η συνολική ενέργεια επηρεάζεται και από άλλες φυσικές μεταβλητές, όπως η θερμοκρασία και η υγρασία, προκύπτει πως η ταχύτητα και η

κατεύθυνση είναι οι κύριοι επιδραστικοί παράγοντες. Στο Σχήμα 4.1 απεικονίζεται συμβολικά η επίδραση της ταχύτητας και της διεύθυνσης στην παραγόμενη ισχύ βάσει πραγματικών δεδομένων. Επίσης, η αύξηση των εισόδων του δικτύου, απαιτεί σημαντική αύξηση της πολυπλοκότητας του, εφόσον καλείται να μοντελοποιήσει περίπλοκα φυσικά φαινόμενα. Εκτός του πλήθους και είδους της εισόδου, εξίσου σημαντικό ρόλο παίζει και ο ποιοτικός χα-



Σχήμα 4.1: Σχηματική απεικόνιση των διαθέσιμων μετρήσεων (ταχύτητα ανέμου ως απόσταση από το μηδέν, γωνία πρόσπτωσης και κανονικοποιημένη παραγόμενη ισχύς ως χρωματική κλίματα).

ρακτήρας τους. Συγκεκριμένα για τα νευρωνικά δίκτυα, η προεπεξεργασία των δεδομένων έχει κρίσιμο ρόλο στην απόδοσή τους. Περιλαμβάνει πολλά βασικά βήματα που συμβάλλουν στη βελτίωση της ποιότητας των δεδομένων εισόδου και στη βελτίωση της απόδοσης του μοντέλου. Συνήθως, η προεπεξεργασία δεδομένων περιλαμβάνει εργασίες όπως ο καθαρισμός δεδομένων, η κανονικοποίηση τους και ο χειρισμός κενών τιμών. Ως καθαρισμός δεδομένων - data cleaning ορίζεται ο εντοπισμός και η διόρθωση σφαλμάτων ή ασυνεπειών στα δεδομένα, όπως ακραίες μη επιτρεπτές τιμές ή εσφαλμένες μετρήσεις, που μπορεί να επηρεάσουν σημαντικά την εκπαίδευση του δικτύου. Επίσης, συχνά εφαρμόζεται κανονικοποίηση στα δεδομένα εισόδου, προτού τροφοδοτηθούν στο δίκτυο. Η κανονικοποίηση είναι ζωτικής σημασίας για την οριοθέτηση της εισόδου σε ένα μειωμένο εύρος, διασφαλίζοντας ότι τα δίκτυα εκπαιδεύονται αποτελεσματικά χωρίς να ωθούνται σε ακραίες τιμές εξόδου.

Ταυτόχρονα, μειώνεται και το υπολογιστικό κόστος της εκπαίδευσης. Επιπλέον, η σωστή προεπεξεργασία της εισόδου μπορεί να βοηθήσει στη μείωση του κινδύνου *υπερπροσαρμογής* ή *υποπροσαρμογής*, βελτιώνοντας την ικανότητα του μοντέλου να αποδίδει καλά σε νέα δεδομένα. Η προσεκτική εκτέλεση αυτών των βημάτων είναι απαραίτητη επειδή επηρεάζει άμεσα την ικανότητα του δικτύου να μαθαίνει και να γενικεύει από τα δεδομένα.

4.4 Αλγόριθμοι βελτιστοποίησης

Η εκπαίδευση ενός νευρωνικού δικτύου και η ελαχιστοποίηση του σφάλματος απαιτούν, εκτός των άλλων, και την χρήση κατάλληλων αλγορίθμων βελτιστοποίησης στο στάδιο της εκπαίδευσης. Οι αλγόριθμοι βελτιστοποίησης αποτελούν σημαντική επιλογή στην επιτυχή εκπαίδευση των δικτύων, συμβάλλοντας στην προσαρμογή των παραμέτρων του δικτύου ώστε να ελαχιστοποιούν την επιλεγμένη συνάρτηση κόστους [35].

Οι αλγόριθμοι βελτιστοποίησης στοχεύουν στην διαρκή διόρθωση ενός συνόλου βαρών και πολώσεων θ που χαρτογραφούν την είσοδο προς την έξοδο του δικτύου. Δεδομένου ότι τα δεδομένα προωθούνται πολλές φορές στο δίκτυο κατά την εκπαίδευση, σε όποια επανάληψη i , οι παράμετροι των νευρώνων είναι

$$\theta_{i+1} = \theta_i + \Delta\theta_i$$

4.4.1 Στοχαστική κλίση καθόδου (SGD)

Η παρούσα μέθοδος υπολογίζει την κλίση της συνάρτησης $J(\theta)$ με βάση τις παραμέτρους θ . Για N τροποποιήσεις του θ ανά εποχή,

$$\theta_{i+1} = \theta_i - \alpha \nabla J(\theta_i, x^i, y^i)$$

όπου θ_{i+1} και θ_i είναι οι αντίστοιχες παράμετροι στις εποχές $i+1$ και i , α προκαθορισμένος ρυθμός εκμάθησης που ορίζεται εξ αρχής ως εξωτερική μεταβλητή από τον ερευνητή και x, y η είσοδος και έξοδος αντίστοιχα. Παρόμοιες παραλλαγές του αλγορίθμου ανανεώνουν τα βάρη και τις πολώσεις μόνο μία φορά ανά εποχή.

4.4.2 Αλγόριθμος προσαρμοστικής κλίσης (ADAGRAD)

Παρόμοια με τον SGD, ο αλγόριθμος ADAGRAD χρησιμοποιεί έναν εξωτερικό ρυθμό εκμάθησης α , ο οποίος όμως τροποποιείται σε κάθε επανάληψη i . Ο ADAGRAD προσαρμό-

ζει τον ρυθμό εκμάθησης για κάθε παράμετρο ξεχωριστά χρησιμοποιώντας την ακολουθία εκτιμήσεων κλίσης. Διαισθητικά, προσαρμόζει τον ρυθμό εκμάθησης για κάθε χαρακτηριστικό, ανάλογα με την εκτιμώμενη γεωμετρία του προβλήματος. Ειδικότερα, τείνει να εκχωρεί υψηλότερους ρυθμούς εκμάθησης σε σπάνιες λειτουργίες, γεγονός που διασφαλίζει ότι οι ενημερώσεις παραμέτρων βασίζονται λιγότερο στη συχνότητα και περισσότερο στη συνάφεια.

4.4.3 Αλγόριθμος προσαρμοστικής στιγμιαίας εκτίμησης (ADAM)

Η μέθοδος ADAM καθορίζει έναν μοναδικό ρυθμό εκμάθησης α_i για κάθε βάρος θ_i , ο οποίος ενημερώνεται για κάθε ζεύγος δειγμάτων x_i, y_i . Χρησιμοποιεί δύο παράγοντες διόρθωσης ως κανόνα ενημέρωσης: έναν εκθετικά μειωμένο μέσο όρο των προηγούμενων τετραγωνικών κλίσεων και έναν εκθετικά μειωμένο μέσο όρο των προηγούμενων ενημερώσεων $\Delta\theta_i$. Σύμφωνα με το [36], ο ADAM έχει καλύτερη απόδοση από άλλους προσαρμοστικούς αλγόριθμους βελτιστοποίησης και είναι από τους πιο δημοφιλείς βελτιστοποιητές που χρησιμοποιούνται στα τεχνητά νευρωνικά δίκτυα. Μέσω δοκιμών, ο συγκεκριμένος αλγόριθμος εφαρμόστηκε και στα δίκτυα που αναπτύχθηκαν στο πλαίσιο της παρούσας εργασίας.

Τα δύο κινούμενα μέσα (moments), ένα για τον πρώτο όρο (mean - $\hat{m}$) και ένα για τον δεύτερο όρο (uncentered variance - $\hat{u}$) χρησιμοποιούνται για την *εκτίμηση* του μέσου m και του δείκτη διακύμανσης u των γραμμικών όρων της συνάρτησης κόστους. Ο ρυθμός μάθησης προσαρμόζεται δυναμικά για κάθε παράμετρο με βάση τον υπολογισμό των κινουμένων μέσων. Αυτό επιτρέπει στον ADAM να αντιμετωπίζει προβλήματα με διαφορετικές κλίσεις και κλίμακες. Αναλυτικά, τα βάρη και οι πολώσεις ενημερώνονται ως εξής:

$$\theta_{i+1} = \theta_i - \frac{\alpha}{\sqrt{\hat{u}_{i+1}} + \epsilon} \hat{m}_{i+1}$$

Λαμβάνοντας υπόψιν ότι:

$$m_{i+1} = \beta_1 m_i + (1 - \beta_1) \cdot \nabla J(\theta_i, x^i, y^i)$$

$$u_{i+1} = \beta_2 u_i + (1 - \beta_2) \cdot (\nabla J(\theta_i, x^i, y^i))^2$$


$$\hat{m}_{t+1} = \frac{m_{t+1}}{1 - \beta_1^{t+1}}$$

$$\hat{u}_{t+1} = \frac{u_{t+1}}{1 - \beta_2^{t+1}}$$

Για την ανάπτυξη των μοντέλων χρησιμοποιήθηκαν $\alpha = 0.001$, $\beta_1 = 0.9$, $\beta_2 = 0.999$ και $\epsilon = 10^{-8}$ [37].

4.5 Συναρτήσεις Ενεργοποίησης

Εκτός του τύπου και της ποσότητας των επιπέδων που εφαρμόζονται σε ένα τεχνητό νευρωνικό δίκτυο, εξίσου σημαντικό ρόλο έχουν και οι συναρτήσεις ενεργοποίησης που επιλέγονται. Λαμβάνοντας την έξοδο του επιπέδου, εφαρμόζεται η ανάλογη συνάρτηση ενεργοποίησης για τη μετατροπή της εξόδου σε είσοδο του επόμενου επιπέδου. Η χρήση τέτοιων συναρτήσεων είναι αναγκαία για την προσθήκη μη γραμμικότητας στο δίκτυο. Ελλείψει συνάρτησης ενεργοποίησης, το σήμα εξόδου θα είναι γραμμικό ως προς την είσοδο, και το δίκτυο θα αδυνατεί να χαρτογραφήσει περιπλοκότερα δεδομένα. Οι συναρτήσεις ενεργοποίησης οφείλουν να είναι διαφορίσιμες, ώστε να μπορεί να γίνει back-propagation για τον υπολογισμό του σφάλματος και βελτιστοποίηση με τους εκάστοτε αλγορίθμους που αναλύθηκαν προηγουμένως. Συχνά, το πλάτος του σήματος εξόδου περιορίζεται σε ένα πεπερασμένο, προκαθορισμένο εύρος (π.χ. $[0, 1]$), και τότε αναφερόμαστε σε *συναρτήσεις σύνθλιψης* (*squashing functions*). Παρακάτω αναλύονται μερικές συχνές συναρτήσεις ενεργοποίησης $f(x)$, όπου x η έξοδος του επιπέδου, και η αντίστοιχη γραφική παράσταση στο Σχήμα 4.2.



Σχήμα 4.2: Γραφική αναπαράσταση συχνότερων συναρτήσεων ενεργοποίησης

- **Σιγμοειδής συνάρτηση (Sigmoid):** Η μη γραμμική σιγμοειδής συνάρτηση είναι από τις ευρέως δοκιμασμένες συναρτήσεις που παράγει έξοδο μεταξύ 0 και 1, και συχνά εφαρμόζεται σε προβλήματα δυαδικής ταξινόμησης.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4.1)$$

- **Γραμμική μονάδα ανόρθωσης (Rectified Linear Unit):** Χρησιμοποιείται αρκετά στα νευρωνικά δίκτυα καθώς δεν ενεργοποιούνται όλοι οι νευρώνες ταυτόχρονα, παρά μόνο μερικοί ανά περίπτωση. Ανά περίπτωση, η παράγωγος της είναι μηδέν, γεγονός που εμποδίζει την ενημέρωση βαρών και πολώσεων κατά το back-propagation.

$$\text{ReLU}(x) = \max(0, x) \quad (4.2)$$

- **Leaky ReLU:** Ταυτίζεται με την ReLU για θετική έξοδο, ενώ για τιμές μικρότερες του μηδενός επιστρέφει τιμή γραμμικώς ανάλογη της εισόδου,

$$f(x) = \begin{cases} x, & \text{αν } x \geq 0 \\ a \cdot x, & \text{διαφορετικά} \end{cases} \quad (4.3)$$

- **Softplus:** Είναι μία ομαλή και παραγωγίσιμη προσέγγιση της ReLU, με σημαντικό πλεονέκτημα την αποφυγή νεκρών νευρώνων - *dying ReLU* - που ενδέχεται να προκαλέσει η ReLU, κατά το οποίο νευρώνες που δικτύου γίνονται μη ενεργοί κατά την εκπαίδευση. Παρόλα αυτά, παρουσιάζει αυξημένο υπολογιστικό κόστος σε σχέση με την απλή ReLU.

$$f(x) = \log(1 + e^x) \quad (4.4)$$

- **Υπερβολική εφαστομένη:** Είναι πλήρως διαφορίσιμη και συνεχής, με τιμές στο διάστημα $(-1, 1)$. Προτιμάτε από την σιγμοειδή, καθώς η παράγωγος της είναι συμμετρική ως προς το μηδέν.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.5)$$

- **Μοναδιαία βηματική:** Μπορεί να εφαρμοστεί μόνο σε εφαρμογές δυαδικής ταξινόμησης και γραμμικής συσχέτισης χρονοσειρών,

$$f(x) = \begin{cases} 1, & \text{αν } x \geq 0 \\ 0, & \text{διαφορετικά} \end{cases} \quad (4.6)$$

Ερευνητικά δεν προκύπτει αυστηρός κανόνας για την επιλογή συγκεκριμένης συνάρτησης ενεργοποίησης ανά είδος δικτύου ή επίπεδο. Εμπειρικά έχει φανεί πως για μειωμένο σφάλμα, εκτός του αριθμού των κρυμμένων επιπέδων σε ένα δίκτυο, την μέθοδο εκπαίδευσης και τις λοιπές υπερπαραμέτρους, η επιλογή σωστών συναρτήσεων ενεργοποίησης είναι από τις πλέον σημαντικές παραμέτρους που πρέπει να ληφθούν υπόψη [38].

4.6 Συνελικτικά Νευρωνικά Δίκτυα

Τα συνελικτικά νευρωνικά δίκτυα (Convolutional Neural Networks) ειδικεύονται στην ανάλυση πλεγματοειδών εισόδων με ισχυρή χωρική συσχέτιση σε επιμέρους περιοχές του πλέγματος, όπως οι εικόνες. Ως εκ τούτου, ιστορικά χρησιμεύουν για αναγνώριση αντικειμένων και ταξινόμηση εικόνων κ.α. Παρόλα αυτά εμφανίζουν χρησιμότητα και στην ανάλυση άλλων ακολουθιακών δεδομένων, όπως οι χρονοσειρές. Κυριότερο στοιχείο αυτών είναι η χρήση *συνελικτικών επιπέδων* που εξάγουν χαρακτηριστικά από τα δεδομένα εισόδου. Στο πλαίσιο των χρονοσειρών, η συνέλιξη είναι μια μαθηματική πράξη που συνδυάζει δύο συναρτήσεις για να παράγει μια τρίτη συνάρτηση. Στην ανάλυση δεδομένο σε διακριτό χρόνο, αν f είναι η χρονοσειρά εισόδου και g είναι ένα φίλτρο, για χρονική στιγμή t :

$$(f * g)(t) = \sum_{\tau=-\infty}^{\infty} f(\tau)g(t - \tau)$$

Για μια πολυδιάστατη χρονοσειρά k μεταβλητών και n χρονικού βήματος, το *συνελικτικό επίπεδο* πολλαπλασιάζει την είσοδο $n \times k$ με ένα *φίλτρο* πλάτους ίσου με της εισόδου και ποικίλου μήκους. Συνεπώς το φίλτρο κινείται από την αρχή προς το τέλος της χρονοσειράς, πολλαπλασιάζοντας τα στοιχεία της. Τέλος, το άθροισμα των αποτελεσμάτων δίνεται σε μία συνάρτηση ενεργοποίησης και μετατρέπεται σε νέο φιλτραρισμένο στοιχείο μιας μονοδιάστατης χρονοσειράς.

4.7 Αναδρομικά Νευρωνικά Δίκτυα

Τα αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Networks) είναι ένας τύπος τεχνητού νευρωνικού δικτύου που έχει σχεδιαστεί για την επεξεργασία ακολουθιακών δεδομένων, όπως χρονοσειρές ή φυσική γλώσσα. Σε αντίθεση με τα νευρωνικά δίκτυα πρόσθιας τροφοδότησης, ένα Αναδρομικό δίκτυο έχει τουλάχιστον ένα *βρόχο ανάδρασης*, επιτρέποντας τη ροή πληροφοριών από την έξοδο ενός βήματος στην είσοδο του επόμενου βήματος, όπως φαίνεται στο Σχήμα 4.3. Αυτό επιτρέπει στα αναδρομικά δίκτυα να διατηρούν μια κατάσταση ή μνήμη προηγούμενων εισόδων, κάτι που είναι ιδιαίτερα χρήσιμο για εργασίες όπως η μετάφραση γλώσσας, η αναγνώριση ομιλίας και η ανάλυση χρονοσειρών.

Συγκεκριμένα, για μια χρονική στιγμή t , η είσοδος x_t , πολλαπλασιάζεται με τον πίνακα βαρών $\mathbf{W}_{xh}$ που μεταφέρει την είσοδο στο κρυφό επίπεδο, και το προηγούμενο κρυφό επί-

πεδο $\mathbf{h}_{t-1}$ πολλαπλασιάζεται με ένα πίνακα βαρών $\mathbf{W}_{hh}$ που αντιπροσωπεύει την αναδρομική ιδιότητα του συστήματος. Η πρόσθεση των δύο ποσοτήτων με την πόλωση b_h δίνουν την κατάσταση h_t , μέσω μίας συνάρτησης ενεργοποίησης $\sigma(\cdot)$:

$$\mathbf{h}_t = \sigma(\mathbf{W}_{xh}\mathbf{x}_t + \mathbf{W}_{hh}\mathbf{h}_{t-1} + \mathbf{b}_h) \quad (4.7)$$

Δημιουργείται, δηλαδή, ένα δυναμικό σύστημα που επιτρέπει την καταγραφή χρονικών εξαρτήσεων εντός της ακολουθίας. Για την ελαχιστοποίηση των σφαλμάτων, η ανανέωση των βαρών ανά επανάληψη γίνεται μέσω της *Οπισθοδιάδοσης στον χρόνο (back propagation through time - BPTT)*. Αξίζει να σημειωθεί πως η παρούσα μέθοδος εμφανίζει συχνά το πρόβλημα των *μηδενιζόμενων κλίσεων (vanishing gradients)*.


Τα RNN μπορούν να λάβουν διάφορες μορφές, όπως η βασική RNN, η μακροπρόθεσμη βραχυπρόθεσμη μνήμη (LSTM) και η Gated Recurrent Unit (GRU), το καθένα με τα δικά του πλεονεκτήματα και αδυναμίες. Τα RNN έχουν επιδείξει μεγάλη επιτυχία σε ένα ευρύ φάσμα εφαρμογών, από τη δημιουργία ρεαλιστικού κειμένου έως την πρόβλεψη των τιμών των μετοχών.

4.7.1 Πρόβλημα μηδενιζόμενων κλίσεων

Το πρόβλημα των *μηδενιζόμενων κλίσεων (vanishing gradients)* είναι ένα κοινό ζήτημα που προκύπτει κατά την εκπαίδευση νευρωνικών δικτύων, συμπεριλαμβανομένων των αναδρομικών, όπου η κλίση της συνάρτησης κόστους σε σχέση με τα βάρη μπορούν να γίνουν πολύ μικρές καθώς διαδίδονται στο δίκτυο. Αυτό καθιστά δύσκολη την αποτελεσματική ενημέρωση των βαρών, καθώς οι μικρές κλίσεις οδηγούν σε αργή ή μηδενική εκμάθηση.

Στην περίπτωση των αναδρομικών δικτύων, το πρόβλημα των *μηδενιζόμενων κλίσεων* είναι ιδιαίτερα σοβαρό καθώς το ίδιο σύνολο βαρών εφαρμόζεται σε κάθε είσοδο στην ακολουθία, και έτσι η κλίση σε κάθε χρονικό βήμα πολλαπλασιάζεται με το ίδιο σύνολο βαρών στην οπίσθια τροφοδότηση. Αυτό σημαίνει ότι για μικρά βάρη, οι κλίσεις μπορούν να γίνουν εκθετικά μικρές καθώς διαδίδονται πίσω στο χρόνο, με αποτέλεσμα πολύ αργή ή καθόλου μάθηση.

Για την αντιμετώπιση αυτού του ζητήματος, έχουν προταθεί διάφοροι τύποι αρχιτεκτονικών αναδρομικών δικτύων, όπως τα *δίκτυα μακράς-βραχύχρονης μνήμης (LSTM)*, που ενσωματώνουν μηχανισμούς για την επιλεκτική αποθήκευση ή απόρριψη πληροφοριών σε κάθε χρονικό βήμα.



Σχήμα 4.3: Πλήρως συνδεδεμένο αναδρομικό δίκτυο 2 εισόδων, με 2 κρυφούς νευρώνες και ένα νευρώνα εξόδου. Οι συνδέσεις ανάδρασης επισημαίνονται με χρώμα [2].

4.7.2 Δίκτυα μακράς-βραχύχρονης μνήμης

Τα Δίκτυα μακράς-βραχύχρονης μνήμης (*Long Short-Term Memory - LSTM*) ανήκουν στην κατηγορία των αναδρομικών δικτύων και αποσκοπούν στην αντιμετώπιση του προβλήματος μηδενιζόμενων κλίσεων μέσω εισαγωγής *κελιών μνήμης* και *πυλών εισόδου-εξόδου* και *επιλεκτικής συγκράτησης*. Τα προαναφερθέντα δίκτυα αποτελούνται από τέσσερα βασικά στοιχεία:

1. Πύλη Εισόδου
2. Πύλη Επιλεκτικής συγκράτησης
3. Κελί μνήμης
4. Πύλη εξόδου

Λαμβάνοντας ως εισόδους την τρέχουσα είσοδο $\bar{x}_t$ και την προηγούμενη κρυφή κατάσταση $\bar{h}_{t-1}$ υπολογίζονται οι πύλες εισόδου $\bar{i}$, επιλεκτικής συγκράτησης $\bar{f}$, και εξόδου $\bar{o}$, καθώς επίσης και η πιθανή νέα κατάσταση κελιού $\bar{c}$:

$$\bar{i} = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (4.8)$$

$$\bar{f} = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (4.9)$$

$$\bar{c} = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (4.10)$$

$$\bar{o} = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (4.11)$$

Όπου $\sigma(\cdot)$ συγμοειδής συνάρτηση ενεργοποίησης και $\tanh(\cdot)$ αντίστοιχη συνάρτηση υπερβολικής εφαπτομένης. Λόγω της σιγμοειδούς συνάρτησης ενεργοποίησης,

$$\sigma(x) = \frac{1}{1 + e^{-x}}, \text{ όπου } \sigma(x) \in [0, 1], \quad (4.12)$$

τα $\bar{i}, \bar{f}, \bar{o}$ μπορούν, χάριν απλότητας, να θεωρηθούν "δυαδικές" τιμές $\{0, 1\}$ και συνεπώς ο μεταξύ του πολλαπλασιασμός να παρομοιαστεί με χρήση λογικής πύλης AND, εξού και η ονομασία. Παρατηρώντας τις παραπάνω σχέσεις και το Σχήμα 4.4 συμπεραίνουμε πως:

1. Η πύλη εισόδου, λόγω της πρόσθεσης, ελέγχει κατά πόσο θα αποθηκευτεί νέα πληροφορία στο κελί μνήμης
2. Η πύλη επιλεκτικής συγκράτησης, λόγω του πολλαπλασιασμού, ελέγχει κατά πόσο θα απορριφθεί η προηγούμενη πληροφορία
3. Η πύλη εξόδου ελέγχει κατά πόσο θα διαρρεύσει πληροφορία από την κατάσταση κελιού προς την κρυφή κατάσταση.


Το νέο κελί μνήμης c_t ανανεώνεται με βάση τα παραπάνω ως εξής:

$$\bar{c}_t = \bar{f} \odot \bar{c}_{t-1} + \bar{i} \odot \bar{c} \quad (4.13)$$

Όπου το γινόμενο $\bar{f} \odot \bar{c}_{t-1}$ ορίζει κατά πόσο θα διατηρηθεί η προϋπάρχουσα τιμή και το $\bar{i} \odot \bar{c}$ κατά πόσο θα προστεθεί νέα πληροφορία. Επίσης, η κρυφή κατάσταση $\bar{h}_t$ υπολογίζεται:

$$\bar{h}_t = \bar{o} \odot \tanh(c_t) \quad (4.14)$$

Αυτή η σχέση δίνει την δυνατότητα στο δίκτυο να εξάγει επιλεκτικά πληροφορία από το κελί μνήμης σε κάθε χρονικό βήμα. Οι μηχανισμοί που αναλύθηκαν έχουν φανεί αρκετά ισχυροί στον εντοπισμό μακροχρόνιων εξαρτήσεων σε ακολουθιακά δεδομένα και λόγω αυτού



Σχήμα 4.4: Σχηματική αναπαράσταση LSTM κόμβου.

τα δίκτυα μακράς-βραχύχρονης μνήμης θεωρούνται σημαντικό εργαλείο για σχετικά προβλήματα [39, 40].

Κεφάλαιο 5

Ανάπτυξη μοντέλου πρόβλεψης αιολικής ισχύος

Στο παρόν κεφάλαιο θα αναλυθεί η μεθοδολογία που εφαρμόστηκε στην ανάπτυξη και δοκιμή διαφόρων νευρωνικών δικτύων πρόβλεψης αιολικής ισχύος. Επίσης, θα αναλυθεί το είδος και η προεργασία των δεδομένων εισόδου, καθώς και τα εργαλεία που χρησιμοποιήθηκαν.

5.1 Λογισμικά

Η δημιουργία και επεξεργασία των μοντέλων έγινε μέσω Python, με χρήση των Keras και TensorFlow. Η Python είναι μια υψηλού επιπέδου γλώσσα προγραμματισμού που χρησιμοποιείται ευρέως για διάφορες εφαρμογές, συμπεριλαμβανομένης της μηχανικής μάθησης και της τεχνητής νοημοσύνης. Το Keras είναι ένα API (Application Programming Interface) νευρωνικών δικτύων υψηλού επιπέδου, γραμμένο σε Python και ικανό να τρέχει στο TensorFlow, το CNTK ή το Theano. Στην παρούσα εργασία χρησιμοποιήθηκε το TensorFlow, το οποίο είναι μια βιβλιοθήκη λογισμικού ανοιχτού κώδικα που χρησιμοποιείται για εφαρμογές μηχανικής μάθησης όπως τα νευρωνικά δίκτυα. Η ανάλυση των δεδομένων εξόδου και των αποτελεσμάτων έγινε συνδυαστικά σε Python και Matlab. Μερικές από τις βασικές βιβλιοθήκες που χρησιμοποιήθηκαν είναι η Pandas για διαχείριση συνόλων δεδομένων, η NumPy για μαθηματικές συναρτήσεις και η Matplotlib για αναπαράσταση γραφικών παραστάσεων.

5.2 Αναπτυχθέντα μοντέλα πρόβλεψης

Στο πλαίσιο της παρούσας εργασίας αναλύθηκε η αποτελεσματικότητα τεσσάρων ειδών νευρωνικών δικτύων στην πρόβλεψη αιολικής παραγωγής με πραγματικές μετρήσεις από αιολικό πάρκο. Συγκεκριμένα, στόχος είναι ο σχεδιασμός αποδοτικών πιθανοτικών μοντέλων βασιζόμενα σε νευρωνικά δίκτυα για την εκτίμηση του Άνω και Κάτω ορίου (Lower-Upper bound estimation - LUBE) της προβλεπόμενης παραγωγής. Αυτό επιτυγχάνεται μέσω της εξαγωγής από το δίκτυο μίας πιθανοτικής κατανομής, που ορίζει το εύρος της εκάστοτε αιολικής παραγωγής. Με αυτό τον τρόπο μπορεί να ληφθεί είτε μία σημειακή πρόβλεψη, μέσω της μέσης τιμής της κατανομής, είτε μια πιθανοτική πρόβλεψη, μέσω του εύρους της κατανομής. Ο σχεδιασμός επικεντρώθηκε σε τέσσερα είδη νευρωνικών δικτύων:

1. Συνελικτικά νευρωνικά δίκτυα (CNN)
2. Δίκτυα μακράς βραχυπρόθεσμης μνήμης (LSTM)
3. Συνδυαστικό δίκτυο επιπέδων CNN-LSTM
4. Συνδυαστικό δίκτυο επιπέδων LSTM-CNN


Επίπεδο εξόδου

Παρά τις διαφοροποιήσεις των δικτύων στο είδος και στο πλήθος των εκάστοτε επιπέδων τους, οι οποίες θα αναλυθούν μετέπειτα, η βασική ομοιότητα τους είναι το επίπεδο εξόδου τους. Στόχος των νευρωνικών δικτύων που σχεδιάστηκαν είναι η δημιουργία πιθανοτικών προβλέψεων παραγωγής. Μέσω αυτών μπορούμε να λάβουμε το Άνω και Κάτω όριο της προβλεπόμενης αιολικής παραγωγής (Lower-Upper bound estimation) και άλλες σχετικές τιμές. Για την επίτευξη αυτού δημιουργήθηκε ένα επίπεδο εξόδου για την παραγωγή μίας κατανομής πιθανότητας για κάθε μέτρηση που δίνεται ως είσοδο. Εν ολίγοις, για κάθε μέτρηση αιολικής παραγωγής και ανέμου, το δίκτυο παράγει μια κατανομή πιθανοτήτων που ορίζει τις προβλεπόμενες τιμές παραγωγής στο μέλλον και τις αντίστοιχες πιθανότητες τους. Η ιδιαιτερότητα της συγκεκριμένης μεθόδου είναι πως μπορεί να δώσει τόσο σημειακά αποτελέσματα (μέσω της μέσης τιμής της κατανομής), όσο και πιθανοτικά (μέσω διαστημάτων εμπιστοσύνης της κατανομής). Επίσης, μας παρέχει ευκολία στην αύξηση και μείωση του εύρους των διαστημάτων, ώστε να επιτευχθεί η επιθυμητή απόδοση.

Το τελευταίο επίπεδο μοντελοποιεί μία κατανομή γάμμα $\Gamma(\alpha, \theta)$, μέσω των δεδομένων t που εξάγονται από το υπόλοιπο δίκτυο. Η κατανομή γάμμα ορίζεται μέσω του σχήματος α και της κλίμακας θ , όπου ορίζουν την μορφή της και εκτείνουν ή συμπύκνουν την συνάρτηση πυκνότητας πιθανότητας κατά την διεύθυνση του άξονα. Συνεπώς, δίνεται η ανάλογη έξοδος Y του δικτύου,

$$Y \sim \Gamma(\alpha = |t[\dots, : 1]|, \theta = \sigma(t[\dots, 1 :]))$$

Δεδομένου ότι η παραγόμενη έξοδος είναι κατανομή, αντί για σταθερές τιμές, η οριοθέτηση του Άνω και Κάτω άκρου γίνεται μέσω επιλογής ενός διαστήματος εμπιστοσύνης της κατανομής, όπως παρουσιάζεται ενδεικτικά στο Σχήμα 5.1. Η επιλογή του κατάλληλου διαστήματος εμπιστοσύνης επιδρά άμεσα στην απόδοση των μοντέλων. Αυξημένο διάστημα παράγει μεγαλύτερο εύρος και μεγαλύτερο PICP, μειώνοντας όμως την αιχμηρότητα του μοντέλου (αυξημένο PINAW).



Σχήμα 5.1: Ενδεικτική κατανομή Γάμμα - τα διάφορα διαστήματα κάλυψης φαίνονται με χρώμα.

Δίκτυο 1: Συνελικτικό δίκτυο (CNN)

Το συνελικτικό δίκτυο CNN που αναπτύχθηκε αποτελείται από συνολικά 7 επίπεδα. Αρχικά, τα δεδομένα τροφοδοτούνται από το επίπεδο εισόδου σε 2 συνελικτικά επίπεδα, διαφορετικών φίλτρων έκαστο και έπειτα σε ένα flatten επίπεδο, όπως φαίνεται στο Σχήμα 5.2. Κάθε συνελικτικό επίπεδο στοχεύει στην εξαγωγή μη γραμμικών χαρακτηριστικών των δεδομένων, ενώ η σε σειρά χρήση συνελικτικών επιπέδων επιτρέπει την σταδιακή και σε βάθος μοντελοποίηση των μοτίβων. Προωθώντας τα δεδομένα από συνελικτικά επίπεδα πολλών

φίλτρων σε λιγότερων, επιτυγχάνεται η σταδιακή ανάλυση των μοτίβων τους, από ένα ευρύ φάσμα, σε ένα πιο αναλυτικό.

Κατά την εκπαίδευση, αρχικά υπολογίζεται το σφάλμα στα διάφορα επίπεδα, με βάση την επιθυμητή τιμή και την έξοδο. Αυτό ελαχιστοποιείται στο στάδιο της οπίσθιας διάδοσης (back-propagation), μέσω της ανανέωσης των βαρών και των πολώσεων. Αναλυτικότερα, συνελκτικό επίπεδο εφαρμόζει στο διάνυσμα εισόδου $X = [x_1, \dots, x_n]$, ένα σύνολο φίλτρων $W = [w_1, w_2, \dots, w_n]$. Η συνέλιξη σε κάθε θέση i υπολογίζεται ως

$$C_i = \sum_{j=1}^n w_j * x_{i+j-1} + b$$

με συνάρτηση ενεργοποίησης f δέχεται ως είσοδο τα δεδομένα εκπαίδευσης ως πίνακα $[n, 1]$, εξάγοντας έναν χάρτη χαρακτηριστικών

$$C_1 = f\left(\sum W_1 * X + b_1\right)$$


όπου $*$ ο συνελκτικός τελεστής. Έπειτα τα δεδομένα τροφοδοτούνται στο επόμενο συνελκτικό επίπεδο και εξάγεται ο αντίστοιχος χάρτης χαρακτηριστικών:

$$C_2 = f\left(\sum W_2 * C_1 + b_2\right)$$

Έπειτα τοποθετήθηκε ένα flatten επίπεδο, για την μετάδοση δεδομένων από τα συνελκτικά στα πυκνά επίπεδα. Συνεπώς, τα δεδομένα εξόδου του συνελκτικού φίλτρου μετατρέπονται σε μονοδιάστατο διάνυσμα. Αυτό εΐθισται κατά τη μετάβαση από συνελκτικά επίπεδα σε πλήρως συνδεδεμένα - πυκνά - επίπεδα. Η flatten αναπαράσταση διατηρεί αναλλοίωτα τα χαρακτηριστικά που εξάγονται από τα συνελκτικά επίπεδα. Τέλος, τοποθετήθηκαν δύο επιπλέον πλήρως διασυνδεδεμένα επίπεδα για περαιτέρω εκμάθηση του δικτύου και την τροφοδοσία των δεδομένων στο επίπεδο πιθανοτική κατανομής, όπου εξάγει τα τελικά αποτελέσματα του νευρωνικού δικτύου, όπως θα αναλυθεί μετέπειτα.

Δίκτυο 2: Μακράς βραχυπρόθεσμης μνήμης (LSTM)

Αντίστοιχα με το συνελκτικό δίκτυο CNN σχεδιάστηκε ένα δίκτυο μακράς βραχυπρόθεσμης μνήμης (LSTM), για να ελεγχθεί η απόδοση του δικτύου με την εισαγωγή LSTM επιπέδων στο δίκτυο. Τα λοιπά επίπεδα του δικτύου παρέμειναν ίδια όπως φαίνεται στο Σχήμα 5.3. Κύρια παράμετρος ενός LSTM επιπέδου είναι το πλήθος των κελιών μνήμης που περιέχει. Όπως και στις υπόλοιπες παραμέτρους ενός νευρωνικού δικτύου, δεν υπάρχει αυστηρός



Σχήμα 5.2: Γραφική αναπαράσταση συνελικτικού δικτύου


κανόνας για τον ορισμό του πλήθους κελιών εκ των προτέρων. Η επιλογή βασίζεται κυρίως στα εξής:

- Πλήθος δεδομένων εκπαίδευσης: Η αύξηση των κελιών μνήμης του επιπέδου συχνά συνιστάται όταν υπάρχει αυξημένο πλήθος διαθέσιμων δεδομένων κατά το στάδιο της εκπαίδευσης.
- Απόδοση μοντέλου: Η αποφυγή υπερπροσαρμογής (overfitting) ή υποπροσαρμογής (underfitting) ενδέχεται να αποφευχθεί μέσω της αντίστοιχης μείωσης ή αύξησης των κελιών.
- Υπολογιστικό κόστος: Συγκριτικά με συνελικτικά ή άλλα απλούστερα δίκτυα, τα δίκτυα LSTM εμφανίζουν σημαντικά αυξημένο υπολογιστικό κόστος, το οποίο σχετίζεται με τον μέγεθος των LSTM επιπέδων τους.

Συνεπώς, λαμβάνοντας υπόψιν τα παραπάνω, μέσω δοκιμών (trial and error), επιλέχθηκε η τελική δομή του δικτύου και του LSTM επιπέδου με τις παραμέτρους του Σχήματος 5.3.

Δίκτυα 3-4 : Συνδυαστικά δίκτυα CNN-LSTM και LSMT-CNN

Η ταυτόχρονη εφαρμογή συνελικτικών επιπέδων με επίπεδα μακράς βραχυπρόθεσμης μνήμης έχει εφαρμοστεί ερευνητικά για την πρόβλεψη αιολικής παραγωγής. Τα υπάρχοντα




Σχήμα 5.3: Γραφική αναπαράσταση δικτύου LSTM


μεμονωμένα CNN και LSTM δίκτυα μπορούν να καθορίσουν τη μη γραμμική συσχέτιση μεταξύ των μεταβλητών εξόδου και εισόδου μέσω ενός μεγάλου αριθμού ιστορικών δεδομένων για την πρόβλεψη της ταχύτητας του ανέμου ή της αιολικής ισχύος. Δεδομένου ότι τα εκάστοτε μοντέλα έχουν ξεχωριστά πλεονεκτήματα και μειονεκτήματά του, ο συνδυασμός αυτών ενδέχεται να συνδυάσει συμπληρωματικά πλεονεκτήματα καθενός για την βελτίωση της ακρίβειας της πρόβλεψης [41]. Συνεπώς, ένα συνδυαστικό δίκτυο CNN-LSTM συνδυάζει το πλεονέκτημα της εξαγωγής χωρικών χαρακτηριστικών του CNN και το πλεονέκτημα της εξαγωγής χαρακτηριστικών χρονοσειρών του LSTM για την εξαγωγή της χωροχρονικής συσχέτισης μεταξύ πολλαπλών μετεωρολογικών παραγόντων και αιολικής ενέργειας. Κατά τον σχεδιασμό του μοντέλου, η δομή και οι παραμετροποίηση των συνελκτικών και των LSTM επιπέδων παρέμεινε ίδια, για την άμεση σύγκριση της αποτελεσματικότητας του δικτύου, όπως φαίνεται στα Σχήματα 5.4 και 5.5 [42].

5.3 Μεθοδολογία αξιολόγησης δικτύων

Με βάση την βιβλιογραφική ανασκόπηση του Κεφαλαίου 1 είναι εμφανής η πολυπλοκότητα που προκύπτει κατά την αξιολόγηση μοντέλων πρόβλεψης αιολικής παραγωγής. Όπως αναλύθηκε προηγουμένως, εφαρμόζεται διαφορετική μεθοδολογία στα σημειακά και στα πιθανοτικά μοντέλα πρόβλεψης, λόγω της διαφορετικής μορφής αποτελέσματος που παράγουν. Παρότι στις σημειακές προβλέψεις χρησιμοποιούνται κλασικοί δείκτες, όπως το μέσο απόλυτο σφάλμα, στις πιθανοτικές προβλέψεις χρησιμοποιούνται πιο εξειδικευμένοι δείκτες



Σχήμα 5.4: Γραφική αναπαράσταση δικτύου CNN-LSTM



Σχήμα 5.5: Γραφική αναπαράσταση δικτύου LSTM-CNN

απόδοσης. Αυτό συμβαίνει λόγω της ιδιομορφίας των δεδομένων που παράγουν τα πιθανοτικά μοντέλα, τα οποία πρέπει να συγκριθούν με τα πραγματικά σημειακά δεδομένα ανέμου.

Στην παρούσα εργασία, θα χρησιμοποιηθούν και οι δύο μέθοδοι, λόγω της διπλής μορφής αποτελεσμάτων που παράγονται από τα δίκτυα που αναπτύχθηκαν. Με βάση την μέση τιμή της εκάστοτε κατανομής Γάμμα υπολογίζονται τα:

- Μέσο απόλυτο σφάλμα (MAE) - (εξ. 1.1)
- Μέσο τετραγωνικό σφάλμα (RMSE) - (εξ. 1.3)
- Μέσο κανονικοποιημένο σφάλμα απόλυτου εύρους (MARNE) - (εξ. 1.5)

Αντίστοιχα, για την πιθανοτική αξιολόγηση χρησιμοποιούνται τα άνω και κάτω όρια της κατανομής, με βάση ένα προκαθορισμένο ποσοστό κάλυψης α . Η επιλογή αυτού γίνεται μέσω δοκιμών, ώστε να βρεθεί κατάλληλη τιμή που να αποδίδει ικανοποιητικά αποτελέσματα σε όλα τα δίκτυα, και έπειτα να υπολογιστούν τα:

- Πιθανότητα κάλυψης (PICP) - (εξ. 1.6)
- Σταθμισμένο Μέσο Πλάτος των ΔΠ (PINAW) - (εξ. 1.8)

5.4 Διαθέσιμα δεδομένα εισόδου

Η δημιουργία του μοντέλου βασίστηκε σε πραγματικά δεδομένα που παράχθηκαν σε Αιολικό πάρκο εντός της Ελλάδας. Ως δεδομένα εισόδου και αξιολόγησης χρησιμοποιήθηκαν οι ιστορικές τιμές παραγόμενης ισχύος ανεμογεννήτριας, καθώς και η ταχύτητα και διεύθυνση του ανέμου στην περιοχή. Τα διαθέσιμα δεδομένα χωρίστηκαν σε δύο τμήματα για την εκπαίδευση και την αξιολόγηση του μοντέλου. Τα δεδομένα εκπαίδευσης αφορούν την περίοδο 1/11/2016 έως 31/10/2018 και τα δεδομένα αξιολόγησης την περίοδο 1/11/2018 έως 1/12/2019. Τα δεδομένα εκπαίδευσης αντιπροσωπεύουν 25 μήνες, αποτελούμενα από 103732 μετρήσεις. Αναλόγως, τα δεδομένα αξιολόγησης αντιπροσωπεύουν 395 ημέρες (13 μήνες), αποτελούμενα από 56881 μετρήσεις. Για κάθε χρονική στιγμή t , τα διαθέσιμα δεδομένα είναι η τρέχουσα παραγόμενη ισχύς και η τρέχουσα ταχύτητα και διεύθυνση του ανέμου.

Κατά την ανάπτυξη ενός νευρωνικού δικτύου, το πρώτο και κύριο βήμα είναι η επιλογή των δεδομένων εισόδου που θα τροφοδοτηθούν, τόσο σε ποσοτικό όσο και σε ποιοτικό επί-

πεδο. Σύμφωνα με την διαθέσιμη βιβλιογραφία, ως είσοδος στο δίκτυο δόθηκε για κάθε χρονική στιγμή η ανάλογη τιμή ισχύος, ταχύτητας και διεύθυνσης του ανέμου πριν από 1 και 2 βήματα (Σενάριο A). Επίσης, ελέγχθηκε και η επιπρόσθετη είσοδος της τρέχουσας ταχύτητας και διεύθυνσης ανέμου (Σενάριο B).

$$X_{A,t+1} = \begin{bmatrix} P_t \\ P_{t-1} \\ \cos \theta_t \\ \cos \theta_{t-1} \\ v_t \\ v_{t-1} \end{bmatrix} \quad \text{και} \quad X_{B,t+1} = \begin{bmatrix} P_t \\ P_{t-1} \\ \cos \theta_{t+1} \\ \cos \theta_t \\ \cos \theta_{t-1} \\ v_{t+1} \\ v_t \\ v_{t-1} \end{bmatrix}$$

Στο διάνυσμα εισόδων A εμφανίζονται μεταβλητές ισχύος P , διεύθυνσης $\cos(\theta)$ και ταχύτητας v , αναφερόμενες στην παρούσα έξοδο και στην έξοδο 1 βήμα πριν. Αντίστοιχα, στο σενάριο B προστίθεται και η προβλεπόμενη τιμή ταχύτητας και διεύθυνσης 1 βήμα μετά, δηλαδή την στιγμή της προβλεπόμενης ισχύος. Τα δίκτυα που έλαβαν ως είσοδο την προβλεπόμενη τιμή ταχύτητας και διεύθυνσης απέδωσαν σημαντικά καλύτερα σε σχέση με τα υπόλοιπα. Συγκεκριμένα, διατηρώντας τις υπόλοιπες παραμέτρους σταθερές (δομή δικτύου, συνάρτηση ενεργοποίησης, βελτιστοποιητής κ.λπ), παρατηρήθηκε αύξηση του PICP με αναλογικά μικρότερη αύξηση του PINAW, τόσο στο CNN όσο και στο CNNv-LSTM δίκτυο. Ταυτόχρονα, τα σημειακά σφάλματα μειώθηκαν και στις 2 περιπτώσεις όπου τα δεδομένα ανέμου για $t + 1$ δόθηκαν ως είσοδο. Τα δίκτυα LSTM και LSTM-CNN δεν απέδωσαν αποτελέσματα χωρίς την εισαγωγή των τρεχόντων μετρήσεων. Αναλυτικά αποτελέσματα παρουσιάζονται στον Πίνακα 5.1.


Με γνώμονα την βιβλιογραφία, ελέγχθηκε η απόδοση του συστήματος με είσοδο μόνο την ισχύ ή μόνο τις μετεωρολογικές μετρήσεις, παρόλα αυτά τα μοντέλα που αναπτύχθηκαν δεν απέδιδαν αρκετά καλά χωρίς και τις τρεις τιμές. Για την καλύτερη διαχείριση των δεδομένων από το νευρωνικό δίκτυο, οι τιμές ισχύος διαβαθμίστηκαν για να μειωθεί το εύρος τους, μέσω της συνάρτησης MinMaxScaler. Αντίστοιχα, για την καλύτερη διαχείριση του από το νευρωνικό δίκτυο, οι τιμές της διεύθυνσης του ανέμου δόθηκαν ως συνημίτονα των γωνιών θ , αντί των ίδιων των γωνιών.

Για την πρόβλεψη της παραγόμενης ισχύς P_t σε μία χρονική στιγμή t , δόθηκαν ως είσοδοι

Πίνακας 5.1: Αποτελέσματα δικτύων CNN-LSTM και CNN για εισαγωγή ή μη της τρέχουσας ταχύτητας και διεύθυνσης ανέμου σαν είσοδο δικτύου.

Δείκτης	CNN-LSTM		CNN	
	t+1 άγνωστο	t+1 γνωστό	t+1 άγνωστο	t+1 γνωστό
PICP(%)	79,9	99,3	75,4	97,0
PINAW(%)	21,7	19,3	19,1	9,7
MAE(kW)	12115,8	2340,27		2504,96
RMSE(kW)	19481,2	5115,78		5535,03

στο δίκτυο οι ιστορικές τιμές ισχύος, κατεύθυνσης και ταχύτητας ανέμου, ενός και δύο βημάτων πίσω και η τρέχουσα μετρήσεις ταχύτητας και κατεύθυνσης. Με βάση τα διαθέσιμα δεδομένα, κάθε βήμα μέτρησης ισοδυναμεί με 1 ώρα. Εμπειρικά η συσχέτιση της τρέχουσας τιμής παραγωγής και των προηγούμενων μετρήσεων μειώνεται με την αύξηση του βήματος, γεγονός που είναι εμφανές και στο Σχήμα 5.6. Βάσει αυτού, και λαμβάνοντας υπόψιν και το υπολογιστικό κόστος του δικτύου, επιλέχθηκαν ως είσοδοι οι 2 προηγούμενες μετρήσεις ισχύος.



Σχήμα 5.6: Αυτοσυσχέτιση μετρήσεων ισχύος βήματος μίας ώρας

5.5 Παραμετροποίηση μοντέλων

Όπως αναλύθηκε προηγουμένως, εκτός της γενικής δομής του δικτύου, πρέπει να οριστούν επιπλέον παράμετροι για την εκπαίδευση του, με βασικότερα τα:

- Συναρτήσεις ενεργοποίησης νευρώνων

- Αλγόριθμοι Βελτιστοποίησης
- Υπερπαράμετροι και παράμετροι:
 - Εποχές (epochs)
 - Ρυθμός εκμάθησης
 - Batch size
 - Kernel size, pool size, bias, return sequence κ.λπ.

Οι συναρτήσεις ενεργοποίησης ορίζονται ξεχωριστά στο εκάστοτε επίπεδο του νευρωνικού δικτύου, αναλόγως το είδος του επιπέδου και το προς επίλυση πρόβλημα. Στα επίπεδα μακράς βραχυπρόθεσμης μνήμης (LSTM) χρησιμοποιείται από προεπιλογή η υπερβολική εφαιπτομένη και η σιγμοειδής, λόγω των εν γένει χαρακτηριστικών τους. Στα συνελικτικά επίπεδα δοκιμάστηκαν οι συναρτήσεις Softplus (εξ. 4.4) και ReLU (εξ. 4.2). Χάριν απλότητας, όλα τα συνελικτικά επίπεδα του δικτύου χρησιμοποιούν ίδια συνάρτηση ενεργοποίησης. Παρόλα αυτά, δεν εντοπίστηκε σημαντική διαφορά στην απόδοση των δικτύων για κάποια από τις δύο συναρτήσεις. Σχετικά με τους αλγόριθμους βελτιστοποίησης, μέσω δοκιμών (trial and error) επιλέχθηκε ο αλγόριθμος Adam.

Οι υπερπαράμετροι του δικτύου (epochs, learning rate και batch size) ορίζονται εμπειρικά μέσω δοκιμών. Κάθε εποχή (epochs) ορίζεται ως ένα μόνο πέρασμα των δεδομένων εκπαίδευσης σε ολόκληρο το νευρωνικό δίκτυο. Κατά τη διάρκεια κάθε εποχής, το δίκτυο διατρέχεται από ολόκληρο το σύνολο δεδομένων που υπάρχουν, υπολογίζοντας το σφάλμα και ενημερώνοντας τις εκάστοτε παραμέτρους των νευρώνων του με βάση τον αλγόριθμο βελτιστοποίησης που έχει οριστεί. Η επιλογή του αριθμού των εποχών επηρεάζει άμεσα την ικανότητα του μοντέλου να αναγνωρίζει μοτίβα από τα δεδομένα. Επιλέγοντας μικρό αριθμό εποχών μπορεί να οδηγηθεί σε υποπροσαρμογή, ενώ ένας υπερβολικός αριθμός μπορεί να οδηγήσει σε υπερπροσαρμογή. Ερευνητικά δεν έχει προκύψει κάποιος αυστηρός κανόνας για την επιλογή αριθμού εποχών και ως εκ τούτου η επιλογή έγινε βάσει δοκιμών.

Το batch size αναφέρεται στον αριθμό των δεδομένων που υποβλήθηκαν σε επεξεργασία ανά εποχή κατά την εκπαίδευση. Το σύνολο δεδομένων εκπαίδευσης χωρίζεται σε παρτίδες (batches) και οι παράμετροι του μοντέλου ενημερώνονται με βάση τη μέση κλίση που υπολογίζεται σε κάθε παρτίδα. Η επιλογή του κατάλληλου μεγέθους παρτίδας είναι μια αντιστάθμιση μεταξύ της υπολογιστικής απόδοσης και της ποιότητας των ενημερώσεων παραμέτρων. Τα μικρότερα μεγέθη παρτίδας μπορεί να προσφέρουν περισσότερο θόρυβο στις εκτιμήσεις

κλίσης, ενώ τα μεγαλύτερα μεγέθη παρτίδας μπορεί να απαιτούν περισσότερη μνήμη και υπολογιστικούς πόρους.

5.6 Αποτελέσματα ωριαίας πρόβλεψης

Ανάλογα με το είδος της εξόδου ενός δικτύου, πραγματοποιείται διαφορετική σύγκριση των αποτελεσμάτων τους. Μοντέλα σημειακής εξόδου χρησιμοποιούν σημειακά σφάλματα για τον υπολογισμό της απόδοσης τους, ενώ πιθανοτικά μοντέλα βασίζονται σε ειδικότερους τύπους, όπως αναλύθηκε σε προηγούμενο κεφάλαιο. Τα δίκτυα που σχεδιάστηκαν στην παρούσα εργασία, παράγουν κατανομή πιθανοτήτων για τις μελλοντικές τιμές παραγωγής, το οποίο μπορεί να αξιολογηθεί τόσο σημειακά, μέσω της μέσης τιμής της κατανομής, όσο και πιθανοτικά, μέσω των αντίστοιχων διαστημάτων εμπιστοσύνης. Λόγω αυτού, η σύγκρισή και αξιολόγηση των αποτελεσμάτων, εμφανίζει μεγαλύτερη πολυπλοκότητα. Στην παρούσα ενότητα θα αναλύσουμε τα επιμέρους αποτελέσματα των δικτύων μέσω διαφόρων μετρήσεων, τόσο συνολικά, όσο και τμηματικά σε συγκεκριμένες μέρες και χρονικά διαστήματα.

5.6.1 Αποτελέσματα σημειακής πρόβλεψης

Ως μέτρο σύγκρισης των αποτελεσμάτων που λήφθηκαν από τα νευρωνικά δίκτυα θα χρησιμοποιηθεί η μέθοδος παραμένουσας τιμής. Σύμφωνα με αυτήν, για κάθε μελλοντική χρονική στιγμή $t + 1$, η προβλεπόμενη τιμή ισχύος είναι:

$$P_{t+1} = P_t$$

Η παρούσα μέθοδος χρησιμοποιείται συχνά ως σημείο αναφοράς για αξιολόγηση νέων μοντέλων, κυρίως σε προβλέψεις μικρού χρονικού ορίζοντα, καθώς παρέχει ικανοποιητικά αποτελέσματα [19]. Βάσει αυτής, οι δείκτες σφάλματος της πρόβλεψης παραγωγής είναι:

- MAE = 10.581,15 kW
- RMSE = 18.766,55 kW
- MARNE = 7,35% kW

Αντίστοιχα, στον Πίνακα 5.2 παρουσιάζονται τα αντίστοιχα σφάλματα των δικτύων που αναπτύχθηκαν. Με βάση της σημειακές εξόδους των δικτύων, υπάρχει σημαντική μείωση


του σφάλματος και στα τέσσερα είδη. Με βάση το σταθμισμένο μέσο απόλυτο σφάλμα (MARNE), που είναι και ο σημαντικότερος δείκτης, το δίκτυο LSTM-CNN παρείχε τις ακριβέστερες προβλέψεις, με αντιστοίχως μικρότερο Μέσο Απόλυτο Σφάλμα. Σε σχέση με το μοντέλο παραμένουσας τιμής, στο LSTM-CNN παρατηρείται μεταβολή του MAE κατά -82,45%, του RMSE κατά -72,82% και του MARNE κατά -82,44%. Το LSTM δίκτυο απέδωσε σχεδόν εξίσου καλά με το LSTM-CNN, με μικρή μεταβολή των MAE και MARNE κατά +6,9%. Αξίζει να σημειωθεί πως μεταξύ των LSTM και LSTM-CNN παρατηρείται αύξηση του MAE και μείωση του RMSE. Αυτό υποδηλώνει ότι το LSTM, αν και έδωσε συνολικά χειρότερο σφάλμα, κατάφερε να προβλέψει καλύτερα ακραίες τιμές παραγωγής. Στο δίκτυο CNN, συγκριτικά με το LSTM-CNN δίκτυο, το MAE αυξήθηκε κατά +25,7%, το MARNE κατά +94,2% και το RMSE κατά +9,61%. Το συνδυαστικό δίκτυο CNN-LSTM ως προς το LSTM-CNN έχει αυξημένο MAE κατά +17%, RMSE κατά 1,3% και MARNE κατά +81.88%.

Πίνακας 5.2: Σημειακά σφάλματα όλων των διαθέσιμων μοντέλων

Δίκτυο	MAE (kW)	RMSE (kW)	MARNE (%)
Persistence	10581.15	18766.55	7.35
LSTM	1992.96	5049.05	1.38
CNN	2504.96	5535.03	2.68
CNN-LSTM	2340.27	5115.78	2.51
LSTM-CNN	1846.20	5100.59	1.29

Αναλύοντας τα αντίστοιχα σφάλματα ανά μήνα, παρατηρείται σημαντική μεταβολή της απόδοσης των μοντέλων, όπως φαίνεται στο Σχήμα 5.7. Και τα 4 μοντέλα εμφάνισαν χειρότερη απόδοση τον 1/2019, όπου είναι ο μήνας με της περισσότερες και εντονότερες διακυμάνσεις, με έντονες αυξομειώσεις μεταξύ μέγιστης και μηδενικής παραγωγής σε μεγαλύτερη τμήμα του. Στην χειρότερη περίπτωση, καλύτερη απόδοση εμφάνισε πάλι το LSTM-CNN Δίκτυο με MAE 4.188,11 kW, αυξημένο κατά +124.71% επί του συνολικού. Αντίστοιχα, η καλύτερη απόδοση εμφανίζεται τον 10/2019, με μικρότερο MAE 982.24 kW και MARNE 0.68% από το LSTM. Στο Πίνακα 5.3 παρουσιάζονται αναλυτικά οι μηνιαίες αποδόσεις όλων των Δικτύων.

Επιπρόσθετα, ένα συχνό εργαλείο για την αξιολόγηση των σφαλμάτων είναι το ιστόγραμμα κατανομής σφαλμάτων, το οποίο δείχνει την κατανομή του μεγέθους των σφαλμά-



Σχήμα 5.7: Γραφική αναπαράσταση μηνιαίας ανάλυσης σφάλματος μεθόδου Persistence και νευρωνικών δικτύων - MAE (kW) και MARNE (%)


των. Ιδανικά, η κύρια μπάρα του ιστογράμματος βρίσκεται στο μηδέν ή πολύ κοντά σε αυτό με τις υπόλοιπες με όσο το δυνατόν μικρότερα ύψη. Αρχικά, στο Σχήμα 5.8 παρουσιάζεται η κατανομή των σφαλμάτων της μεθόδου παραμένουσας τιμής ως σύγκριση. Η συγκεκριμένη έχει σημαντική διασπορά των σφαλμάτων, τόσο σε ποσοστό επί του συνόλου όσο και σε μέγεθος, με μέση τιμή 7.080 kW για το 46,6% των σφαλμάτων και -7084 για το 29,1%.

Τα εκάστοτε σφάλματα των νευρωνικών δικτύων σε σχέση με την παραμένουσα τιμή είναι εμφανώς πιο συγκεντρωμένα στο μηδέν με μικρότερη διασπορά στον οριζόντιο άξονα και μικρότερες μέσες τιμές, όπως φαίνεται στα Σχήματα 5.10, 5.9, 5.11 και 5.12. Με γνώμονα την διασπορά των σφαλμάτων στον οριζόντιο άξονα, το δίκτυο LSTM έχει την καλύτερη

Πίνακας 5.3: Μηνιαία ανάλυση σημειακού σφάλματος ενδοωριαίας πρόβλεψης νευρωνικών δικτύων - Δίνονται τα MAE (kW) και MARNE (%).


		LSTM	CNN	CNN-LSTM	LSTM-CNN
MAE	ΣΥΝΟΛΟ ΠΕΡΙΟΔΟΥ	1.992,96	2.504,96	2.340,27	1.864,20
	11/2018	1.502,45	2.048,94	1.961,48	1.487,49
	12/2018	2.966,33	3.622,96	3.126,60	2.435,71
	1/2019	4.561,76	5.381,56	4.439,75	4.188,11
	2/2019	2.773,64	4.142,23	2.815,51	2.502,30
	3/2019	2.112,66	2.646,37	2.402,87	2.009,26
	4/2019	1.711,06	2.175,00	2.061,13	1.678,15
	5/2019	1.872,72	2.306,52	2.132,81	1.802,04
	6/2019	1.980,39	2.103,18	2.423,78	1.897,61
	7/2019	1.488,10	1.858,02	2.011,49	1.491,58
	8/2019	1.274,32	1.617,73	1.920,33	1.248,02
	9/2019	1.167,25	1.535,13	1.645,04	1.098,43
	10/2019	982,24	1.286,33	1.592,48	950,84
	11/2019	1.524,13	1.910,30	1.880,88	1.451,82
MARNE	ΣΥΝΟΛΟ ΠΕΡΙΟΔΟΥ	1,38	2,68	2,51	1,29
	11/2018	1,04	1,42	1,36	1,03
	12/2018	2,16	2,64	2,28	1,78
	1/2019	3,22	3,80	3,13	2,96
	2/2019	1,96	2,92	1,99	1,77
	3/2019	1,49	1,87	1,70	1,42
	4/2019	1,22	1,55	1,46	1,19
	5/2019	1,30	1,60	1,48	1,25
	6/2019	1,38	1,47	1,69	1,33
	7/2019	1,03	1,29	1,40	1,04
	8/2019	0,88	1,12	1,33	0,87
	9/2019	0,82	1,08	1,16	0,78
	10/2019	0,68	0,89	1,11	0,66
	11/2019	1,08	1,35	1,33	1,03

απόδοση, καθώς το 91,3% των σφαλμάτων του βρίσκονται στην τιμή 3.631 kW. Λιγότερο ικανοποιητικά αποτελέσματα έχει και το δίκτυο CNN, με το 75% των σφαλμάτων να έχουν μέση τιμή -4.528 kW. Τα δίκτυα LSTM-CNN και CNN-LSTM εμφάνισαν μεγαλύτερες διακυμάνσεις στο σφάλμα τους. Το CNN-LSTM έχει κύρια μπάρα ιστογράμματος στο -7.831 kW για το 64,1% των σφαλμάτων και το LSTM-CNN έχει κύρια μπάρα στο 6.449 kW για το 70% των σφαλμάτων. Δεδομένου ότι το σφάλμα ορίζεται από την διαφορά πραγματικής και προβλεπόμενης τιμής, η θέση της κύρια μπάρας του δικτύων CNN και CNN-LSTM δηλώνει πως και τα δύο δίκτυα τείνουν να προβλέπουν τιμές παραγωγής υψηλότερες από την πραγματική, ενώ ισχύει το αντίθετο για τα δίκτυα LSTM και LSTM-CNN.




Σχήμα 5.8: Κατανομή σφαλμάτων μέσω της μεθόδου παραμένουσας τιμής για ωριαία πρόβλεψη αιολικής ενέργειας.


Το ιστόγραμμα συχνοτήτων σφάλματος είναι ιδιαίτερος χρήσιμο και στο στάδιο της εκπαίδευσης, καθώς παρουσιάζει σαφώς την συμπεριφορά των μοντέλων για διάφορες παραμετροποιήσεις τους. Όπως αναλύθηκε στο Κεφάλαιο 4, οι υπερπαραμέτροι του νευρωνικού δίκτυο δεν μπορούν να οριστούν εκ των προτέρων με ακρίβεια, παρά μόνο εμπειρικά μέσω δοκιμών στο συγκεκριμένο πρόβλημα. Το πλήθος των εποχών παίζει σημαντικό ρόλο στην προσαρμογή του δικτύου στα δεδομένα και στην ύπαρξη υπό- ή υπερπροσαρμογής. Αυξημένος αριθμός εποχών προκαλεί υπερπροσαρμογή του δικτύου. Δηλαδή, το δίκτυο μαθαίνει να προβλέπει άριστα τα δεδομένα εκπαίδευσης και αδυνατεί να επεκτείνει την πρόβλεψη στα δεδομένα αξιολόγησης. Για παράδειγμα, στο Σχήμα 5.13 παρουσιάζονται οι κατανομές των σφαλμάτων τριών LSTM δικτύων, ίδιας δομής, με διαφορετικές εποχές εκπαίδευσης το καθένα. Μέσω της αύξησης των εποχών του LSTM, φαίνεται η διασπορά των σφαλμάτων και η αύξηση της μέσης τιμής τους.




Σχήμα 5.9: Κατανομή σφαλμάτων (kW) μέσω δικτύου LSTM για ωριαία πρόβλεψη αιολικής ενέργειας.




Σχήμα 5.10: Κατανομή σφαλμάτων (kW) μέσω δικτύου CNN για ωριαία πρόβλεψη αιολικής ενέργειας.



Σχήμα 5.11: Κατανομή σφαλμάτων (kW) μέσω δικτύου CNN-LSTM για ωριαία πρόβλεψη αιολικής ενέργειας.



Σχήμα 5.12: Κατανομή σφαλμάτων (kW) μέσω δικτύου LSTM-CNN για ωριαία πρόβλεψη αιολικής ενέργειας.



Σχήμα 5.13: Ιστόγραμμα συχνότητας σφαλμάτων (kW) τριών τροποποιήσεων των εποχών εκπαίδευσης LSTM δικτύων για ωριαία πρόβλεψη αιολικής ενέργειας.

5.6.2 Αποτελέσματα πιθανοτικής πρόβλεψης

Όπως αναλύθηκε προηγουμένως, τα νευρωνικά δίκτυα που σχεδιάστηκαν παρέχουν την δυνατότητα πιθανοτικών προβλέψεων, μέσω δημιουργίας πιθανοτικών κατανομών που δίνουν το εύρος της προβλεπόμενης παραγωγής μαζί με την αντίστοιχη πιθανότητα της. Καθώς αυτό αποτελεί κεντρικό σημείο ερευνητικού ενδιαφέροντος, θα γίνει ξεχωριστή επιμέρους αξιολόγηση των πιθανοτικών αποτελεσμάτων των δικτύων. Για την σύγκριση των αποτελεσμάτων χρησιμοποιήθηκε η μέθοδος παραμένουσας τιμής για την δημιουργία των διαστημάτων πρόβλεψης, όπως αναλύθηκε στην Ενότητα 3.2.1. Ορίζοντας ως διάστημα εμπιστοσύνης $\alpha = 0.95$ και χρησιμοποιώντας ιστορικά δεδομένα μίας ημέρας πίσω για τον υπολογισμό της μεταβλητότητας, οι δείκτες απόδοσης της μεθόδου παραμένουσας τιμής και των νευρωνικών δικτύων παρουσιάζονται στον Πίνακα 5.4.

Πίνακας 5.4: Πιθανοτικά αποτελέσματα όλων των διαθέσιμων μοντέλων

	Persistence	CNN	LSTM	CNN-LSTM	LSTM-CNN
PICP(%)	79,1	97,0	98,5	99,3	96,0
PINAW(%)	49,1	9,7	16,3	19,3	7,2

Το μοντέλο Persistence παρουσιάζει ικανοποιητικά αποτελέσματα ως προς την πιθανότητα κάλυψης του διαστήματος πρόβλεψης (PICP) με σημαντικά αυξημένο και ασταθές εύρος πρόβλεψης (PINAW), γεγονός που συνάδει με την τρέχουσα βιβλιογραφία [43]. Στον πίνακα 5.5 παρουσιάζονται τα αποτελέσματα των 4 ειδών δικτύων που σχεδιάστηκαν στην παρούσα εργασία με ανάλυση ανά μήνα. Για την άμεση σύγκριση των διαστημάτων πρόβλεψης, τέθηκε σε όλα τα δίκτυα ποσοστό κάλυψης της δοθείσας κατανομής $\alpha = 0.95$, το οποίο θα αναλυθεί μετέπειτα. Με βάση τα αποτελέσματα, είναι αρχικά εμφανής ο συμβιβασμός που προκύπτει μεταξύ της επίτευξης υψηλού PICP και μειωμένου PINAW. Σε κάθε μοντέλο που αναπτύχθηκε, η αύξηση του PICP οδήγησε σε ταυτόχρονη μείωση του PINAW, δηλαδή έγινε αύξηση της αξιοπιστίας του μοντέλου με μείωση της αιχμηρότητας του, γεγονός το οποίο συνάδει άμεσα με την υπάρχουσα βιβλιογραφία [8, 24]. Παρόλα αυτά, είναι σημαντικό να αξιολογηθεί αν υπάρχει ή όχι γραμμική σύνδεση των δύο μεταβολών και σε ποιες περιπτώσεις μπορεί να γίνει αποδεκτός τέτοιος συμβιβασμός.

Με γνώμονα την αξιοπιστία των μοντέλων, και τα 4 δίκτυα παρέχουν αρκετά ακριβείς προβλέψεις με μέση ακρίβεια σε όλο το διάστημα πρόβλεψης άνω του 95% σε όλα. Ειδικό-

τερα, το μοντέλο CNN-LSTM προβλέπει επιτυχώς το διάστημα παραγωγής στο 99,3% των παρατηρήσεων, με χειρότερη απόδοση 98,1% τον 1/2019 και καλύτερη 99,7% τον 9/2019. Αυτό αντιπροσωπεύει αύξηση της απόδοσης κατά +25,6% σε σχέση με το Persistence. Αντίστοιχα, δεύτερη καλύτερη απόδοση είχε το CNN μοντέλο με επιτυχής πρόβλεψη 98,5%, χειρότερη απόδοση 97,1% τον 6/2019 και μέγιστη 99,4% τους 11/2018, 12/2018 και 6/2019. Τα δίκτυα LSTM και LSTM-CNN απέδωσαν χειρότερα ως προς την ακρίβεια, με PICP 97% και 96% αντίστοιχα, που αναλογούν σε αύξηση της ακρίβειας σε σχέση με το Persistence κατά +22.1% και +21,3% αντίστοιχα.

Αξιολογώντας τα αποτελέσματα των μοντέλων βάσει της *αιχμηρότητας* τους, το persistence εμφανίζει έντονες διακυμάνσεις στο εύρος των προβλέψεων του με PINAW = 49,1% για το σύνολο της πρόβλεψης. Συγκριτικά, το LSTM-CNN παρέχει PINAW = 7,2%, το οποίο είναι μικρότερο σε σχέση με τα υπόλοιπα δίκτυα. Αμέσως μεγαλύτερη εύρος έδωσε το δίκτυο CNN, με PINAW = 9,7%. Τα δίκτυα LSTM και CNN-LSTM απέδωσαν χειρότερα σε σχέση με τα άλλα δύο, με PINAW ίσο με 16,3% και 19,3% έκαστο.


Εμβαθύνοντας στην μεταβολή της *αξιοπιστίας* και της *αιχμηρότητας* κάθε μοντέλου, φαίνεται πως η αύξηση της μίας ενδέχεται να οδηγήσει σε δυσανάλογη μείωση της άλλης. Για το δίκτυο CNN, το οποίο έχει σχετική αύξηση της αξιοπιστίας κατά +1,04% συγκριτικά με το LSTM-CNN, η αιχμηρότητα του μειώνεται κατά -34,7%. Παρόμοια αποτελέσματα φαίνεται να έχει και το δίκτυο CNN-LSTM, όπου η αύξηση της αξιοπιστίας του κατά 3,4% σε σχέση με το LSTM-CNN, οδηγεί σε μείωση της αιχμηρότητας κατά -168,0%. Το συγκεκριμένο πρόβλημα είναι συχνό στην ανάπτυξη νευρωνικών δικτύων για πιθανοτική πρόβλεψη, καθώς υπάρχει περιορισμός των μοτίβων που μαθαίνει το δίκτυο είτε λόγω δομής του ή λόγω πεπερασμένων δεδομένων.

Επίσης, πραγματοποιήθηκε επιπλέον ανάλυση των αποτελεσμάτων σε εβδομαδιαία και ημερήσια βάση, για τον εντοπισμό χρονικών οριζόντων με σημαντικά μειωμένη ή αυξημένη απόδοση των μοντέλων. Η μηνιαία διακύμανση των πιθανοτικών δεικτών σφάλματος παρουσιάζεται στο Σχήμα 5.14. Συγκεκριμένα, για την εβδομάδα 10/1/2019-16/1/2019 παρατηρήθηκε σημαντική μείωση απόδοσης σε όλα τα μοντέλα, με ημέρα χειρότερης απόδοσης στις 15/1/2019. Η συγκεκριμένη ημέρα είχε έντονες διακυμάνσεις σε όλη την διάρκεια της, με παραγωγή σε όλο το φάσμα, όπως φαίνεται στα Σχήματα 5.15 και 5.16. Για το CNN δίκτυο, το PICP είναι 68.1%, σε σχέση με το 98,5% για ολόκληρο το διάστημα πρόβλεψης, και το Μέσο Απόλυτο Σφάλμα (MAE) είναι 106000 kW, ενώ για ολόκληρο το διάστημα




Σχήμα 5.14: Μηνιαία ανάλυση πιθανοτικής απόδοσης - PICP(%) και PINAW(%)


ήταν 2504 kW. Αντίστοιχα, το LSTM Δίκτυο για όλο το διάστημα είχε MAE 1992 kW με PICP 97%, ενώ στις 15/1/2019 είχε 93% PICP και MAE 19985 kW. Βέλτιστη απόδοση των δικτύων παρατηρήθηκε τον 10/2019, με τις αντίστοιχες τιμές στα Σχήματα 5.17, 5.18, 5.19 και 5.20. Η συγκεκριμένη περίοδος δεν εμφανίζει έντονες διακυμάνσεις στην παραγωγή, σε σχέση με άλλους μήνες. Επίσης, χαρακτηρίζεται από σχετικά μικρές τιμές παραγωγής, που δεν φτάνουν συχνά σε οριακές τιμές. Την συγκεκριμένη περίοδο, το μοντέλο CNN-LSTM παρουσίασε καλύτερη απόδοση, με $PICP = 99,6(+0,3\%)$ και $PINAW = 13,3(-34\%)$. Και τα τέσσερα μοντέλα παρείχαν σημαντικά μειωμένο εύρος διαστημάτων, δηλαδή αυξημένη αιχμηρότητα, σε σχέση με την συνολική απόδοσή τους.




Σχήμα 5.15: Πραγματική μέτρηση (kW) και προβλεπόμενη μέση τιμή CNN Δικτύου για το διάστημα 14/1/2019-16/1/2019.




Σχήμα 5.16: Πραγματική μέτρηση (kW) και προβλεπόμενη μέση τιμή LSTM Δικτύου για το διάστημα 14/1/2019-16/1/2019.




Σχήμα 5.17: Διαστήματα πρόβλεψης, μέση και πραγματική τιμή παραγωγής (kW) CNN δικτύου τον 10/2019



Σχήμα 5.18: Διαστήματα πρόβλεψης, μέση και πραγματική τιμή παραγωγής (kW) LSTM δικτύου τον 10/2019



Σχήμα 5.19: Διαστήματα πρόβλεψης, μέση και πραγματική τιμή παραγωγής (kW) CNN-LSTM δικτύου τον 10/2019



Σχήμα 5.20: Διαστήματα πρόβλεψης, μέση και πραγματική τιμή παραγωγής (kW) LSTM-CNN δικτύου τον 10/2019

Πίνακας 5.5: Μηνιαία ανάλυση πιθανοτικού σφάλματος ωριαίας πρόβλεψης νευρωνικών δικτύων - PICP(%) και PINAW(%).

		LSTM	CNN	CNN-LSTM	LSTM-CNN
PICP	ΣΥΝΟΛΟ ΠΕΡΙΟΔΟΥ	97,0	98,5	99,3	96,0
	11/2018	97,6	99,4	99,6	96,9
	12/2018	96,1	99,4	99,4	95,9
	1/2019	92,8	97,5	98,1	91,4
	2/2019	97,8	99,4	99,4	96,3
	3/2019	97,4	98,9	99,2	95,7
	4/2019	97,2	98,9	99,6	96,0
	5/2019	96,6	98,6	99,7	95,0
	6/2019	96,5	97,1	98,7	95,3
	7/2019	97,7	97,8	99,4	96,9
	8/2019	97,0	97,3	99,2	96,2
	9/2019	98,7	99,0	99,7	98,1
	10/2019	98,1	98,9	99,6	97,9
	11/2019	97,0	98,9	99,3	96,3
PINAW	ΣΥΝΟΛΟ ΠΕΡΙΟΔΟΥ	9,7	16,3	19,3	7,2
	11/2018	7,3	13,5	16,9	5,5
	12/2018	15,1	24,9	27,2	11,2
	1/2019	15,8	25,9	28,0	12,3
	2/2019	15,9	27,5	29,6	10,8
	3/2019	10,2	16,9	19,9	7,4
	4/2019	8,3	14,5	17,8	6,3
	5/2019	10,1	16,2	19,2	7,5
	6/2019	8,5	13,5	16,8	6,2
	7/2019	8,4	13,5	16,8	6,3
	8/2019	8,1	12,5	16,0	5,7
	9/2019	7,4	12,9	16,4	5,5
	10/2019	5,1	9,5	13,3	3,9
	11/2019	7,5	12,9	16,4	5,7

5.6.3 Τροποποίηση διαστήματος κατανομής

Σύμφωνα με την δομή των νευρωνικών δικτύων που σχεδιάστηκαν, η κατανομή που παρέχεται πρέπει να οριοθετηθεί για να ληφθούν τα σχετικά όρια πρόβλεψης. Όπως εξηγήθηκε και στην Ενότητα 5.2, η οριοθέτηση γίνεται μέσω ορισμού του ποσοστού α της κατανομής. Παρόλα αυτά, δεν υπάρχει συγκεκριμένος κανόνας για την επιλογή αυτού του εύρους, καθώς προκύπτει από τα συγκεκριμένα δεδομένα και τους στόχους του προβλήματος. Στην παρούσα ενότητα θα αναλυθεί η επίδραση της τροποποίησης αυτού του εύρους στους δείκτες που προαναφέρθηκαν.

Αναλυτικότερα, για το δίκτυο LSTM-CNN, παρουσιάζονται στο Πίνακα 5.6 τα PIRP και PINAW για ποσοστά κάλυψης 95%, 90% και 85%. Συγκρίνοντας τα αποτελέσματα για κάλυψη 85% και 95% βλέπουμε πως οι αυξήσεις που πλάτους των διαστημάτων δεν ανταποκρίνονται σε σημαντική βελτίωση της ακρίβειας. Με ποσοστό κάλυψης 95%, το μοντέλο παρείχε αποτελέσματα με ακρίβεια πρόβλεψης 96% και αιχμηρότητα 7,2%. Σε περίπτωση που ορίσουμε ποσοστό κάλυψης 85%, η ακρίβεια του μοντέλου μειώνεται στο 91,2%. Παρόλη την σχετική μείωση ακρίβειας κατά -5% (απόλυτη μείωση PIRP 4,8%), παρατηρείται σημαντική ποσοστιαία βελτίωση της αιχμηρότητας, από 7,2% για $\alpha = 0.95$, στο 5,3% για $\alpha = 0.85$, το οποίο αντιστοιχεί σε μεταβολή κατά -26,6%.

Πίνακας 5.6: Αποτελέσματα πιθανοτικής πρόβλεψης LSTM-CNN δικτύου για διάφορα ποσοστά κάλυψης της κατανομής - PICP(%) και PINAW(%).

		LSTM-CNN		
		$\alpha = 95\%$	$\alpha = 90\%$	$\alpha = 85\%$
PICP	ΣΥΝΟΛΟ ΠΕΡΙΟΔΟΥ	96,0	93,7	91,2
	11/2018	96,9	94,9	92,9
	12/2018	95,9	93,4	90,5
	1/2019	91,4	87,7	84,0
	2/2019	96,3	93,6	90,6
	3/2019	95,7	93,3	90,2
	4/2019	96,0	93,3	90,0
	5/2019	95,0	92,0	89,6
	6/2019	95,3	93,1	90,9
	7/2019	96,9	94,8	93,1
	8/2019	96,2	94,6	92,7
	9/2019	98,1	96,3	94,4
	10/2019	97,9	96,4	94,8
	11/2019	96,3	94,1	91,6
PINAW	ΣΥΝΟΛΟ ΠΕΡΙΟΔΟΥ	7,2	6,0	5,3
	11/2018	5,5	4,6	4,1
	12/2018	11,2	9,4	8,2
	1/2019	12,3	10,3	9,0
	2/2019	10,8	9,0	7,9
	3/2019	7,4	6,2	5,5
	4/2019	6,3	5,3	4,6
	5/2019	7,5	6,3	5,5
	6/2019	6,2	5,2	4,5
	7/2019	6,3	5,3	4,6
	8/2019	5,7	4,8	4,2
	9/2019	5,5	4,6	4,0
	10/2019	3,9	3,3	2,9
	11/2019	5,7	4,8	4,2

Κεφάλαιο 6

Συμπεράσματα

Σε παγκόσμιο επίπεδο, με κύριο γνώμονα την κλιματική κρίση, η προώθηση και βελτίωση των εναλλακτικών καυσίμων και των ανανεώσιμων πηγών ενέργειας είναι στο επίκεντρο της επιστημονικής και τεχνολογικής προόδου. Συνεπώς, η ολοένα και αυξανόμενη είσοδος ΑΠΕ στα δίκτυα παραγωγής ηλεκτρικής ενέργειας αποτελεί μονόδρομο. Παρότι οι ΑΠΕ παρέχουν την δυνατότητα για πιο βιώσιμη ηλεκτροπαραγωγή, η αστάθεια τους δεν συνάδει με τις ανάγκες και τις απαιτήσεις ενός σύγχρονου συστήματος ηλεκτρικής ενέργειας. Ένα σύγχρονο ΣΗΕ ωφείλει να παρέχει ηλεκτρική ενέργεια με σταθερότητα, ελάχιστο κόστος και ελάχιστες οικολογικές επιπτώσεις, διατηρώντας σταθερή τάση και συχνότητα. Η μεταβλητότητα των ΑΠΕ, και ειδικά της αιολικής ενέργειας, ενδέχεται να διαταράξει την ομαλή λειτουργία του δικτύου, μέσω αυξομειώσεων τάσης, αντίστροφης ροής ισχύος, παραμόρφωση συχνότητας και διακύμανση κόστους και ποσότητας παραγωγής. Τέτοιου είδους μεταβολές δυσχεραίνουν την διατήρηση σταθερού κόστους λειτουργίας και την οργάνωση και επέκταση των μονάδων. Γίνεται πλέον σαφές ότι το ζήτημα της οργάνωσης και πρόβλεψης αιολικής παραγωγής είναι άμεσα αναγκαίο να επιλυθεί, τόσο για την αποδοτικότερη χρήση των ήδη εγκατεστημένων μονάδων, όσο και για την προσθήκη νέων. Τα μοντέλα πρόβλεψης, ως εργαλεία για την αντιμετώπιση του εν λόγω ζητήματος, έχουν εφαρμογή σε διάφορα στάδια της ηλεκτροπαραγωγής. Αυτό γίνεται είτε μέσω μοντέλων μικρού ορίζοντα, για τον υπολογισμό της τιμής πώλησης, είτε μακροπρόθεσμων για διεξαγωγή μελετών σκοπιμότητας κ.α.. Στην παρούσα εργασία αναλύθηκε σε βάθος το ζήτημα της αστάθειας και της πρόβλεψης της αιολικής ενέργειας και τα σχετικά προβλήματα που πρέπει να επιλυθούν για την δημιουργία σωστών προβλέψεων. Ο άνεμος χαρακτηρίζεται από στοχαστικότητα τόσο στην ένταση, όσο και στην διεύθυνση του. Συνεπώς, η έγκυρη πρόβλεψη αυτών φέρει πολυπλοκό-

τητα. Λόγω της ραγδαίας ανάπτυξης της πληροφορικής και της τεχνολογίας των τελευταίων ετών, μπορούν να δημιουργηθούν σύγχρονα μοντέλα και να γίνονται ακριβέστερες καταγραφές συνόλου δεδομένων, για την επίλυση του προβλήματος.

6.1 Σύνοψη και συμπεράσματα

Με γνώμονα της δημιουργία έγκυρων και αξιόπιστων εργαλείων πρόβλεψης, αναπτύχθηκαν τέσσερα νευρωνικά δίκτυα για δημιουργία πιθανοτικών ωριαίων προβλέψεων αιολικής παραγωγής. Στόχος ήταν να αναλυθούν οι ικανότητες των συνελκτικών δικτύων και των δικτύων μακράς βραχυπρόθεσμης μνήμης στην πρόβλεψη. Αρχικά, εξετάστηκε η επιρροή των δεδομένων εισόδου στο δίκτυο. Έχοντας ως διαθέσιμα δεδομένα τις ιστορικές τιμές παραγωγής, ταχύτητας και κατεύθυνσης, συγκρίθηκαν οι αποδόσεις δικτύων σε δύο σενάρια. Πρώτον, δίνοντας μόνο ιστορικές τιμές, και δεύτερον, δίνοντας επιπλέον πληροφορία για την τρέχουσα κατάσταση του ανέμου σε μορφή πρόβλεψης. Σύμφωνα με τα δεδομένα, η απόδοση των δικτύων βελτιώθηκε σημαντικά με την αύξηση των δεδομένων εισόδου, τόσο σε σημεικές όσο και πιθανοτικές προβλέψεις. Επιπροσθέτως, σχεδιάστηκαν δύο ακόμα συνδυαστικά δίκτυα επιπέδων CNN και LSTM, για να ελεγχθεί κατά πόσο η αύξηση της πολυπλοκότητας και ο συνδυασμός διαφορετικών χαρακτηριστικών βελτιώνουν την απόδοση. Σύμφωνα με τα αποτελέσματα, παρατηρείται αύξηση της αξιοπιστίας των δικτύων με την εισαγωγή διαφορετικών επιπέδων στα δίκτυα. Παρόλα αυτά, η βελτίωση της αξιοπιστίας μείωσε την αιχμηρότητα των μοντέλων, δίνοντας μεγαλύτερα διαστήματα πρόβλεψης. Συνολικά, όλα τα δίκτυα απέδωσαν καλύτερα σε σχέση με την μέθοδο παραμένουσας τιμής, που τέθηκε ως σύγκριση.

6.2 Μελλοντικές επεκτάσεις

Ο τομέας της μηχανικής μάθησης και των νευρωνικών δικτύων βρίσκεται ακόμα υπό διαρκή πρόοδο, τόσο γενικά, όσο και ειδικά στο ζήτημα της αιολικής πρόβλεψης. Το αντικείμενο της παρούσας διπλωματικής εργασίας αναλύεται διαρκώς στην τρέχουσα βιβλιογραφία με ολοένα και καλύτερα αποτελέσματα. Ως και τούτου, κρίνεται αναγκαία η συνεχής ανάπτυξη νέων μοντέλων, για την σε βάθος κατανόηση του ζητήματος. Συγκεκριμένα, με βάση το παρόν πρόβλημα και τα δίκτυα που σχεδιάστηκαν, υπάρχουν αρκετές επιλογές επέκτα-

σης. Στο κομμάτι των δεδομένων εισόδου, ενδέχεται η χρήση επιπλέον μεταβλητών, όπως η θερμοκρασία αέρα, να βελτιώσει την απόδοση, καθώς τα νευρωνικά δίκτυα έχουν την ικανότητα μοντελοποίησης αρκετά περίπλοκων μοτίβων. Τέλος, η περαιτέρω εμβάθυνση στον τομέα του preprocessing, με χρήση μεθόδων όπως ο διακριτός μετασχηματισμός κυματιδίων ενδέχεται να αποδώσουν βελτιωμένα αποτελέσματα. Καταλήγοντας, οι επεκτάσεις στο τομέα της πρόβλεψης έχουν σημαντικές προοπτικές, σε διάφορες κατευθύνσεις, ώστε να δημιουργηθούν μοντέλα ικανά να αντεπεξέλθουν στις σύγχρονες ανάγκες παραγωγής αιολικής ισχύος.

Βιβλιογραφία

- [1] U. Focken M. Lange. *Physical Approach to Short-Term Wind Power Prediction*. Oldenburg: Springer, 2006.
- [2] S. Haykin. *Neural networks and learning machines*. New Jersey: Pearson Education, 3 edition, 2009.
- [3] A. Khosravi H. Quan, D. Srinivasan. Short-term load and wind power forecasting using neural network-based prediction intervals. In *IEEE Transactions on Neural Networks and Learning Systems*, volume 25, pages 303–315. 2014.
- [4] J. J. Copier S. Lorenczik. Electricity market report. Technical report, International Energy Association, Ιούλιος, 2022.
- [5] Wind energy in europe –2020 statistics and the outlook for 2021-2025. Technical report, WindEurope, 2021.
- [6] Wind energy and economic recovery in europe. Technical report, WindEurope, 2020.
- [7] Γ. Β. Γιαννακόπουλος και Ν. Α. Βοβός. *Εισαγωγή στα Συστήματα Ηλεκτρικής Ενέργειας*. Ζήτη, Αθήνα, 2 edition, 2008.
- [8] Ι. Κ. Bazionis και Ρ. Σ. Georgilakis. Review of deterministic and probabilistic wind power forecasting: Models, methods, and future research. *Electricity*, 2(1):13–47, Ιαν. 2021.
- [9] P. Pinson. Methods for the estimation of the uncertainty of wind power forecasts. Technical report, ANEMOS Project, 2007.
- [10] Levelized costs of new generation resources in the annual energy outlook 2022. Technical report, EIA, 2022.

- [11] S. S. Soman κ.α. A review of wind power and wind speed forecasting methods with different time horizons. *North American Power Symposium*, pages 1–8, 2010.
- [12] W. Chang κ.α. A literature review of wind forecasting methods. *Journal of Power and Energy Engineering*, pages 161–169, 2014.
- [13] Hans Auer Dominik Putz, Michael Gumhalter. A novel approach to multi-horizon wind power forecasting based on deep neural architecture. In *Renewable Energy*, volume 178, pages 494–505. 2021.
- [14] Z. Tian. A state-of-the-art review on wind power deterministic prediction. *Wind Engineering*, 45(5):1374–1392, 2021.
- [15] R. Hagedorn T. Palmer. Predictability of weather and climate. *Cambridge University Press*, pages 585–589, 2006.
- [16] X. Wang και J. Chen Y. Shen. Wind power forecasting using multi-objective evolutionary algorithms for wavelet neural network-optimized prediction intervals. *Applied Sciences*, 8(2):185, 2018.
- [17] A. Ficarella και M. Tarantino M. G. De Giorgi. Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods. *Energy*, 36(7):3968–3978, 2011.
- [18] T. Taskaya-Temizel και M. Casey. A comparative study of autoregressive neural network hybrids. *Neural Networks*, 18(5-6):781–9, 2005.
- [19] R. G. Kavasseri και K. Seetharaman. Day-ahead wind speed forecasting using f-arma models. *Renewable Energy*, 34(5), 2009.
- [20] G. C. Reinsel G. M. Ljung G. E. P. Box, G. M. Jenkins. *Time Series Analysis: Forecasting and Control*. Okland: Willey, 5 edition, 2015.
- [21] R. Castro P. Gomes. Wind speed and wind power forecasting using statistical models: Autoregressive moving average (arma) and artificial neural networks (ann). *International Journal of Sustainable Energy Development*, 1(2), 2012.
- [22] W. Rivera E. Cadenas. Short term wind speed forecasting in la venta, oaxaca, méxico, using artificial neural networks. *Renewable Energy*, 34(1):274–278, 2009.

- [23] W. Y. Chang. Wind energy conversion system power forecasting using radial basis function neural network. *Applied Mechanics and Materials*, 1:1067–1071, 2013.
- [24] J. Shi G. Li. On comparing three artificial neural networks for wind speed forecasting. *Applied Energy*, 87:2313–2320, 2010.
- [25] P. Pinson Z. Y. Dong και K. P. Wong C. Wan, z. Xu. Probabilistic forecasting of wind power generation using extreme learning machine. In *IEEE Trans. Power Syst.*, volume 29, pages 1033–1044. 2014.
- [26] W. Yuan-Kang. Probabilistic wind-power forecasting using weather ensemble models. In *IEEE TRANSACTIONS ON INDUSTRY APPLICATIONS*, volume 54, pages 5609–5620. 2018.
- [27] R. Chen Z. Zhou W. Xie, P. Zhang. A nonparametric bayesian framework for short-term wind power probabilistic forecast. In *IEEE TRANSACTIONS ON POWER SYSTEMS*, volume 34, pages 371–379. 2018.
- [28] J. B. Bremnes. Probabilistic wind power forecasts using local quantile regression. *Wind Energy*, 7:47–57, 2004.
- [29] M. Yang J. Yang Y. Yu, X. Han. Probabilistic prediction of regional wind power based on spatiotemporal quantile regression. In *EEE Transactions on Industry Applications*, 2020.
- [30] B. W. Silverman. *Density Estimation*. London: Chapman Hall/CRC, 1 edition, 1986.
- [31] L. Fugon και G. Kariniotakis J. Juban. Probabilistic short-term wind power forecasting based on kernel density estimators. In *European Wind Energy Conference and exhibition*, Milan, 2007.
- [32] D. Creighton A. F. Atiya A. Khosravi, S. Nahavandi. Lower upper bound estimation method for construction of neural network-based prediction intervals. In *IEEE Transactions of Neural Networks*, volume 22, pages 337–346. 2011.
- [33] D. Creighton A. Khosravi, S. Nahavandi. Prediction intervals for short-term wind farm power generation forecasts. In *IEEE Transactions on Sustainable Energy*, volume 4, pages 602–610. 2013.

- [34] Kumar S. Lydia M. A comprehensive review on wind turbine power curve modeling techniques. In *Renew. Sustain. Energy Rev.*, pages 452–460. 2014.
- [35] J.L. Rueda Torres E. Rakhshani M. van der Meijden V.N. Sewdien, R. Preece. Assessment of critical parameters for artificial neural networks based short-term wind generation forecasting. In *Renewable Energy*, volume 161, pages 878–892. 2020.
- [36] Dozat Timothy. Incorporating nesterov momentum into adam. 2016.
- [37] Keras documentation - adam optimizer. https://www.tensorflow.org/api_docs/python/tf/keras/optimizers/Adam. Ημερομηνία πρόσβασης: 13-06-2023.
- [38] A. Athaiya S. Sharma, S. Sharma. Activation functions in neural networks. In *International Journal of Engineering Applied Sciences and Technology*, volume 4, pages 310–316. 2020.
- [39] Charu C. Aggarwal. *Neural Networks and Deep Learning*. Springer Cham, 1 edition, 2018.
- [40] Lin Guan Yao Liu. Wind power short-term prediction based on lstm and discrete wavelet transform. *Applied Sciences*, 9(6):1108, 2019.
- [41] Z. Wenyu C. Yong, Z. Shuai. Multifactor spatio-temporal correlation model based on a combination of convolutional neural network and long short-term memory neural network for wind speed forecasting. In *Energy Conversion and Management*, volume 185, pages 783–799. 2019.
- [42] H. Yongzhang Q. Wu, G. Fei. Ultra-short-term multi-step wind power forecasting based on cnn-lstm. In *IET Renewable Power Generation*, volume 15, pages 1019–1029. 2021.
- [43] Jiayi M. Ultra-short-term probabilistic wind turbine power forecast based on empirical dynamic modeling. In *Transactions on Sustainable Energy*, volume 5, pages 1949–1958. 2019.