



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

**Πρόβλεψη δυναμικού ανανεώσιμων πηγών ενέργειας με τη
χρήση αλγορίθμων μηχανικής μάθησης**

Γεώργιος Γούσης

Μεταπτυχιακή Διπλωματική Εργασία

Επιβλέπων: Ιωάννης Παναπακίδης

Βόλος 2021



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

**Πρόβλεψη δυναμικού ανανεώσιμων πηγών ενέργειας με τη
χρήση αλγορίθμων μηχανικής μάθησης**

Γεώργιος Γούσης

Μεταπτυχιακή Διπλωματική Εργασία

Επιβλέπων: Ιωάννης Παναπακίδης

Βόλος 2021



UNIVERSITY OF THESSALY

SCHOOL OF ENGINEERING

DEPARTMENT OF ELECTRICAL AND COMPUTER ENGINEERING

**Forecasting of renewable energy resources potential
with the usage of machine learning algorithms**

MSc Thesis

Georgios Gousis

Advisor: Ioannis Panapakidis

Volos 2021

Εγκρίνεται από την Επιτροπή Εξέτασης:

Επιβλέπων/πους **Ιωάννης Παναπακίδης**
Επίκουρος Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών και
Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Μέλος **Δημήτριος Μπαργιώτας**
Αναπληρωτής Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Μέλος **Ελευθέριος Τσουκαλάς**
Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών και
Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Ημερομηνία έγκρισης: 25-02-2021

ΕΥΧΑΡΙΣΤΙΕΣ

Θα ήθελα να ευχαριστήσω τον επιβλέποντα Επίκουρο Καθηγητή κ. Ιωάννη Παναπακίδη για την καθοδήγηση και την συμβολή του στην ολοκλήρωση της διπλωματικής εργασίας. Στο ίδιο πλαίσιο θα ήθελα να ευχαριστήσω όλους τους διδάσκοντες του μεταπτυχιακού 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. 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/Η Δηλών/ούσα

ΓΟΥΣΗΣ ΓΕΩΡΓΙΟΣ

Ημερομηνία

25-02-2021

ΠΕΡΙΛΗΨΗ

Η οικονομική ανάπτυξη και η τεχνολογική πρόοδος βασίζονται κατά ένα μεγάλο ποσοστό στον ηλεκτρισμό. Η ραγδαία ανάπτυξη όμως οδηγεί σε υπερεκμετάλλευση πόρων και στο περιβαλλοντικό πρόβλημα. Μία λύση σε αυτό μπορούν να δώσουν καθαρές ανανεώσιμες πηγές ενέργειας. Η ζήτηση τεχνολογιών παραγωγής από ηλιακή και αιολική ενέργεια συνεχώς αυξάνει. Η εισχώρησή τους όμως εισάγει και προβλήματα στο δίκτυο που απαιτούν λύσεις. Δημιουργούν μικρότερη αξιοπιστία, σχετίζονται με την αστάθεια του δικτύου και μπορούν να αυξήσουν το κόστος λειτουργίας. Μία λύση για την αντιμετώπιση των ζητημάτων είναι η επιτυχής πρόβλεψη την παραγωγής ηλεκτρικής ισχύος από ΑΠΕ. Η πρόβλεψη διαχωρίζεται σε κατηγορίες ανάλογα με τον χρονικό ορίζοντα στο οποίο αναφέρεται και ανάλογα με τα εργαλεία που χρησιμοποιεί. Ένα από τα εργαλεία που μπορούν να χρησιμοποιηθούν, είναι η τεχνητή νοημοσύνη, που έχει αρκετά ελπιδοφόρα αποτελέσματα στην επίλυση του προβλήματος. Στην παρούσα εργασία δημιουργήθηκαν δύο μοντέλα πρόβλεψης. Ο ορίζοντας πρόβλεψης είναι εντός ώρας και ημέρας μπροστά όσον αφορά την ηλιακή ενέργεια και ενδοωριαίος για την αιολική. Το μοντέλο είναι υβριδικό και χρησιμοποιεί διακριτό μετασχηματισμό κυματιδίων για προεπεξεργασία και διαχείριση του θορύβου. Στη συνέχεια τροφοδοτείται ένα συνελκτικό νευρωνικό δίκτυο και εκπαιδεύεται ώστε να ακολουθήσει πρόβλεψη με τα δεδομένα ελέγχου. Ένα μοντέλο προς διερεύνηση δημιουργήθηκε, με σκοπό να αντιμετωπίσει την μεγάλη στοχαστικότητα του ανέμου, με τη μέθοδο του ολισθαίνοντος παραθύρου. Έπειτα εξάγονται τα αποτελέσματα τα οποία συγκρίνονται με κλασικές τεχνικές πρόβλεψης, μηχανικής και βαθιάς μάθησης. Τέλος εξάγονται τα συμπεράσματα και γίνονται προτάσεις για εξέλιξη των μοντέλων και περαιτέρω έρευνα.

ABSTRACT

Economic growth and technological progress are largely based on electricity. However, rapid growth leads to over-exploitation of resources and the environmental problem. One solution to this is to provide clean renewable energy sources. The demand for solar and wind production technologies is constantly increasing. However, their penetration also introduces problems in the network that require solutions. They create less reliability, are associated with network instability and can increase operating costs. One solution to address the issues is to successfully predict the production of electricity from RES. The forecast is divided into categories depending on the time horizon to which it refers and depending on the tools it uses. One of the tools that can be used is artificial intelligence, which has quite promising results in solving the problem. In the present work, two prediction models were created. The forecast horizon is intra-hour and day-ahead in terms of solar energy and intra-hour for wind. The model is hybrid and uses discrete wavelet transformation for preprocessing and noise management. A convolutional neural network is then fed and trained, to follow the prediction with the test dataset. In order to deal with the wind stochastic phenomena a model using sliding window is created. Then the extracted results are compared with classical techniques of forecasting such as machine and deep learning. Finally, the conclusions are drawn and suggestions are made for the development of the model and further research.

ΠΕΡΙΕΧΟΜΕΝΑ

ΠΕΡΙΛΗΨΗ	xiii
ABSTRACT	xv
ΛΙΣΤΑ ΣΧΗΜΑΤΩΝ	xix
ΛΙΣΤΑ ΠΙΝΑΚΩΝ	xx
ΚΕΦΑΛΑΙΟ 1	1
1. ΕΙΣΑΓΩΓΗ – ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΙΣΗ.....	1
1.1 Η σημασία της πρόβλεψης παραγωγής από ΑΠΕ στα σημερινά συστήματα ηλεκτρικής ενέργειας	Error! Bookmark not defined.
1.2 Ανασκόπηση της βιβλιογραφίας στην πρόβλεψη παραγωγής ηλιακής ενέργειας	2
1.2.1 Κύριοι παράγοντες που επηρεάζουν την πρόβλεψη	5
1.2.2 Χρονικός ορίζοντας πρόβλεψης	5
1.2.3 Ακρίβεια πρόβλεψης και χρονικός ορίζοντας.....	10
1.2.4 Κατηγοριοποίηση καιρού	11
1.2.5 Απόδοση του μοντέλου πρόβλεψης.....	12
1.2.6 Είσοδοι του μοντέλου πρόβλεψης	13
1.2.7 Κατηγοριοποίηση των τεχνικών πρόβλεψης για φ/β	20
1.2.8 Ανασκόπηση για την παρούσα εργασία	25
1.3 Ανασκόπηση της βιβλιογραφίας για στην πρόβλεψη παραγωγής από αιολική ενέργεια	25
1.3.1 Κατηγοριοποίηση πρόβλεψης αιολικής ισχύος.....	27
1.3.2 Παράγοντες σύγκρισης διαφορετικών μεθόδων.....	32
1.3.3 Βελτίωση της ακρίβειας πρόβλεψης	33
1.3.4 Συμπεράσματα για την αιολική ενέργεια	35
1.4 Σκοπός της διπλωματικής εργασίας	36
1.5 Μεθοδολογία της διπλωματικής εργασίας.....	37
1.6 Δομή της διπλωματικής εργασίας	38
ΚΕΦΑΛΑΙΟ 2	39
2. ΜΑΘΗΜΑΤΙΚΗ ΘΕΜΕΛΙΩΣΗ ΤΟΥ ΜΟΝΤΕΛΟΥ ΠΡΟΒΛΕΨΗΣ	39
2.1 Διαμόρφωση του προβλήματος της πρόβλεψης παραγωγής	39
2.2 Διακριτός μετασχηματισμός κυματιδίων-Discrete wavelet transformation (DWT)	40
2.3 Convolutional Neural Network	46

2.4	Adam Optimizer	49
2.5	Προτεινόμενα Μοντέλα	50
2.5.1	Μεταβλητές μοντέλου φ/β παραγωγής.....	51
2.5.2	Αλγόριθμος πρόβλεψης για την ηλεκτρική ισχύ προερχόμενη από την α/γ 52	
2.6	Λοιπά Μοντέλα πρόβλεψης	55
2.6.1	Long Short-Term Memory	55
2.6.2	Άλλα μοντέλα μηχανικής μάθησης.....	59
2.7	Αποτίμηση της πρόβλεψης	61
ΚΕΦΑΛΑΙΟ 3		62
3.	ΑΝΑΛΥΣΗ ΑΠΟΤΕΛΕΣΜΑΤΩΝ	62
3.1	Μελέτη Περίπτωσης	62
3.1.1	Ιστορική Συσχέτιση Παραγωγής Ηλεκτρικής Ισχύος.....	62
3.2	Αποτελέσματα πρόβλεψης για το φωτοβολταϊκό πρόβλημα	70
3.2.1	Πρόβλεψη με χρονικό ορίζοντα ημέρας μπροστά και φ/β 1.5 MW.....	70
3.2.2	Πρόβλεψη με χρονικό ενδοωριαίο χρονικό ορίζοντα για τα δύο φ/β.....	80
3.3	Αποτελέσματα πρόβλεψης για το αιολικό πρόβλημα WT/CNN.....	81
3.4	Μοντέλο πρόβλεψης προσαρμοζόμενου στην χρονοσειρά με τη μέθοδο του ολισθαίνοντος παραθύρου (Ο.Π.)	87
ΚΕΦΑΛΑΙΟ 4		91
4.	ΣΥΜΠΕΡΑΣΜΑΤΑ	91
ΒΙΒΛΙΟΓΡΑΦΙΑ		94

ΛΙΣΤΑ ΣΧΗΜΑΤΩΝ

Σχήμα 1.1 Κάθετη ηλιακή ακτινοβολία ανά τον κόσμο [1].....	3
Σχήμα 1.2 Ζήτηση τεχνολογιών αξιοποίησης ηλιακής ενέργειας [1]	4
Σχήμα 1.3 Έξοδος ισχύος φ/β και ισχύς ηλιακής ακτινοβολίας κατά την διάρκεια της ημέρας [1].	15
Σχήμα 1.4 Συσχέτιση εξόδου φ/β και ισχύος ηλιακής ακτινοβολίας [1]	15
Σχήμα 1.5 Συσχέτιση εξόδου φ/β και ατμοσφαιρικής θερμοκρασίας [1]	16
Σχήμα 1.6 Αναπαράσταση ενός τεχνητού νευρωνικού δικτύου [1]	22
Σχήμα 1.7 Αναπαράσταση ενός πολυεπίπεδου νευρωνικού δικτύου [1]	23
Σχήμα 1.8 Αναπαράσταση ενός recurrent νευρωνικού δικτύου [1].....	23
Σχήμα 2.1 Διαδικασία DWT.....	43
Σχήμα 2.2 Διαδικασία IDWT.....	45
Σχήμα 2.3 Αρχιτεκτονική CNN για πρόβλεψη φ/β.....	48
Σχήμα 2.4 Αρχιτεκτονική CNN για πρόβλεψη α/γ	49
Σχήμα 2.5 Αποδόμηση και ανακατασκευή σήματος των προτεινόμενων μοντέλων	51
Σχήμα 2.6 Διάγραμμα ροής για την φ/β και αιολική πρόβλεψη χωρίς ολισθαίνον παράθυρο	52
Σχήμα 2.7 Λογικό διάγραμμα ροής αλγορίθμου επίλυσης για την ανεμογεννήτρια.....	54
Σχήμα 2.8 Εκτύλιξη της RNN [107]	56
Σχήμα 2.9 Δομή της LSTM [107].....	57
Σχήμα 2.10 Αρχιτεκτονική του LSTM που χρησιμοποιήθηκε για σύγκριση	59
Σχήμα 2.11 Δίκτυο Regression Tree [111].....	60
Σχήμα 2.12 Elman νευρωνικό δίκτυο [112].....	60
Σχήμα 2.13 GMDH νευρωνικό δίκτυο [113].....	60
Σχήμα 3.1 Συσχέτιση για φ/β 1.5MW έως και δύο ημέρες υστέρηση	63
Σχήμα 3.2 Συσχέτιση για φ/β 2.45 MW έως και 2 ημέρες υστέρηση.....	63
Σχήμα 3.3 Συσχέτιση για α/γ.....	66
Σχήμα 3.4 Συνιστώσες κυματιδίων για φ/β 1.5MW και οριζοντα ημέρας μπροστά.....	69
Σχήμα 3.5 Συνιστώσες κυματιδίων για την α/γ	69
Σχήμα 3.6 Ιστόγραμμα σχετικών σφαλμάτων για το μοντέλο WT/CNN για προβλέψεις Φ/Β παραγωγής της επόμενης ημέρας για το Φ/Β σύστημα 1.5 MW.....	71
Σχήμα 3.7 Ιστόγραμμα σχετικών σφαλμάτων για το μοντέλο WT/LSTM για προβλέψεις Φ/Β παραγωγής της επόμενης ημέρας για το Φ/Β σύστημα 1.5 MW.....	72
Σχήμα 3.8 Ιστόγραμμα σχετικών σφαλμάτων για το μοντέλο WT/ENN για προβλέψεις Φ/Β παραγωγής της επόμενης ημέρας για το Φ/Β σύστημα 1.5 MW.....	72
Σχήμα 3.9 Ιστόγραμμα σχετικών σφαλμάτων για το μοντέλο WT/GMDH για προβλέψεις Φ/Β παραγωγής της επόμενης ημέρας για το Φ/Β σύστημα 1.5 MW.....	73
Σχήμα 3.10 Ιστόγραμμα σχετικών σφαλμάτων για το μοντέλο WT/RT για προβλέψεις Φ/Β παραγωγής της επόμενης ημέρας	73
Σχήμα 3.11 Συσχέτιση πραγματικής-προβλεπόμενης ισχύος για το μοντέλο WT/CNN.....	75
Σχήμα 3.12 Συσχέτιση πραγματικής-προβλεπόμενης ισχύος για το μοντέλο WT/LSTM	75
Σχήμα 3.13 Συσχέτιση πραγματικής-προβλεπόμενης ισχύος για το μοντέλο WT/ENN.....	76
Σχήμα 3.14 Συσχέτιση πραγματικής-προβλεπόμενης ισχύος για το μοντέλο WT/GMDH.....	76
Σχήμα 3.15 Συσχέτιση πραγματικής-προβλεπόμενης ισχύος για το μοντέλο WT/RT.....	77

Σχήμα 3.16 Προφίλ πραγματικής παραγωγής και προβλέψεων για την 10/07/2019	78
Σχήμα 3.17 Προφίλ πραγματικής παραγωγής και προβλέψεων για την 10/07/2019	78
Σχήμα 3.18 Προφίλ πραγματικής παραγωγής και προβλέψεων για την 27/04/2019	79
Σχήμα 3.19 Προφίλ πραγματικής παραγωγής και προβλέψεων για την 20/08/2019	79
Σχήμα 3.20 Ιστόγραμμα σφαλμάτων για το WT/CNN για α/γ	82
Σχήμα 3.21 Ιστόγραμμα σφαλμάτων για το WT/LSTM για α/γ	82
Σχήμα 3.22 Ιστόγραμμα σφαλμάτων για το WT/ENN για α/γ	83
Σχήμα 3.23 Ιστόγραμμα σφαλμάτων για το WT/GMDH για α/γ	83
Σχήμα 3.24 Ιστόγραμμα σφαλμάτων για το WT/RT για α/γ	84
Σχήμα 3.25 Πραγματική και προβλεπόμενη ισχύς για την 16/07/2019	85
Σχήμα 3.26 Πραγματική και προβλεπόμενη ισχύς για την 29/10/2019	85
Σχήμα 3.27 Πραγματική και προβλεπόμενη ισχύς για την 14/10/2019	86
Σχήμα 3.28 Πραγματική και προβλεπόμενη ισχύς για την 27/02/2019	86
Σχήμα 3.29 Συντελεστής συσχέτισης πραγματικής και προβλεπόμενης ισχύος για το προσαρμοζόμενο στα δεδομένα μοντέλο	87
Σχήμα 3.30 Πραγματική και προβλεπόμενη ισχύς για την 8/03/2019 και μοντέλο Ο.Π.	88
Σχήμα 3.31 Πραγματική και προβλεπόμενη ισχύς για την 10/04/2019 και μοντέλο Ο.Π.	89
Σχήμα 3.32 Πραγματική και προβλεπόμενη ισχύς για την 10/04/2019 και μοντέλο Ο.Π.	89
Σχήμα 3.33 Πραγματική και προβλεπόμενη ισχύς για την 10/04/2019 και μοντέλο Ο.Π.	90

ΛΙΣΤΑ ΠΙΝΑΚΩΝ

Πίνακας 1.1 Χρονικοί ορίζοντες πρόβλεψης για α/γ και Εφαρμογές	27
Πίνακας 3.1 Σύγκριση των μοντέλων για προβλέψεις Φ/Β παραγωγής της επόμενης ημέρας για το Φ/Β σύστημα 1.5 MW	70
Πίνακας 3.2 Σφάλματα για ενδοωριαίο ορίζοντα και φ/β μεγέθους 1.5 MW	80
Πίνακας 3.3 Σφάλματα για ενδοωριαίο ορίζοντα και φ/β μεγέθους 2.45 MW	80
Πίνακας 3.4 Σύγκριση των μοντέλων για προβλέψεις παραγωγής από Α/Γ της επόμενης ώρας για το σύστημα 4.25 MW	81
Πίνακας 3.5 Σύγκριση των μοντέλων για προβλέψεις παραγωγής από Α/Γ της επόμενης ώρας για το σύστημα 4.25 MW	88

ΚΕΦΑΛΑΙΟ 1

1. ΕΙΣΑΓΩΓΗ – ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΙΣΗ

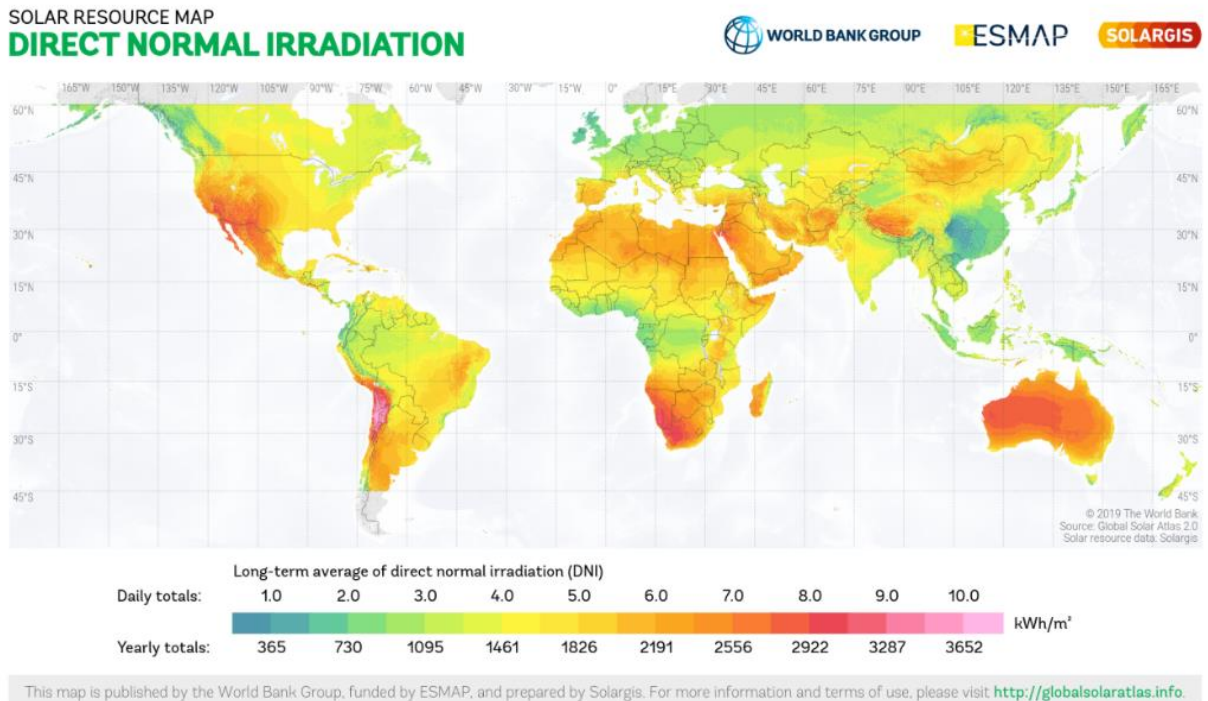
1.1 Η σημασία της πρόβλεψης παραγωγής από ΑΠΕ στα σημερινά συστήματα ηλεκτρικής ενέργειας

Ο ηλεκτρισμός είναι κρίσιμης σημασίας τόσο για την οικονομική ανάπτυξη όσο και για την τεχνολογική πρόοδο [1]- [2]. Είναι κύριας σημασίας για την γρήγορη αστικοποίηση και εκβιομηχάνιση που συμβαίνει. Συχνά ακόμα και η οικονομική ανάπτυξη μετράται ως προς την κατά κεφαλήν ισχύ μιας χώρας [3]. Αυτή η συνεχής αύξηση στην ζήτηση ενέργειας οδηγεί σε μεγαλύτερη ανάγκη για παραγωγή και διανομή ηλεκτρικής ενέργειας. Παγκοσμίως όμως, η παραγωγή ηλεκτρικής ενέργειας εξαρτάται από την κατανάλωση μη ανανεώσιμων καυσίμων, που προκαλούν περιβαλλοντική ρύπανση. Περίπου τα δύο τρίτα του παγκόσμιων εκπομπών διοξειδίου του άνθρακα προέρχεται από τέτοια καύσιμα τα οποία, εάν συνεχίσουν να συμμετέχουν σε τέτοιο βαθμό στην παραγωγή ενέργειας, αναπόφευκτα θα οδηγήσει σε σημαντική αύξηση της μέσης παγκόσμιας θερμοκρασίας και άλλων περιβαλλοντικών προβλημάτων και καταστροφών [4]. Αυτό προκύπτει και από το γεγονός ότι ήδη η αύξηση της μέσης θερμοκρασίας του πλανήτη σχετίζεται με ακραία καιρικά φαινόμενα όπως καταιγίδες, πλημμύρες, σφοδρές χιονοπτώσεις αλλά και ξηρασίες [5]. Χαρακτηριστικά οι μέση θερμοκρασία του πλανήτη την τελευταία πενταετία (2015-2019) αλλά και δεκαετία (2010-2019) είναι στις μέγιστες τιμές που έχει καταγραφεί ιστορικά. Παραδόξως, η τρομερή ανάγκη για μείωση των εκπομπών αερίων του θερμοκηπίου έχει αποτύχει να μειώσει την εξάρτηση από τα ορυκτά καύσιμα λόγω της οικονομίας τους. Η φωτεινή πλευρά είναι ότι η αξιοποίηση των ανανεώσιμων πηγών ενέργειας πρόσφατα επέφερε αλλαγές στο πεδίο της παραγωγής ενέργειας και καταδεικνύει το δυναμικό της καθαρής και απεριόριστης ενέργειας για το μέλλον. Επιπροσθέτως, οι πολιτικές που εφαρμόζονται από διεθνείς οργανισμούς και σημαντικούς παράγοντες της παγκόσμιας οικονομίας όσον αφορά τη φορολογία του άνθρακα έχουν ανοίξει το δρόμο για παραγωγή ηλεκτρικής ισχύος

από ανανεώσιμες πηγές. Ψηφίσματα όπως η αλλαγή του κλίματος των Ηνωμένων Εθνών (COP21) το 2015 και δηλώσεις κυβερνόντων από μεγάλες οικονομικές δυνάμεις όπως οι ΗΠΑ και η Κίνα σηματοδοτούν νέες πολιτικές οι οποίες υπόσχονται εφαρμογή των ανανεώσιμων πηγών ενέργειας [6]. Η Ευρωπαϊκή Ένωση έχει ακόμη μεγαλύτερες φιλοδοξίες με στόχο την μείωση κατά 80% των αερίων του θερμοκηπίου και πλήρη κάλυψη των ενεργειακών αναγκών των πολιτών, να προέρχεται από ανανεώσιμες πηγές μέχρι το 2050 [7]. Ακόμη τα παρόντα τεχνολογικά πλεονεκτήματα στην παραγωγή ηλεκτρικής ισχύος από αιολική ενέργεια αλλά και ηλιακή, έχουν καταστήσει τις ΑΠΕ ανταγωνιστικές ως προς τα ορυκτά καύσιμα [8]- [9]. Η εισχώρηση των ΑΠΕ στο δίκτυο ισχύος όμως δημιουργεί προβλήματα. Αυτά μπορεί να είναι προβλήματα ευστάθειας, αξιοπιστίας και αυξάνουν το κόστος λειτουργίας και σχεδιασμού. Τα προβλήματα αξιοπιστίας μπορούν να αντιμετωπιστούν, με αποθήκευση της παραγόμενης ενέργειας και χρήση της σε μελλοντικό χρόνο, ενώ μία μέθοδος για την καλύτερη ευστάθεια του δικτύου είναι η ακριβής πρόβλεψη του φορτίου, προερχόμενου από ΑΠΕ, με σκοπό τον καλύτερο προγραμματισμό στο σύνολο του δικτύου ισχύος.

1.2 Ανασκόπηση της βιβλιογραφίας στην πρόβλεψη παραγωγής ηλιακής ενέργειας

Η ηλιακή ενέργεια είναι η ακτινοβολούμενη ενέργεια του ήλιου, ο οποίος παράγει τεράστιες ποσότητες ηλεκτρομαγνητικής ενέργειας με θερμοπυρηνική σύντηξη υδρογόνου. Η μέση ένταση της ηλιακής ακτινοβολίας στην επιφάνεια της γης είναι 1367 W/m^2 και η συνολική παγκόσμια απορρόφηση της ηλιακής ενέργειας είναι περίπου $1,8 \times 10^{11} \text{ MW}$ [10]. Αυτή η τεράστια ποσότητα ενέργειας είναι αρκετή για να καλύψει όλες τις απαιτήσεις ισχύος σε παγκόσμια κλίμακα [4]. Το Σχήμα 1.1 απεικονίζει την ένταση της ηλιακής ενέργειας στον κόσμο. Χώρες που βρίσκονται στις γεωγραφικές ζώνες άνω των 45° B ή σε γεωγραφικά πλάτη κάτω των 45° έχουν τεράστια ευκαιρία για την αξιοποίηση της ηλιακής ενέργειας. Περιοχές στη Μέση Ανατολή, την έρημο Mojave (ΗΠΑ), την έρημο Atacama της Χιλής, την έρημο Σαχάρα, την έρημο Καλαχάρι (Αφρική) και την βορειοδυτική περιοχή της Αυστραλίας είναι κατάλληλες για φωτοβολταϊκά σε μεγάλης κλίμακας εγκαταστάσεις. Όμως και η Ελλάδα έχει ένα αρκετά μεγάλο δυναμικό προς αξιοποίηση.

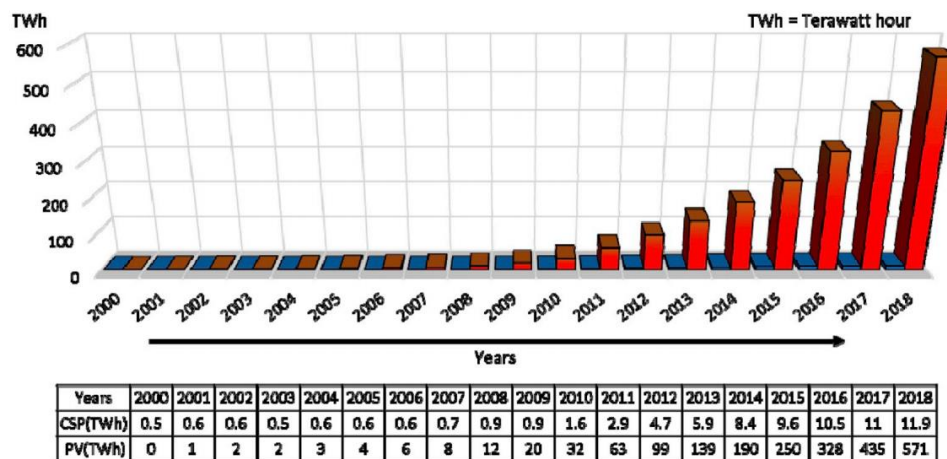


Σχήμα 1.1 Κάθετη ηλιακή ακτινοβολία ανά τον κόσμο [1]

Οι τρέχοντες ηλιακοί σταθμοί για παραγωγή ηλεκτρικής ισχύος είναι δύο τύπων: ηλιακά θερμικά συστήματα και ηλιακά φωτοβολταϊκά πάρκα. Η ηλιακή θερμική τεχνολογία συγκεντρώνει ηλιακό φως, αυξάνοντας έτσι τη θερμοκρασία των συλλεκτών θερμότητας που παράγουν ατμό. Ο ατμός χρησιμοποιείται σε ατμοστρόβιλους για παραγωγή ηλεκτρικής ενέργειας μεγάλης κλίμακας. Έτσι, χώρες όπως η Ισπανία και οι ΗΠΑ εφαρμόζουν την παραπάνω τεχνολογία συγκέντρωσης ηλιακής ενέργειας (concentrated solar power) (CSP) για παραγωγή ηλεκτρικής ενέργειας [11].

Ωστόσο, για να είναι αποτελεσματικό και συμφέρον απαιτούνται μεγάλες εγκαταστάσεις. Σε αντίθεση, τα φωτοβολταϊκά χρησιμοποιούν τα προσπίπτοντα φωτόνια από φως του ήλιου για να διεγείρουν ελεύθερα ηλεκτρόνια σε ενσωματωμένους ημιαγωγούς, προκαλώντας μια φόρτιση με αποτέλεσμα να παράγουν ηλεκτρισμό. Αυτά τα πάνελ είναι λειτουργικά σε διαφορετικές κλίμακες μεγέθους και χρησιμοποιούνται συχνά σε στέγες ή ανοιχτούς χώρους, ενσωματωμένα σε κτίρια ή ακόμα και σε οχήματα, αλλά και διατεταγμένα σε τεράστιες συστοιχίες σε σταθμούς ηλιακής ενέργειας. Κατά τις τελευταίες δεκαετίες, τα φωτοβολταϊκά έχουν εγκατασταθεί ευρέως και η ζήτησή τους έχει αυξηθεί ως

άμεση συνέπεια της μαζικής ζήτησής τους [12]- [13]. Το Σχήμα 1.2 συγκρίνει την παγκόσμια ζήτηση για φωτοβολταϊκή τεχνολογία και τεχνολογία συγκέντρωσης ηλιακής ισχύος. Φαίνεται χαρακτηριστικά η αύξηση της ζήτησης για φωτοβολταϊκά από το 2009 και μετά ενώ οι εγκαταστάσεις συγκεντρωτικής τεχνολογίας αν και αυξάνονται παραμένουν σε χαμηλά επίπεδα σε σχέση με τα φωτοβολταϊκά.



Σχήμα 1.2 Ζήτηση τεχνολογιών αξιοποίησης ηλιακής ενέργειας [1]

Η αξιοσημείωτη μακροχρόνια ανάπτυξη της φωτοβολταϊκής ισχύος οφείλεται κυρίως στη μείωση της τιμής των φωτοβολταϊκών συστημάτων, την αύξηση της απόδοσής τους, την βελτίωση της λειτουργικότητας της εγκατάστασης, το χαμηλό κόστος συντήρησης και λειτουργίας, την μακρά διάρκεια ζωής, την μείωση των εκπομπών CO₂ και φιλικότητα προς το περιβάλλον [14]. Οι φωτοβολταϊκοί σταθμοί είναι τώρα ανταγωνιστικοί με την τεχνολογία παραγωγής από ορυκτά καύσιμα σε πολλές χώρες ανά τον κόσμο. Είναι αποτελεσματική η χρήση τους, σε αυτόνομες ή συνδεδεμένες στο δίκτυο λειτουργίες, αλλά η απόδοση ποικίλλει σημαντικά λόγω των διακυμάνσεων του προσβεβλημένου ηλιακού δυναμικού λόγω περιβαλλοντικών συνθηκών και γεωγραφικής θέσης. Ο καιρός μιας συγκεκριμένης γεωγραφικής τοποθεσίας ποικίλλει σε χρονικά διαστήματα που κυμαίνονται από λεπτά έως ώρες ή και πολλές ημέρες, καθώς και σε όλη την χρονιά ή και δεκαετίες. Η φωτοβολταϊκή έξοδος εξαρτάται επίσης από την κίνηση του ήλιου κατά την διάρκεια της ημέρας, κλιμακώνεται το πρωί, φτάνοντας στη μέγιστη παραγωγή στα μέσα της ημέρας και πέφτει το απόγευμα. Έτσι, η έξοδος ηλεκτρικής ισχύος είναι δυναμική και εξαρτάται από την τοποθεσία και το κλίμα.

Η ένταση της ηλιακής ακτινοβολίας μιας περιοχής ποικίλει και εξαρτάται από το γεωγραφικό πλάτος, την εποχή, τις ατμοσφαιρικές συνθήκες, την ποιότητα του αέρα και την ατμοσφαιρική ρύπανση. Έτσι, η ποικιλομορφία του καιρού οδηγεί την παραγωγή ηλεκτρικής ισχύος από φωτοβολταϊκά να είναι αβέβαιη. Αυτή η αβεβαιότητα οδηγεί σε προβλήματα ευστάθειας του δικτύου όπως η απότομη αύξηση της τάσης, αντίστροφη ροή ισχύος, διακυμάνσεις στην αρμονική, παραμόρφωση συχνότητας σε κυματομορφές ρεύματος και τάσης κ.λπ. [14]. Η αβέβαιη έξοδος επηρεάζει σημαντικά την αξιοπιστία, τη σταθερότητα και τον προγραμματισμό της λειτουργίας του συστήματος ισχύος και της οικονομικής αποστολής. Η αξιόπιστη πρόβλεψη παραγωγής φωτοβολταϊκών θα μειώσει σημαντικά αυτήν την αβεβαιότητα, θα ενισχύσει τη σταθερότητα και θα βελτιώσει την οικονομική βιωσιμότητα. Ως εκ τούτου, η ακριβής πρόβλεψη παραγωγής ηλεκτρικής ισχύος από φωτοβολταϊκά είναι μια κρίσιμη έρευνα και αποτελεί ένα παράγοντα κλειδί στο πεδίο ανάπτυξης των ΑΠΕ [15]- [16]- [17].

1.2.1 Κύριοι παράγοντες που επηρεάζουν την πρόβλεψη

Ποικίλοι παράγοντες επηρεάζουν την πρόβλεψη ηλεκτρικής ισχύος προερχόμενης από φωτοβολταϊκά με αποτέλεσμα η διαδικασία να θεωρείται πρόκληση. Συσχέτιση των αναλύσεων, υπολογισμός της αβεβαιότητας και περαιτέρω ανάλυση πρέπει να πραγματοποιηθεί ώστε να υπάρξουν πιο ακριβή αποτελέσματα. Στη συνέχεια παρουσιάζονται οι παράγοντες που επηρεάζουν την ακρίβεια της πρόβλεψης.

1.2.2 Χρονικός ορίζοντας πρόβλεψης

Η μελλοντική χρονική περίοδος για την πρόβλεψη εξόδου ή η χρονική διάρκεια μεταξύ πραγματικού και ισχύοντος χρόνου πρόβλεψης είναι ο ορίζοντας πρόβλεψης [13]. Μερικοί ερευνητές προτιμούν τρεις κατηγορίες του ορίζοντα πρόβλεψης: βραχυπρόθεσμα, μεσοπρόθεσμα και μακροπρόθεσμα, όπως στις αναφορές [18]- [19]. Οι υπόλοιποι έχουν προσθέσει μια «τέταρτη» κατηγορία [20] με βάση τις απαιτήσεις του διαδικασίας λήψης αποφάσεων για έξυπνα ή μικροδίκτυα [14], που ονομάζεται συνήθως «πολύ βραχυπρόθεσμος ή εξαιρετικά βραχυπρόθεσμος ορίζοντας πρόβλεψης». Ωστόσο, μέχρι τώρα δεν υπάρχει καθολικά συμφωνημένο κριτήριο ταξινόμησης [14]- [21]- [22].

1.2.2.1 Πολύ βραχυπρόθεσμος ή εξαιρετικά βραχυπρόθεσμος ορίζοντας πρόβλεψης

Πολύ βραχυπρόθεσμη πρόβλεψη χρησιμοποιείται σε σύστημα ισχύος και έξυπνα δίκτυα με περίοδο πρόβλεψης από δευτερόλεπτα μέχρι λιγότερο από 30 λεπτά [23]. Άλλοι θεωρούν το 1 λεπτό έως 1 ή αρκετές ώρες ή ακόμη και μέχρι την ημερήσια πρόβλεψη σε αυτήν την κατηγορία. Τέτοιες προβλέψεις είναι εξαιρετικά επωφελείς για την εμπορία ηλεκτρικής ενέργειας ή την τιμολόγηση, τις διαδικασίες εξομάλυνσης ισχύος, παρακολούθηση της αποστολής ηλεκτρικού ρεύματος σε πραγματικό χρόνο και ελέγχου αποθήκευσης φωτοβολταϊκών [13].

1.2.2.2 Βραχυπρόθεσμος ορίζοντας πρόβλεψης

Η πρόβλεψη σε βραχυπρόθεσμο επίπεδο είναι δημοφιλής στην αγορά ηλεκτρικής ενέργειας, όπου οι αποφάσεις περιλαμβάνουν οικονομική αποστολή φορτίου και λειτουργία συστήματος ισχύος. Είναι επίσης χρήσιμος, για τον έλεγχο ολοκληρωμένων συστημάτων διαχείρισης ενέργειας από ΑΠΕ. Γενικά, ο χρονικός ορίζοντας κυμαίνεται μεταξύ 30 και 360 λεπτών [24]. Ωστόσο, ορισμένοι θεωρούν μία έως αρκετές ώρες, μία μέρα ή έως και επτά ημέρες ως βραχυπρόθεσμο ορίζοντα πρόβλεψης [13]. Για παράδειγμα Αναφ. [25], πρότεινε ότι πρέπει να προβλεφθούν μοτίβα ηλεκτρικού φορτίου 2 ημέρες μπροστά για αποτελεσματικό προγραμματισμό σταθμών παραγωγής ενέργειας και για προγραμματισμό συναλλαγών.

1.2.2.3 Μεσοπρόθεσμος ορίζοντας πρόβλεψης

Η μεσοπρόθεσμη πρόβλεψη εκτείνεται σε όρια 6-24 ώρες [23]. Αν και, ορισμένοι θεωρούν μια μέρα, μία εβδομάδα και έως και ένα μήνα μπροστά πρόβλεψη σε αυτή την κατηγορία. Είναι απαραίτητη για τον προγραμματισμό συντήρησης συμβατικών ή ολοκληρωμένων ηλιακά συστημάτων ισχύος που αποτελούνται από μετασχηματιστές υψηλών προδιαγραφών και διαφορετικούς τύπους ηλεκτρομηχανικών μηχανημάτων [13].

1.2.2.4 Μακροπρόθεσμος ορίζοντας πρόβλεψης

Οι μακροπρόθεσμες προβλέψεις προβλέπουν σενάρια για περισσότερες από 24 ώρες μπροστά [24]. Ωστόσο, ορισμένοι έχουν κατηγοριοποιήσει περιόδους από ένα μήνα

έως ένα έτος ως μακροπρόθεσμες προβλέψεις [13]. Ένας τέτοιος ορίζοντας προβλέψεων είναι κατάλληλος για μεγάλο χρονικό διάστημα σε μακροπρόθεσμη παραγωγή ενέργειας, μετάδοση, διανομή και κατανομή ηλιακής ενέργειας [26], καθώς και για τη συνεκτίμηση των εποχιακών τάσεων. Ωστόσο, αυτά τα μοντέλα έχουν μειωμένη ακρίβεια λόγω των διακυμάνσεων του καιρού. Δεν μπορεί να προβλεφθεί μια ή λίγες μέρες χρησιμοποιώντας τόσο μεγάλους ορίζοντες λόγω της στοχαστικότητας των καιρικών φαινομένων.

Οι διαφορετικοί χρονικοί ορίζοντες προσθέτουν πολυπλοκότητα. Έτσι, μια εναλλακτική λύση είναι χρησιμοποιώντας βραχυπρόθεσμες μεθόδους πρόβλεψης σε εκτεταμένους ορίζοντες. Αν και, αυτό μπορεί να υποβαθμίσει σοβαρά την ακρίβεια πρόβλεψης [27]. Ωστόσο, οι ερευνητές [28]- [29]- [30] έχουν αναπτυχθεί μεσοπρόθεσμα και μακροπρόθεσμα μοντέλα για μηνιαίο σύστημα ισχύος όσον αφορά τον προγραμματισμό, την τιμολόγηση ηλεκτρικής ενέργειας και πρόβλεψη φορτίου. Τα προβλήματα με τις προβλέψεις όπως συζητήθηκαν παραπάνω έχουν προκαλέσει πολλούς ερευνητές να αναπτύξουν μια προσέγγιση ταξινόμησης ορίζοντα πρόβλεψης ειδικά για φωτοβολταϊκά: εντός ωρών, εντός ημέρας και ημέρας μπροστά. Αυτές οι κατηγορίες καλύπτονται συχνά με τις βραχυπρόθεσμες, μεσοπρόθεσμες και μακροπρόθεσμες κατηγορίες όπως περιεγράφηκε προηγουμένως.

1.2.2.5 Εντός ώρας πρόβλεψη (Intra-hour)

Περιλαμβάνει ορίζοντες πρόβλεψης από δευτερόλεπτα έως μια ώρα, έτσι επικαλύπτεται με πολύ βραχυπρόθεσμα και βραχυπρόθεσμα μοντέλα πρόβλεψης [31]. Οι προβλέψεις εντός ωρών βοηθούν στη διασφάλιση του δικτύου σε ποιότητα και σταθερότητα, καθώς και να πραγματοποιηθεί ακριβής προγραμματισμός των αποθεμάτων και να προβλεφθεί η απόκριση στην ζήτηση. Νησιδοποιημένα δίκτυα και δίκτυα χαμηλότερης ισχύος, όπου υπάρχουν υψηλές ηλιακές διεισδύσεις, βασίζονται σε τέτοιες προβλέψεις. Χρησιμοποιείται στον προγραμματισμό λειτουργίας σε συστήματα διανομής για τη μείωση του κόστους λειτουργίας σε μετασχηματιστές και στη διαμόρφωση των τιμών για ηλεκτρική ενέργεια στην αγορά σε επίπεδα μικρότερα της ώρας. Παρ' όλα αυτά, οι περισσότερες κατανεμημένες

φωτοβολταϊκές εγκαταστάσεις γενικά δεν επηρεάζονται από πολύ βραχυπρόθεσμη μεταβλητότητα στην παραγωγή ενέργειας [32].

1.2.2.6 Εντός ημέρας πρόβλεψη

Αυτός ο ορίζοντας πρόβλεψης εκτείνεται 1-6 ώρες και σχετίζεται με σύντομο και μεσοπρόθεσμες κατηγορίες. Βρίσκει χρήση στον έλεγχο ηλεκτρικής ενέργειας συγκεκριμένης ζώνης φορτία και εμπορία ηλεκτρικής ενέργειας εκτός του τυπικού δικτύου [33].

Ενώ κάποιες μελέτες [34]- [35] χρησιμοποίησαν αριθμητική πρόβλεψη καιρού (numerical weather prediction) (NWP) για τις προβλέψεις εντός της ώρας, είναι ένα κοινό εργαλείο και για εντός της ημέρας προβλέψεις καθώς ενσωματώνει μελλοντικές ατμοσφαιρικές συνθήκες στο πρόβλημα πρόβλεψης ισχύος από φωτοβολταϊκά με αυξημένη ακρίβεια. Αυτό συμβαίνει επειδή, η NWP είναι αποτελεσματική για πρόβλεψη σε ορίζοντες άνω των 4 ωρών.

Οι Almonacid, et al. [36] ανέπτυξε ένα μοντέλο που εκμεταλλεύεται τα τεχνητά νευρωνικά δίκτυα (artificial neural network) (ANN). Το μοντέλο τους προέβλεψε με ακρίβεια 1 ώρα μπροστά φωτοβολταϊκή έξοδο βασιζόμενο στην παγκόσμια οριζόντια ακτινοβολία (global horizontal irradiation) (GHI) και θερμοκρασία κυψέλης φ/β ως είσοδο. Οι είσοδοι προήλθαν από δύο μη γραμμικά μοντέλα που προέβλεπαν GHI και ατμοσφαιρική θερμοκρασία από την τρέχουσα και την ιστορική μέτρηση. Στη συνέχεια, λήφθηκε η θερμοκρασία των κυττάρων του φ/β και η θερμοκρασία. Τα δεδομένα χρησιμοποιούνται σε ένα μοντέλο ANN για τη λήψη προβλέψεων εξόδου ισχύος φ/β με κανονικοποιημένο μέσο τετραγωνικό σφάλμα (normal route mean square error) (nRMSE) 3,38%.

Ένα άλλο εντός ημέρας μοντέλο πρόβλεψης με βάση το ANN χρησιμοποίησε την αποδόμηση με κυματίδια στην ισχύ εξόδου σε συνδυασμό με GHI και προβλέψεις θερμοκρασίας βελτιστοποιημένες [37]. Πρόβλεψε με ακρίβεια 1, 3 και 6 ώρες μπροστά με εκτίμηση αβεβαιότητας μέσω bootstrap μεθόδου.

Οι Zhang, et al. [38] συνδύασαν εντός της ημέρας και της ημέρας μπροστά ορίζοντα πρόβλεψης. Ανέλυσαν τέσσερα σενάρια με βάση γεωγραφική συγκέντρωση και

τοποθεσία, λαμβάνοντας καλές προβλέψεις με nRMSE κυμαίνεται από 2 έως 17% για ένα ενιαίο και ένα μεγάλο σύνολο από φ/β συστήματα (64 και 495 GW).

1.2.2.7 Πρόβλεψη ημέρας μπροστά

Οι προβλέψεις που καλύπτουν 6-48 ώρες περιλαμβάνονται σε αυτήν την κατηγορία και σχετίζονται με μεσοπρόθεσμους και μακροπρόθεσμους ορίζοντες. Τέτοια μοντέλα χρησιμοποιούνται σε βοηθητικά προγράμματα σχεδιασμού και δέσμευσης μονάδας παραγωγής. Οι Chen et al. [39] πρότειναν ένα μοντέλο αυτο-οργανωμένου χάρτη (self-organized map) (SOM) για πρόγνωση ημέρας. Το μοντέλο τους ταξινόμησε τους τύπους καιρού (ηλιόλουστος, συννεφιασμένος και βροχερός) σύμφωνα με μετεωρολογικές μεταβλητές (ηλιακή ακτινοβολία, σύνολο και χαμηλά ποσά νέφους), και αξιοποιήθηκε το ANN-RBFN για πρόβλεψη με σφάλμα (mean absolute percentage error) MAPE 9,45%, 9,88% και 38,12% για ηλιόλουστες, συννεφιασμένες και βροχερές μέρες, αντίστοιχα.

Συχνά, οι προβλέψεις ημέρας χρησιμοποιούν εξόδους αριθμητικών δεδομένων πρόβλεψης που σχετίζονται με τις μετεωρολογικές συνθήκες του καιρού (NWP). Lu, et al. [40] αξιολόγησαν μοντέλα που χρησιμοποιούσαν τη μέρα και χρησιμοποιούσαν μηχανική εκμάθηση και NWP σε συνδυασμό σε: Βόρεια Αμερική Mesoscale Μοντέλο (NAM), Rapid Refresh (RAP) και High-Resolution Rapid Refresh (HRRR) μεθόδους. Τα αποτελέσματά τους επιβεβαίωσαν ότι το αναμεμιγμένο μοντέλο ήταν καλύτερο από μεμονωμένα μοντέλα με 30% χαμηλότερο μέσο απόλυτο σφάλμα (mean absolute error) (MAE), αποδίδοντάς το στην ακύρωση των συστηματικών σφαλμάτων προκατάληψης. [38] Κατέληξε στο συμπέρασμα ότι η συνολική προσέγγιση ήταν η καλύτερη για πρόβλεψη σε ωριαίο επίπεδο σε σχέση με το ημέρας μπροστά. Ένα άλλο σημαντικό εύρημα ήταν ότι η διαφορά στην ακρίβεια πρόβλεψης ισχύος σε φ/β για διαφορετικούς ορίζοντες (ώρα και μέρα) αυξήθηκαν με την περιοχή κατανεμημένων συστημάτων.

Υπάρχουν και περιορισμένες έρευνες στην βιβλιογραφία που σχετίζουν την πρόβλεψη ημέρας μπροστά σε χρονικούς ορίζοντες πέραν των δύο ημερών όπως [41].

1.2.3 Ακρίβεια πρόβλεψης και χρονικός ορίζοντας

Πολλοί έχουν μελετήσει τους ορίζοντες πρόβλεψης και παρατηρείται ότι με τη διατήρηση σταθερού μοντέλου και άλλων παραμέτρων, η ακρίβεια ποικίλλει ανάλογα με την αλλαγή στο χρονικό διάστημα [13]. Lonij, et al. [34] ανέπτυξαν μοντέλο χρονικού ορίζοντα 15-90 λεπτών και κατέληξαν στο συμπέρασμα ότι η ακρίβεια του μοντέλου ποικίλλει ανάλογα με το χρόνο, διατηρώντας όλους τους άλλους παράγοντες σταθερούς. Ομοίως [42], διαπίστωσε ότι το σφάλμα πρόβλεψης αυξήθηκε από 3,2% έως 15,5% για τους ορίζοντες πρόβλεψης που κυμαίνονται από 20 έως 180 s για το ίδιο σύνολο δεδομένων. Κατά συνέπεια, οι ερευνητές αναπτύσσουν ένα σύστημα που μπορεί να χειριστεί βραχυπρόθεσμες χρονικές προβλέψεις ισχύος από φ/β.

Άλλοι έχουν αξιολογήσει διαφορετικά μοντέλα υβριδικών προβλέψεων για ηλιακή ακτινοβολία με διαφορετικούς ορίζοντες πρόβλεψης. Ορίζοντες που έχουν μελετηθεί είναι από 5 έως 30 λεπτά σε βήματα 5 λεπτών και από 1 έως 6 ώρες. Διαπιστώθηκε ότι ανεξάρτητα από τον τύπο του μοντέλου, οι τιμές nRMSE αυξήθηκαν με τη διάρκεια του ορίζοντα πρόβλεψης. Επιπλέον, συμπεραίνεται ότι συντομότερες χρονικές κλίμακες των δεδομένων μάθησης σε σύγκριση με εκείνη των δεδομένων δοκιμής δεν αύξησε την ακρίβεια των προβλέψεων. Αυτό σημαίνει ότι η αύξηση των στατιστικών πληροφοριών με τη χρήση μικρότερων χρονικών κλιμάκων δεν ενίσχυσε την ακρίβεια. Μάλλον θα μπορούσε να περιπλέξει τη φάση της εκμάθησης του μοντέλου για μεγαλύτερους χρονικούς ορίζοντες [43].

Ένας άλλος παράγοντας που επηρεάζει την παραγωγή ισχύος είναι η νεφωκάλυψη. Αυτό γιατί παίζει καθοριστικό ρόλο στα ποσά της προσπίπτουσας ηλιακής ακτινοβολίας. Οι μελέτες που αφορούν εξαιρετικά μικρά χρονικά διαστήματα πρέπει να εμπεριέχουν δεδομένα καιρού και επεξεργασίας τους για να επιτύχουν ακρίβεια στην πρόβλεψη [44]- [45].

Από τα παραπάνω συμπεραίνεται ότι το χρονικό περιθώριο πρόβλεψης επηρεάζει την ακρίβεια οποιουδήποτε μοντέλου πρόβλεψης. Η ακρίβεια μειώνεται και επηρεάζεται σημαντικά μετά από ένα χρονικό διάστημα 24-48 ώρες. Αυτό συμβαίνει επειδή η κάλυψη και η διασπορά σύννεφων, που σχετίζεται έντονα με την ηλιακή

ακτινοβολία, δεν μπορεί να προβλεφθεί με σημαντική ακρίβεια για εκτεταμένες χρονικές περιόδους λόγω της στοχαστικής φύσης του. Έτσι, η τρέχουσα ανασκόπηση επικεντρώθηκε στις προσπάθειες των σύγχρονων ερευνητών που ενδιαφέρονται για την ακρίβεια των μοντέλων, που είναι πολύ καλύτερα για συντομότερους χρονικούς ορίζοντες, έως και μια μέρα. Αυτός είναι και ο λόγος για τον οποίο υπάρχουν περισσότερα έργα που διερευνούν βραχυπρόθεσμους έως μεσοπρόθεσμους ορίζοντες πρόβλεψης. Οι λιγότερες μελέτες σχετίζονται με μακροπρόθεσμους ορίζοντες πρόβλεψης. Τα μοντέλα μακροπρόθεσμου ορίζοντα πρόβλεψης ήταν λιγότερο ακριβή. Η νεφωκάλυψη είναι δυναμική και μπορεί να προβλεφθεί μόνο για σύντομες χρονικές προθεσμίες με περιορισμένο βαθμό ακρίβειας. Ωστόσο, πρέπει να αναφερθεί ότι έχουν χρησιμοποιηθεί μακροπρόθεσμα μοντέλα στην πρόβλεψη εποχιακών παραλλαγών και των επιπτώσεών τους στα φωτοβολταϊκά. δηλ. για προγραμματισμό φωτοβολταϊκών εγκαταστάσεων.

1.2.4 Κατηγοριοποίηση καιρού

Η έξοδος ισχύος συσχετίζεται περισσότερο με την ηλιακή φασματική ακτινοβολία η οποία εξαρτάται από μετεωρολογικούς παράγοντες: κατανομή αεροζόλ, ταχύτητα και κατεύθυνση ανέμου, υγρασία και κάλυψη σύννεφων. Η αλλαγή της κατάστασης του καιρού επηρεάζει την ακρίβεια της πρόβλεψης. Το μοντέλο πρέπει να ενσωματώνει τις προβλέψεις με την ταξινόμηση καιρού για βέλτιστα αποτελέσματα. Πράγματι, η έρευνα δείχνει ότι η ταξινόμηση του καιρού είναι απαραίτητο βήμα επεξεργασίας, ειδικά για βραχυπρόθεσμα μοντέλα [44]- [46].

Ωστόσο, τα μοντέλα που βασίζονται στην ταξινόμηση καιρού αντιμετωπίζουν δυσκολίες σχετικά με την ανεπάρκεια συνόλων δεδομένων εκπαίδευσης. Στην Αναφ. [47] οι συγγραφείς επαναταξινόμησαν 33 μετεωρολογικές κατηγορίες καιρού σε 10 καιρικές ομάδες. Αντιθέτως, οι περισσότερες μελέτες έχουν κατηγοριοποιήσει δεδομένα καιρού σε λιγότερους από τέσσερις γενικούς τύπους [44]- [47]. Wang, et al. [47] έκρινε ότι το ξεχωριστό μοντέλο για κάθε κατηγορία καιρού αυξάνει την ακρίβεια. Για την μελέτη, χρησιμοποίησαν γενετικό δίκτυο αντιπαραθέσεων (generative adversarial network) (GAN) για να αυξήσουν τα σύνολα δεδομένων εκπαίδευσης που χρησιμοποιούνται για κάθε τύπο καιρού, ειδικά για ακραία

φαινόμενα, ώστε να εκπαιδεύσουν το συνελκτικό νευρικό δίκτυο (convolutional neural network) (CNN). Έτσι, τόσο πραγματικά όσο και τεχνητά δεδομένα ηλιακής ακτινοβολίας χρησιμοποιήθηκαν. Οι συγγραφείς ισχυρίστηκαν ότι το μοντέλο που βασίζεται στο GAN – CNN, ήταν πιο ακριβές από καθιερωμένες προσεγγίσεις. Οι καιρικές συνθήκες συσχετίζονται έντονα με την έξοδο φ/β [47], απαιτώντας τη συμπερίληψη των καιρικών καταστάσεων στα μοντέλα πρόβλεψης ισχύος [47]- [48]- [49]. Πολλές ερευνητικές μελέτες [44]- [47] κατέληξαν στο συμπέρασμα ότι η ταξινόμηση του καιρού είναι ένα αποτελεσματικό βήμα προεπεξεργασίας για βελτίωση της πρόβλεψης βραχυπρόθεσμα, ειδικά για πρόβλεψη ημέρα. Οι έρευνες δεν έχουν διερευνήσει πλήρως τη διαδικασία καθιέρωσης ενός ακριβούς και συνεπούς μοντέλου ταξινόμησης καιρού. Οι περισσότεροι το θεωρούν πλευρικό μέρος της διαδικασίας. Σε αντίθεση [47], υποστήριξε ότι η ταξινόμηση του καιρού θα πρέπει να χρησιμοποιηθεί ως σημείο αναφοράς για την επιλογή της καταλληλότερης στρατηγικής πρόβλεψης για μια δεδομένη περιοχή και κλιματικές συνθήκες. Επιπλέον, έδειξαν ότι μεμονωμένα μοντέλα πρόβλεψης (χωρίς ταξινόμηση καιρού) επηρεάστηκαν σημαντικά από τα ιστορικά δεδομένα των προηγούμενων ημερών. Όσο καλύτερη η πρόβλεψη του καιρού τόσο καλύτερη και η πρόβλεψη της ισχύος των φ/β αναφέρουν.

1.2.5 Απόδοση του μοντέλου πρόβλεψης

Η εκτίμηση απόδοσης είναι απαραίτητη για την αξιολόγηση της ακρίβειας των προβλέψεων ενός μοντέλου. Τα κοινά εργαλεία περιλαμβάνουν: Μέσο απόλυτο σφάλμα (MAE), σφάλμα μέσου απόλυτου ποσοστού (MAPE) και σφάλμα ρίζας μέσου τετραγώνου (RMSE) αλλά και το μέσο κανονικοποιημένο σφάλμα εύρους (mean absolute range normalized error) (MARNE). Το MAE εκτιμά τη μέση σημασία του σφάλματος σε ένα σύνολο δεδομένων προβλέψεων με μέσο όρο τις διαφορές μεταξύ πραγματικών παρατηρήσεων και προβλεπόμενων αποτελεσμάτων ολόκληρου του δείγματος δοκιμής, δίνοντας σε όλες τις μεμονωμένες διαφορές ίσο βάρος. Ομοίως, εκτιμά το RMSE η μέση τιμή του σφάλματος που χρησιμοποιεί την τετραγωνική ρίζα του μέσου όρου του τετραγωνικής διαφορές μεταξύ των προβλεπόμενων τιμών και των πραγματικών παρατηρήσεων. Επομένως, είναι πιο στιβαρό στην αντιμετώπιση μεγάλων αποκλίσεων που είναι ιδιαίτερα ανεπιθύμητες, δίνοντας στον ερευνητή τη

δυνατότητα αναγνώρισης και εξάλειψης των ακραίων τιμών. Επίσης, το κανονικοποιημένο RMSE (nRMSE) χρησιμοποιείται σε μεγάλο βαθμό σε σύνολα δεδομένων για την αξιολόγηση των συνολικών αποκλίσεων. Οι μετρήσεις, ωστόσο, μπορούν να κυμαίνονται από μηδέν έως άπειρο [50]- [51]. Σε αντίθεση, το MAPE είναι μια τυπική τεχνική πρόβλεψης που μετρά την ακρίβεια των προβλέψεων και δικαιολογεί την ποικιλομορφία πρόβλεψης για πραγματικά σύνολα δεδομένων. Ομοίως, για μεγάλα σύνολα δεδομένων, το κανονικοποιημένο nMAPE χρησιμοποιείται για αξιολόγηση πρόβλεψης.

Ορισμένοι ερευνητές [52], ωστόσο, έχουν κρίνει ότι η χρήση μετρήσεων στατιστικών σφαλμάτων για την αξιολόγηση απόδοσης του μοντέλου δεν είναι επαρκής. Πρότειναν περισσότερες αξιολογήσεις προσανατολισμένες στην εφαρμογή, δηλαδή υπολογισμό της βέλτιστης ακρίβειας μιας συγκεκριμένης πρόβλεψης με βάση τα οικονομικά του συστήματος ενέργειας και σημαντικές πτυχές σχεδιασμού. Οι τομείς περιλαμβάνουν: οικονομική αποστολή, βέλτιστο μέγεθος αποθήκευσης ενέργειας, αναδυόμενες πολιτικές αγοράς ενέργειας σε τοπικό επίπεδο, αλλά και διεθνή επίπεδα, μεγιστοποίηση κερδών για τους ενδιαφερόμενους στην αγορά ενέργειας και βέλτιστος καθορισμός μεγέθους αποθεμάτων.

Ανεξάρτητα από τη μέτρηση απόδοσης που χρησιμοποιείται, ο στόχος του ερευνητή πρέπει να είναι η αντικειμενική αξιολόγηση μιας συγκεκριμένης πρόβλεψης, έτσι ώστε οι επαγγελματίες να είναι σε θέση να λάβουν την καλύτερη απόφαση όσον αφορά τον σχεδιασμό, την εγκατάσταση και χρήση φωτοβολταϊκών για εφαρμογές δικτύου.

1.2.6 Είσοδοι του μοντέλου πρόβλεψης

Οι είσοδοι στα μοντέλα πρόβλεψης έχουν άμεση επίδραση στην ακρίβεια και είναι βασικός παράγοντας για τον καθορισμό της απόδοσης του μοντέλου. Γενικά, η ακατάλληλη επιλογή εισόδων μπορεί να προκαλέσει σφάλματα πρόβλεψης που αυξάνουν το χρόνο, το κόστος και υπολογιστική πολυπλοκότητα. Έτσι, χαμηλό ποσοστό ακρίβειας θα μπορούσε να εμφανιστεί σε πολύπλοκα μοντέλα [14]. Οι είσοδοι για φ/β συστήματα είναι κυρίως μετεωρολογικές παράμετροι: ηλιακή ακτινοβολία, ατμοσφαιρική θερμοκρασία, θερμοκρασία μονάδας, ταχύτητα ανέμου


και υγρασία , βαρομετρική πίεση και aerosol , αλλά και την κλιματική κατάσταση και τη γεωγραφική θέση. Ως εκ τούτου, ο συσχετισμός μεταξύ της φωτοβολταϊκής εξόδου και των μετεωρολογικών εισόδων ποικίλλει και μπορεί να έχει θετική ή αρνητική επίδραση και ισχυρή ή αδύναμη.

1.2.6.1 Ηλιακή ακτινοβολία

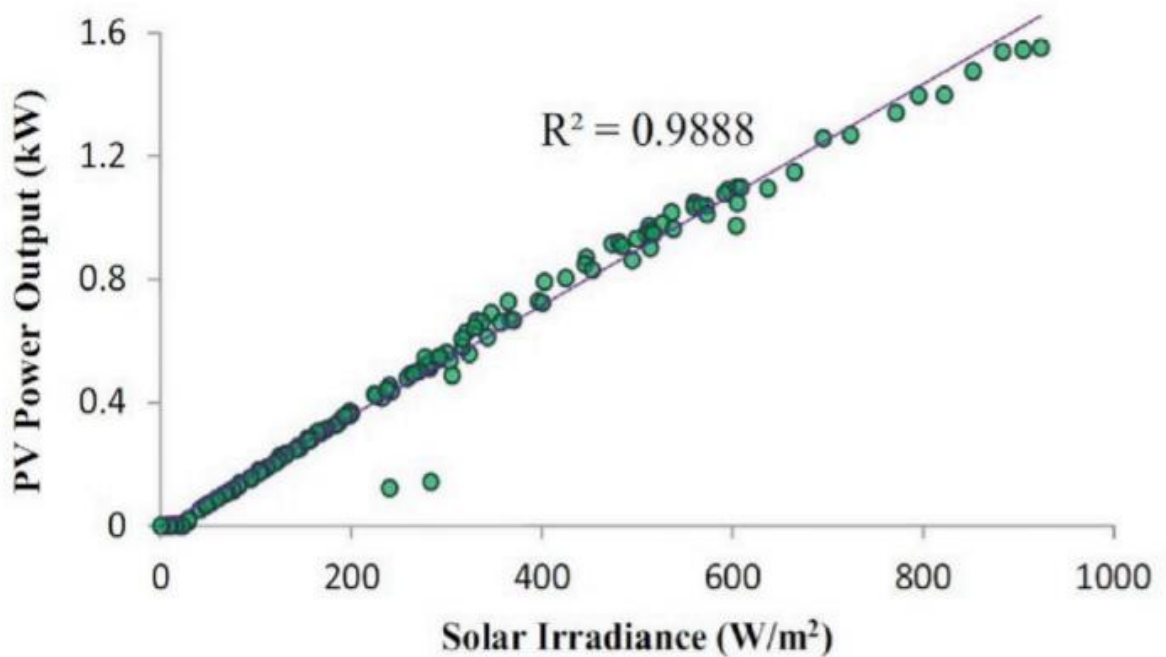
Η ηλιακή ακτινοβολία είναι η ακτινοβολούμενη ενέργεια από τον Ήλιο που εκπέμπεται στο μορφή ηλεκτρομαγνητικής ακτινοβολίας. Είναι άμεσα ανάλογη με την ποσότητα ηλιακής ενέργειας που μπορεί να έχει συλλέξει και έχει την ισχυρότερη συσχέτιση με την έξοδο ισχύος. De Giorgi, et al. [53] πρότεινε ένα μοντέλο πρόβλεψης τεχνητού νευρικού δικτύου (ANN) για την ανάλυση των συσχετίσεων των εισόδων με την απόδοση του μοντέλου. Τα σφάλματα πρόβλεψης ήταν (nRMSE) 12,57%, 12,60% και 10,91% για διανύσματα εισόδου του ιστορικού φ/β έξοδος, ηλιακή ακτινοβολία και θερμοκρασία μονάδας, αντίστοιχα. Επομένως μελέτη συσχέτισης μεταξύ μετεωρολογικών παραμέτρων και έξοδος φ/β είναι απαραίτητη για τον σχεδιασμό μοντέλων πρόβλεψης. Το Σχήμα 1.3 αντιπροσωπεύει το σχέδιο ηλιακής ακτινοβολίας και φωτοβολταϊκής εξόδου για μια συγκεκριμένη ημέρα. Το πείραμα πραγματοποιήθηκε στη στέγη ενός θεσμικού κτηρίου του Πανεπιστημίου της Μαλαισίας, Κουάλα Λουμπούρ [68]. Η φωτοβολταϊκή ισχύς ποικίλλει από 7 π.μ. έως 7 μ.μ. και το μέγεθος ακολούθησε την τάση της ηλιακής ακτινοβολίας. Καθώς η μέρα προχωρούσε, η έξοδος ισχύος αυξήθηκε και κορυφώθηκε κατά τη διάρκεια της μέσης ημέρας, τη στιγμή που είναι η ηλιακή ακτινοβολία πιο έντονη.

Το Σχήμα 1.4 δείχνει μια θετική συσχέτιση μεταξύ της εξόδου Φ / Β ισχύος και ηλιακή ακτινοβολία για το ίδιο πείραμα. Ο συντελεστής συσχέτισης R² ήταν 0,988, δείχνοντας ότι η ηλιακή ακτινοβολία είναι η πιο σημαντική είσοδος για την πρόβλεψη.

Έτσι είναι θεμιτό η ηλιακή ακτινοβολία να συμπεριλαμβάνεται σαν μεταβλητή στα μοντέλα πρόβλεψης παραγωγής ισχύος από φ/β και πολλές φορές συμπεριλαμβάνεται και η μετεωρολογική πρόβλεψη του μεγέθους της ηλιακής ακτινοβολίας.



Σχήμα 1.3 Έξοδος ισχύος φ/β και ισχύς ηλιακής ακτινοβολίας κατά την διάρκεια της ημέρας [1].




Σχήμα 1.4 Συσχέτιση εξόδου φ/β και ισχύς ηλιακής ακτινοβολίας [1]

1.2.6.2 Θερμοκρασία

Η θερμοκρασία είναι μια φυσική ποσότητα που μετρά την ένταση της θερμότητας που είναι διαθέσιμη σε μια ουσία ή αντικείμενο ή περιβάλλον. Αυτή η είσοδος ή παράμετρος είναι πολύ πιθανό να είναι ένας συντελεστής παραγωγής φωτοβολταϊκής ενέργειας. Ορισμένες ερευνητικές μελέτες έδειξαν ότι, υπάρχει συσχέτιση μεταξύ θερμοκρασίας περιβάλλοντος και ισχύος εξόδου φ/β.

Το Σχήμα 1.5 αντιπροσωπεύει τη συσχέτιση μεταξύ της ατμοσφαιρικής θερμοκρασίας και φ/β εξόδου για το ίδιο ερευνητικό έργο. Ο συντελεστής συσχέτισης R^2 είναι λιγότερο σημαντικός στα 0,3776. Οι ερευνητές διαπίστωσαν επίσης ότι δεν υπήρχε συσχέτιση μεταξύ ατμοσφαιρικής θερμοκρασίας και φωτοβολταϊκής εξόδου κατά τη διάρκεια του απογεύματος για προφανείς λόγους.



Σχήμα 1.5 Συσχέτιση εξόδου φ/β και ατμοσφαιρικής θερμοκρασίας [1]

1.2.6.3 Νεφωκάλυψη

Η νεφωκάλυψη είναι ένας από τους πιο σημαντικούς παράγοντες που καθορίζουν την ένταση ηλιακής ακτινοβολίας στην επίγεια επιφάνεια. Επιπλέον, το κλάσμα της ηλιακής ενέργειας που διέρχεται από τα σύννεφα δεν είναι σταθερό και εξαρτάται

από τον τύπο και την ποσότητα των σχηματισμών νέφους [54]. Κίνηση νεφών, γέννηση, σκεδασμός και αποσύνθεση, προκαλούν διακυμάνσεις στην ένταση του ήλιου επηρεάζοντας έτσι την έξοδο ισχύος του φ/β. Οι περισσότεροι ερευνητές έχουν χρησιμοποιήσει δορυφορικές εικόνες για ανάλυση νέφωσης [55]- [56]- [57]- [58] που δεν έχουν ικανοποιητική ακρίβεια λόγω χαμηλών χωρικών και χρονικών αναλύσεων, ειδικά όταν εφαρμόζεται σε εξαιρετικά βραχυπρόθεσμες προβλέψεις [59]. Αυτό έχει ωθήσει τη χρήση τεχνικών επίγειας απεικόνισης ουρανού.

1.2.6.4 Ταχύτητα ανέμου και θερμοκρασία φωτοβολταϊκού κυττάρου

Η ταχύτητα του ανέμου είναι μια κρίσιμη είσοδος στα μοντέλα πρόβλεψης που αφορούν φ/β, αλλά λόγω της στοχαστικής φύσης του, εισάγει σημαντικές αβεβαιότητες [60]. Ο ρόλος είναι στην απαγωγή θερμότητας και στη μείωση της θερμοκρασίας των φωτοβολταϊκών κυττάρων. Γενικά, η απόδοση των φωτοβολταϊκών εξαρτάται από τη θερμοκρασία της μονάδας, η οποία αυξάνεται κατά τη λειτουργία λόγω αλλαγών στη θερμοκρασία περιβάλλοντος ή λόγω της ακτινοβολίας που απορροφάται. Επομένως, τόσο η θερμοκρασία του ανέμου όσο και η θερμοκρασία των κυψελών είναι σημαντικές και συνδέονται.

1.2.6.5 Επεξεργασία δεδομένων εισόδου

Η ποιότητα των δεδομένων εισαγωγής είναι ζωτικής σημασίας για ακριβείς και αξιόπιστες προβλέψεις. Πολλά ερευνητικά έργα έχουν χρησιμοποιήσει ιστορικά δεδομένα χρονοσειρών της φ/β εξόδου καθώς και μετεωρολογικές πληροφορίες από σταθμούς παραγωγής και τις γεωγραφικές τους τοποθεσίες για σκοπούς μοντελοποίησης. Ωστόσο, αυτά τα σύνολα δεδομένων έχουν συχνά διαλείποντα στατικά στοιχεία ή στοιχεία λανθασμένα που προκαλούνται από καιρικές ή εποχιακές διακυμάνσεις, διακυμάνσεις της ζήτησης ηλεκτρικής ενέργειας και αστοχίες του συστήματος ισχύος. Πρόκειται για ακραίες τιμές που δεν ακολουθούν κάποια τάση, επηρεάζονται από τυχαία γεγονότα και επηρεάζουν σημαντικά την πρόβλεψη. Επιπλέον, τα δεδομένα μπορεί μερικές φορές να είναι κατεστραμμένα ή να λείπουν λόγω ελαττωματικών αισθητήρων ή εσφαλμένων καταγραφών. Επομένως, είναι επιτακτική ανάγκη να προεπεξεργαστούν παραμορφωμένα δεδομένα εισόδου χρησιμοποιώντας αποδόμηση, παρεμβολή ή εποχικές προσαρμογές [61] (δηλαδή

καθαρισμός δεδομένων και αλλαγή δομής). Για να επιτευχθεί αυτό, αναφέρονται πολλές τεχνικές στην υπάρχουσα βιβλιογραφία όπως ο μετασχηματισμός κυματιδίων (wavelet transformation) (WT), χρόνο trend free time, εμπειρική αποδόμηση empirical method decomposition, SOM, κανονικοποίηση και singular spectrum analysis [13], καθένα από τα οποία έχει τα δικά του μοναδικά πλεονεκτήματα και μειονεκτήματα. Ο Bacher, et al. [62] και Kemmoku, et al. [63] ανέφεραν ότι για την πρόβλεψη ηλιακής ενέργειας, χρησιμοποιήθηκε τεχνική χρονοσειρών σχετικά με πληροφορίες καθαρού ουρανού για προεπεξεργασία δεδομένων εισόδου σε πολλά ερευνητικά έργα. Οι Sfetsos και Coonick [64] ωστόσο διαφωνούν και κρίνουν ότι είναι τυχαία στη συμπεριφορά και πολύ ευαίσθητη στις καιρικές αλλαγές. Έτσι, αποδίδει χαμηλό ποσοστό εκμάθησης των δεδομένων εισόδου, που οδηγεί σε υψηλά σφάλματα πρόβλεψης. Άλλες μελέτες έδειξαν ότι η πληροφορία της ηλιακής ακτινοβολίας ήταν πιο σημαντική και αποτελεσματική στην έξοδο φ/β για την πρόβλεψη σε σύγκριση με τις χρονοσειρές δεδομένων καθαρού ουρανού. Ο Reikard [65] χρησιμοποίησε στατιστικό εργαλείο για την εξάλειψη της εποχιακής τάσης από δεδομένα ηλιακής ακτινοβολίας. Η μελέτη τους έδειξε τροποποιημένο ποσοστό μάθησης με βελτιωμένη ακρίβεια πρόβλεψης για το ανεπτυγμένο μοντέλο. Ομοίως, ο Baig, et al. [66] και ο Karlanis [67] χρησιμοποίησαν μια τεχνική τάσης για το σύνολο δεδομένων ηλιακής ακτινοβολίας, καθώς είναι πολύ περίπλοκο στην ακρίβεια να προσδιοριστεί η τάση της ημερήσιας ηλιακής ακτινοβολίας λόγω των καθημερινών καιρικών συνθηκών. Στις Αναφορές [68] ο Boland βρήκε χαμηλό σφάλμα πρόβλεψης για περιοδικό μοτίβο συνόλου δεδομένων ηλιακής ακτινοβολίας χρησιμοποιώντας τον μετασχηματισμό Fourier.

Τώρα, μεταξύ των τεχνικών προεπεξεργασίας δεδομένων η κανονικοποίηση [44]-[69] και ο μετασχηματισμός WT [70]- [71] χρησιμοποιούνται ευρέως καθώς μπορούν να μετατρέψουν μεγάλα δεδομένα εισόδου σε μικρότερο εύρος βελτιώνοντας έτσι την υπολογιστική απαίτηση. Για το WT, το concept του wavelet με μηδενική μέση τιμή χρησιμοποιείται και μπορεί να παράγει χρονική συχνότητα για την αναπαράσταση του σήματος ταυτόχρονα και χρησιμοποιείται για αποδόμηση και ανακατασκευή σημάτων [72]. Μπορεί να ξεπεράσει το πρόβλημα με μη σταθερά σύνολα δεδομένων. Επομένως, έχει τη δυνατότητα να μετασχηματίσει τα σήματα στα

πεδία συχνότητας χρόνου και αποδοθούν τα σήματα σε ένα κατά προσέγγιση σύνολο και πολλά λεπτομερή σύνολα [73].

Επιπλέον, το φιλτράρισμα δεδομένων και η συσχέτιση χρησιμοποιήθηκαν για δεδομένα καιρού και φωτοβολταϊκής ισχύος. Αυτή η προεπεξεργασία φιλτράρει τα ελλείποντα δεδομένα καιρού με τη σχετική τιμή φωτοβολταϊκής ισχύος ή οποιαδήποτε εγγραφή ισχύος με δεδομένα καιρού που λείπουν [74]- [75].

Λεπτομερή βήματα για αποτελεσματική προεπεξεργασία:

1. Αρνητική ηλιακή ακτινοβολία και ελλείπουσες σχετικές τιμές παραγωγής παρατηρούνται συχνά νωρίς και αργά τις ώρες της ημέρας, λόγω της ηλιακής ακτινοβολίας. Αντισταθμίσεις αισθητήρων ακτινοβολίας και αστοχίες αντιστροφέα, αντίστοιχα μπορούν να συμβούν. Συνιστάται να ρυθμιστούν οι τιμές εξόδου ακτινοβολίας και ϕ/β σε μηδέν (0).
2. Ελλείποντα δεδομένα ηλιακής ακτινοβολίας, θερμοκρασίας και εξόδου κατά τη διάρκεια της ημέρας, μπορεί να οφείλονται σε δυσλειτουργία των αισθητήρων ηλιακής ακτινοβολίας και θερμοκρασίας, καθώς και σε διακοπές του μετατροπέα ή του δικτύου, αντίστοιχα. Το προτεινόμενο βήμα είναι να τα αποκλειστούν από την ανάλυση.
3. Η κανονικοποίηση των υπόλοιπων δεδομένων [εύρος: 0, 1] μπορεί να αυξήσει την υπολογιστική ταχύτητα, να διατηρήσει συσχετισμούς εισόδου και να εξασφαλίσει γρήγορη σύγκλιση των ANN.

Τέλος, η μετα-επεξεργασία είναι απαίτηση πριν από την αξιολόγηση προβλέψεων οποιουδήποτε μοντέλου. Οι δύο πιο δημοφιλείς προσεγγίσεις μετά την επεξεργασία είναι απο-κανονικοποίηση [76] και η ανακατασκευή των κυματιδίων [77]. Εάν κανονικοποιηθούν τα δεδομένα που χρησιμοποιούνται στο μοντέλο πρόβλεψης στη συνέχεια, η πρόβλεψη θα πρέπει πρώτα να είναι αντι-κανονικοποιημένη προκειμένου να διευκρινιστεί η πραγματική προβλεπόμενη φωτοβολταϊκή ισχύος και έπειτα να αξιολογήσει την απόδοση του μοντέλου. Ομοίως, στα κυματίδια η ανακατασκευή χρησιμοποιείται για την απόκτηση της πραγματικής προβλεπόμενης φωτοβολταϊκής ισχύος εάν τα δεδομένα εισαγωγής του μοντέλου είχαν αρχικά προ-

επεξεργαστεί χρησιμοποιώντας αποδόμηση κυματιδίων (wavelet decomposition) (WD).

1.2.6.6 Βελτιστοποίηση των δεδομένων εισόδου

Η σωστή επιλογή των εισόδων, ως προς τον αριθμό και τον τύπο, είναι προϋπόθεση για βελτιωμένες προβλέψεις. Οι περιττές ή ασθενώς συσχετισμένες εισοδοί θα εισαγάγουν αδικαιολόγητες πολυπλοκότητες στον υπολογισμό, ενώ η απουσία μείζονος παραμέτρου μπορεί να επηρεάσει σοβαρά τις προβλέψεις. Έτσι, οι αλγόριθμοι βελτιστοποίησης είναι απαραίτητοι για την καλύτερη επιλογή των σημαντικών παραμέτρων εισαγωγής.

1.2.7 Κατηγοριοποίηση των τεχνικών πρόβλεψης για φ/β

Αρκετές προσεγγίσεις μοντελοποίησης: φυσική, στατιστική, τεχνητή νοημοσύνη (συμπεριλαμβανομένων των νευρικών δικτύων βαθιάς μάθησης), αλλά και υβριδικά μοντέλα πρόβλεψης έχουν χρησιμοποιηθεί για προβλέψεις εξόδου φ/β. Μερικοί ερευνητές έχουν συγκρίνει διαφορετικά μοντέλα πρόβλεψης.

1.2.7.1 Πρόβλεψη εμμονής (Persistence forecast)

Το μοντέλο εμμονής είναι δημοφιλές για πολύ βραχυπρόθεσμες και βραχυπρόθεσμες πρόβλεψης. Έχει μικρό υπολογιστικό κόστος, χαμηλή καθυστέρηση χρόνου και ικανοποιητική ακρίβεια. Αυτή η τεχνική υιοθετεί την έννοια ότι η τωρινή τιμή ισούται με την μελλοντική, με άλλα λόγια, οι συνθήκες του κλίματος (δηλαδή ηλιακή ακτινοβολία) την επόμενη μέρα αναμένεται να παραμείνουν παρόμοιες με την προηγούμενη ημέρα [140]. Η εξίσωση που χρησιμοποιεί το μοντέλο είναι:

$$P(t + k|t) = \frac{1}{T} \sum_{i=0}^{n-1} P(t - i\Delta t)$$

1.2.7.2 Φυσικό μοντέλο

Η φυσική πρόβλεψη περιλαμβάνει: πίεση αέρα, τραχύτητα επιφανείας, θερμοκρασία, ορογραφία, ανάγλυφο και συνθήκες της χαμηλότερης ατμόσφαιρας για μελλοντικές προβλέψεις [78]- [79]. Αυτή η τεχνική είναι γενικά πιο αξιόπιστη στις μακροπρόθεσμες προβλέψεις [61]. Με βάση αυτή τη μέθοδο, η τεχνική αριθμητικών

καιρικών δεδομένων συνδυάζει μετεωρολογικές πληροφορίες και εξισώσεις μοντέλου ατμόσφαιρας για την πρόβλεψη.

1.2.7.3 Στατιστικές προβλέψεις

Οι στατιστικές μέθοδοι χρησιμοποιούν το ιστορικό των χρονοσειρών και παρόντα δεδομένα. Χρησιμοποιούν λιγότερα δεδομένα εισόδου σε σχέση με άλλες μεθόδους τεχνητής νοημοσύνης και βαθιάς μάθησης. Τα στατιστικά μοντέλα χρησιμοποιούν καθαρά αριθμητικά δεδομένα για την εξαγωγή μοτίβων και την συσχέτιση των δεδομένων.

1.2.7.4 Μοντέλα βασισμένα σε πρόβλεψη χρονοσειρών

Οι χρονοσειρές παρέχουν στατιστικές πληροφορίες για την πρόβλεψη της φύσης του ποσοτικοποιημένου στοιχείου. Αυτές οι παρατηρήσεις καταγράφονται γενικά στον χρόνο σε διαδοχικά σημεία σε τακτικά διαστήματα όπως τριμηνιαία, μηνιαία, εβδομαδιαία, καθημερινή ή ακόμη και ωριαία και λεπτά, ανάλογα με τη μεταβλητή απόκρισης με το χρόνο [22]. Το κίνητρο της ανάλυσης χρονοσειρών είναι να προβλέψει την επικείμενη τιμή αξιολογώντας το μοτίβο των προηγούμενων πληροφοριών. Τέτοιες μέθοδοι μπορεί να είναι:

1. Εκθετική εξομάλυνση
2. Autoregressive moving average (ARMA)
3. Autoregressive integrated moving average (ARIMA)


1.2.7.5 Μοντέλα μηχανικής μάθησης

Η άλλη στατιστική μοντελοποίηση αξιοποιεί τα πλεονεκτήματα της μηχανικής μάθησης, μια προσέγγιση που βασίζεται στην πληροφορική ή την τεχνητή νοημοσύνη (TN). Η μέθοδος βασίζεται στην ικανότητα της TN να μάθει από την εμπειρία με ιστορικά δεδομένα και να ακονίσει περαιτέρω τις προγνωστικές ικανότητές της μέσω εκπαίδευσης. Απαιτούνται ισχυροί υπολογιστές, πολυάριθμες επαναλήψεις πριν η τελική πρόβλεψη να μπορεί να επιτευχθεί. Μπορεί να αντιληφθεί αδύνατες αναπαραστάσεις χωρίς προκαθορισμένους τύπους ή εξισώσεις. Οι εφαρμογές του αφθονούν: αναγνώριση προτύπων, εξόρυξη δεδομένων, προβλήματα ταξινόμησης, φιλτράρισμα και πρόβλεψη. Οι κύριες τεχνικές μηχανικής μάθησης είναι τεχνητά

νευρωνικά δίκτυα, πολυεπίπεδο νευρωνικό δίκτυο (multi-layer perceptron neural network) (MLPNN), recurrent νευρωνικό δίκτυο (RNN), feed forward νευρικό δίκτυο (FFNN) και νευρωνικό δίκτυο feedback.

1.2.7.5.1 Τεχνητά νευρωνικά δίκτυα (ΤΝΔ)

Το ΤΝΔ μιμείται τον μηχανισμό επεξεργασίας πληροφοριών του ανθρώπινου εγκεφάλου. Έχει μια μοναδική ικανότητα στην προσέγγιση μη γραμμικών συναρτήσεων με υψηλή πιστότητα και ακρίβεια και χρησιμοποιούνται σε διαφορετικά πεδία όπως μετεωρολογικές προβλέψεις, χρηματοοικονομικά, φυσική, μηχανική και ιατρική. Το Σχήμα 1.6 είναι μια βασική αναπαράστασή του.




Σχήμα 1.6 Αναπαράσταση ενός τεχνητού νευρωνικού δικτύου [1]

1.2.7.5.2 Multi-layer perceptron neural network

Πολλοί ερευνητές έχουν το MLPNN ως ορόσημο. Είναι μια τεχνική για στοιχειώδη και αποτελεσματική προσέγγιση ANN στο σχεδιασμό και στην πρόβλεψη. Είναι τόσο ισχυρό που αυτό το δίκτυο χρησιμοποιείται καθολικά ώστε να προσεγγίσει και μη


γραμμικά μοντέλα και περίπλοκα προβλήματα που δεν μπορούν να λυθούν από ένα συνηθισμένο νευρωνικό δίκτυο ενός επιπέδου.



Σχήμα 1.7 Αναπαράσταση ενός πολυεπίπεδου νευρωνικού δικτύου [1]

1.2.7.5.3 Recurrent neural network (RNN)

Το RNN είναι μια εξέχουσα εκδοχή των ANN που μπορεί να μάθει και να επεξεργαστεί διαφορετικές και σύνθετες σχέσεις καθώς και υπολογιστικές δομές. Αυτό το δίκτυο βασίζεται προσωρινά σε δεδομένα χρονοσειρών από σύστημα ανατροφοδότησης για να κληρονομήσει τις τιμές του προηγούμενου χρονικού βήματος επιδεικνύοντας χρονικά δυναμικά χαρακτηριστικά. Το μοντέλο έχει μια απλή δομή με ενσωματωμένο βρόχο ανάδρασης που του επιτρέπει να λειτουργεί ως μηχανή πρόβλεψης RNN. Η έξοδος του σχετικού νευρικού στρώματος αθροίζεται με την επόμενη είσοδο και τροφοδοτείται ξανά στο ίδιο στρώμα που είναι το μόνο στρώμα σε ολόκληρο το δίκτυο. Σε αυτή την κατηγορία μπορεί να τοποθετηθεί το long short-term memory network.



Σχήμα 1.8 Αναπαράσταση ενός recurrent νευρωνικού δικτύου [1]

1.2.7.5.4 Radial basis function neural network (RBFNN)

Το RBFNN είναι μια ταχύτερη και καλύτερη προσέγγιση στη μηχανική μάθηση από άλλες προσεγγίσεις ANN. Ως εκ τούτου, χρησιμοποιείται για πρόβλεψη χρονοσειρών και ταξινόμηση και έλεγχο συστήματος. Η δομή χρησιμοποιεί ακτινική βασική λειτουργία ως λειτουργία ενεργοποίησης. Αυτό το δίκτυο έχει γενικά δύο στρώματα. Τα χαρακτηριστικά συγχωνεύονται μαζί με τη λειτουργία ενεργοποίησης ακτινικής βάσης στο πρώτο στρώμα και στη συνέχεια η έξοδος του πρώτου στρώματος χρησιμοποιείται για τον υπολογισμό της ίδιας εξόδου στο επόμενο βήμα. Τα δύο στρώματα μπορούν να αναγνωρίζονται μέσω του συνοπτικού τους βάρους. Το πρώτο επίπεδο δημιουργείται από τις πληροφορίες εισαγωγής ενώ το βάρος του δεύτερου επιπέδου πρέπει να προσδιοριστεί από τον υπολογισμό. Το RBFNN μπορεί να μάθει μέσω μη εποπτευόμενης μεθόδου καθώς τροφοδοτούνται μόνο δεδομένα εισόδου στο δίκτυο. Η εξίσωση δικτύου έχει ως εξής:

$$Y_k(x) = \sum_{j=1}^M W_{kj} \varphi(x) + W_{ko}$$

1.2.7.5.5 Βαθιά μάθηση

Η τελευταία λέξη στην μηχανική μάθηση είναι η βαθιά μάθηση (deep learning) (DL) ή το βαθύ νευρωνικό δίκτυο (deep neural network) (DNN). Αυτό το ANN μπορεί να μάθει από ογκώδη δεδομένα εισόδου και να χρησιμοποιεί βελτιωμένο αλγόριθμο εκμάθησης, καλύτερες μεθόδους ανάλυσης παραμέτρων και πολλά κρυφά στρώματα. Το DL είναι μια τεχνική μηχανικής μάθησης χωρίς επίβλεψη υπονοώντας ότι ο αλγόριθμός του μπορεί να προβλέψει το αποτέλεσμα αντιλαμβανόμενος το μοτίβο στην είσοδο. Προτάθηκε για πρώτη φορά από τον Hinton το 2006 [80]- [81], το DL έχει βελτιωμένη ικανότητα προσδιορισμού τοπικών βέλτιστων και απεικονίζει ρυθμούς συναρμολόγησης.

Κάποιοι ερευνητές ισχυρίζονται ότι το deep convolutional neural network (DCNN) υπερνικά σε απόδοση σε προβλέψεις, για διάφορα δεδομένα εισόδου. Σε όρους πρόβλεψης αξιοπιστίας, ευκρίνειας και συνολικής συνεχούς κατάταξης ικανότητας, μοντέλα πρόβλεψης που αναπτύχθηκαν από πιθανό συνδυασμό με WT, DCNN και

ποσοτική παλινδρόμηση (quantitative regression) (QR), τα μοντέλα φάνηκε να είναι πολύ αποτελεσματικά.

Ένα ειδικό υποσύνολο αλγορίθμου DL, το συνελκτικό νευρωνικό δίκτυο (CNN) είναι μια νέα προσέγγιση όπου οι αρχές συνδεσιμότητας μεταξύ των συνθετικών νευρώνων μιμούνται την οργάνωση του οπτικού φλοιού των ζώων. Εκτός αυτού, μαθαίνει να αναγνωρίζει μοτίβα συνήθως επισημαίνοντας τα όρια και συμπεριφορές των pixel που παρατηρούνται γενικά σε διάφορες εικόνες. Για να λειτουργήσει, το CNN αποτελείται από πολλά μπλοκ, όπως συνέλιξη, ενεργοποίηση και συγκέντρωση, όλα λειτουργούν μαζί για εξαγωγή χαρακτηριστικών.

1.2.8 Ανασκόπηση για την παρούσα εργασία

Η αβεβαιότητα του καιρού δίνει την εντύπωση ότι ένα δίκτυο μεταφοράς ισχύος βασισμένο σε ΑΠΕ ή ακόμα και ένα υβριδικό δίκτυο είναι δύσκολο να υλοποιηθεί. Ωστόσο, οι εξελίξεις στα μαθηματικά μοντέλα, οι φυσικές αναπαραστάσεις, η στατιστική ανάλυση και η υπολογιστική δύναμη έχουν κάνει την πρόβλεψη μια βιώσιμη επιλογή. Πολλοί οργανισμοί έχουν δείξει πρωτοβουλία για την υποστήριξη της έρευνας σε αυτή την κατεύθυνση και, ως απάντηση, υπάρχουν διαθέσιμα σημαντικά ερευνητικά ευρήματα. Ακόμα, τα υπάρχοντα μοντέλα πρόβλεψης είναι είτε πολύ συγκεκριμένα για ένα χωρικό χρονικό ορίζοντα είτε είναι περιορισμένα για μια συγκεκριμένη περιοχή. Η τρέχουσα ανάγκη, επομένως, είναι για μια πιο ευέλικτη προσέγγιση πρόβλεψης που δεν περιορίζεται από αυτούς τους περιορισμούς και μπορεί να αναπαραχθεί για ποικίλες αρχικές συνθήκες σε διαφορετικές γεωκλιματικές συνθήκες. Ο προφανής υποψήφιος για αυτό το πρόβλημα είναι το ANN, πιο συγκεκριμένα η προσέγγιση DNN, μαζί με τα παράγωγά του, όπως το deep LSTM και το DCNN. Περισσότερη έρευνα είναι απαιτείται για τη διερεύνηση της χρήσης αυτών των τεχνικών για την επίλυσή του.

1.3 Ανασκόπηση της βιβλιογραφίας για στην πρόβλεψη παραγωγής από αιολική ενέργεια

Το μεγαλύτερο εμπόδιο, που καταστέλλει την αύξηση της διείδυσης της αιολικής ενέργειας μέσα στο δίκτυο, ισχύος είναι η αβεβαιότητα και οι διακυμάνσεις στις ταχύτητες του ανέμου. Επομένως, η ακριβής πρόβλεψη της αιολικής ενέργειας

αποτελεί μια δύσκολη εργασία, η οποία μπορεί να επηρεάσει σημαντικά την αποτελεσματική λειτουργία των συστημάτων ισχύος. Η πρόβλεψη της αιολικής ισχύος είναι επίσης ζωτικής σημασίας για τον προγραμματισμό της δέσμευσης της μονάδας, του προγραμματισμού συντήρησης και της μεγιστοποίησης του κέρδους των εμπορών ενέργειας.

Τα τελευταία χρόνια, η ραγδαία οικονομική ανάπτυξη οφείλεται στην αύξηση της παραγωγής ηλεκτρικής ενέργειας με ποικίλους τρόπους. Μεταξύ όλων των ειδών ανανεώσιμων πηγών ενέργειας όπως ηλιακή φωτοβολταϊκή, παλιρροιακή, κύματα και σύγχρονη βιοενέργεια, η αιολική ενέργεια έχει γίνει εξαιρετικά δημοφιλής επειδή είναι πολύ αποτελεσματική, φθηνή και ευεργετική για το περιβάλλον [3]. Επιπλέον, λόγω της αφθονίας, η αιολική ενέργεια παίζει ένα πρωταγωνιστικό ρόλο στην παραγωγή ηλεκτρικής ενέργειας στον τομέα των ανανεώσιμων πηγών ενέργειας [82]. Έχει τη μεγαλύτερη ζήτηση και ανάπτυξη μεταξύ όλων των ανανεώσιμων πηγών ενέργειας την τελευταία δεκαετία [83]. Πρόσφατες έρευνες έδειξαν ότι η ετήσια αύξηση της εγκατεστημένης ισχύος αιολικής ενέργειας είναι περίπου 30% [84].

Η πρόβλεψη της αιολικής ενέργειας είναι εξαιρετικά σημαντική για την αξιολόγηση της μελλοντικής χρήσης ενέργειας από μία ή περισσότερες ανεμογεννήτριες. Ωστόσο, η ισχύς που παράγεται από ανεμογεννήτριες αλλάζει γρήγορα λόγω της διακύμανσης της ταχύτητας του ανέμου και της κατεύθυνσης του ανέμου. Εξαρτάται επίσης από το έδαφος, την υγρασία, την ημερομηνία και ώρα της ημέρας [85]. Αυτή η συνεχής αλλαγή κάνει τη διαχείριση της αιολικής ενέργειας πρόκληση για δίκτυα διανομής, όπου είναι ιδιαίτερα επιθυμητή η ισορροπία μεταξύ της τροφοδοσίας και ζήτησης [86]. Επομένως, ένας από τους κύριους λόγους για την πρόβλεψη της αιολικής ενέργειας είναι η μείωση του κινδύνου αβεβαιότητας στον άνεμο, επιτρέποντας μεγαλύτερη διεύθυνση. Είναι επίσης ζωτικής σημασίας για καλύτερη αποστολή, συντήρηση, σχεδιασμό, προσδιορισμό του απαιτούμενου λειτουργικού εξοπλισμού κ.λπ.

Έρευνες έχουν πραγματοποιηθεί και πρόσφατες μελέτες πρόβλεψης αιολικής ενέργειας [87]- [85]- [86], οδηγούν σύγκριση διαφορετικών προγνωστικών μεθόδων.

1.3.1 Κατηγοριοποίηση πρόβλεψης αιολικής ισχύος

Η πρόβλεψη της αιολικής ενέργειας θα μπορούσε να ταξινομηθεί βάσει είτε χρονικών οριζόντων είτε των μεθόδων που χρησιμοποιούνται για την πρόβλεψη [84]. Με βάση διαφορετικές χρονικές κλίμακες, η πρόβλεψη μπορεί να χωριστεί σε πολύ βραχυπρόθεσμο σενάριο, για το οποίο το εύρος των προβλέψεων είναι συνήθως κάτω από 30 λεπτά, έως και ένα μήνα (μακροπρόθεσμη πρόβλεψη), η οποία έχει δει μια προοδευτική εξέλιξη από την τελευταία δεκαετία. Αφ' ετέρου, η μέθοδος πρόβλεψης έχει επωφεληθεί από την εξέλιξη των υπολογιστικών εργαλείων υψηλής απόδοσης, που καθιερώνονται ολοένα και πιο νέες υπολογιστικές μέθοδοι.

1.3.1.1 Ορίζοντες πρόβλεψης

Ανάλογα με τις διαφορετικές προδιαγραφές, οι ορίζοντες πρόβλεψης θα μπορούσαν να χωριστούν σε τέσσερις σημαντικές χρονικές κλίμακες, οι οποίες συνοψίζονται στον Πίνακα 1.1. Αξίζει να σημειωθεί ότι τα σφάλματα πρόβλεψης αυξάνονται με αύξηση των χρονικών οριζόντων [85]- [88].

Πίνακας 1.1 Χρονικοί ορίζοντες πρόβλεψης για α/γ και Εφαρμογές

Χρονικός Ορίζοντας	Χρονικό Εύρος	Εφαρμογές
Πολύ βραχυπρόθεσμος	Μερικά έως 30 λεπτά	ενέργειες ρύθμισης, λειτουργίες δικτύου σε πραγματικό χρόνο, καθαρισμός αγοράς, έλεγχος στροβίλου
Βραχυπρόθεσμος	30 λεπτά έως 6 ώρες	προγραμματισμός διανομής φορτίων, λήψη έξυπνων αποφάσεων
Μεσοπρόθεσμος	6 έως 24 ώρες	μεσοπρόθεσμη λειτουργική ασφάλεια 6 ωρών έως 1 ημέρας στην

		αγορά ενέργειας	ηλεκτρικής
Μακροπρόθεσμος	1 μέρα έως 1 μήνα	απαιτήσεις αποθεμάτων, προγράμματα συντήρησης, βέλτιστο λειτουργικό κόστος, διαχείριση λειτουργίας	

1.3.1.2 Μέθοδοι πρόβλεψης

Σύμφωνα με τις εφαρμοσμένες μεθοδολογίες, τα μοντέλα πρόβλεψης αιολικής ενέργειας μπορούν περαιτέρω να χωριστούν σε επιμένουσες μεθόδους, φυσικές μεθόδους, μοντέλα χρονοσειρών και τεχνητά νευρωνικά δίκτυα (ANN). Οι διαφορές τους εντοπίζονται στα απαιτούμενα δεδομένα εισόδου, στην ακρίβεια σε διαφορετικές χρονικές κλίμακες και στην πολυπλοκότητα της διαδικασίας.

1.3.1.2.1 Μέθοδοι εμμονής

Χρησιμοποιεί συνήθως ως αναφορά, ότι η αιολική ισχύς στο μέλλον θα είναι ίση με τη μετρούμενη στο παρόν. Αυτή η προσέγγιση χρησιμοποιείται συνήθως για να συγκριθεί με βραχυπρόθεσμες μεθόδους πρόβλεψης για τον εντοπισμό των βελτιώσεων τους [86]- [88]- [89]. Η ακρίβεια αυτής της μεθόδου μπορεί να επιδεινωθεί γρήγορα με την αύξηση του χρονοδιαγράμματος πρόβλεψης [90]. Εκτός από το ότι είναι απλό και οικονομικό μοντέλο, το κύριο πλεονέκτημα αυτής της μεθόδου είναι ότι ούτε αξιολόγηση παραμέτρων ούτε εξωτερικές μεταβλητές απαιτούνται [91].

1.3.1.2.2 Φυσικές μέθοδοι

Οι φυσικές μέθοδοι χρησιμοποιούν λεπτομερή φυσικό χαρακτηρισμό για τη μοντελοποίηση ανεμογεννητριών ή ολόκληρων πάρκων. Αυτή η προσπάθεια μοντελοποίησης συχνά πραγματοποιείται χρησιμοποιώντας τα αριθμητικά δεδομένα πρόγνωσης καιρού (NWP), το οποίο απαιτεί περιγραφή της περιοχής, όπως τραχύτητα και εμπόδια, καθώς και πρόγνωση καιρού με δεδομένα θερμοκρασίας,

πίεσης κ.λπ. Αυτές οι μεταβλητές χρησιμοποιούνται σε πολύπλοκα μαθηματικά μοντέλα που είναι χρονοβόρα για τον προσδιορισμό της ταχύτητας του ανέμου. Στη συνέχεια, η προβλεπόμενη ταχύτητα ανέμου θα χρησιμοποιηθεί για να εξαχθεί η καμπύλη ισχύος ανεμογεννητριών που συνήθως παρέχεται από τον κατασκευαστή του στροβίλου για την πρόβλεψη της αιολικής ενέργειας. Αυτή η μέθοδος δεν χρειάζεται να εκπαιδευτεί με ιστορικά δεδομένα, αλλά απαιτούνται από τα φυσικά δεδομένα [92].

1.3.1.2.3 Στατιστικές μέθοδοι

Αυτή η μέθοδος βασίζεται γενικά στην ανάπτυξη των μη γραμμικών και των γραμμικών σχέσεων μεταξύ δεδομένα (όπως ταχύτητα ανέμου, κατεύθυνση και θερμοκρασία ανέμου) και της παραγόμενης ισχύος. Για να οριστεί η στατιστική σχέση, τα προηγούμενα δεδομένα ιστορικού χρησιμοποιούνται ως δεδομένα εκπαίδευσης. Το μοντέλο είναι τότε συντονισμένο συγκρίνοντας την πρόβλεψη του μοντέλου και τη μετρούμενη ισχύ. Μετά από αυτό, το μοντέλο είναι έτοιμο να προβλέψει από τις προβλέψεις για τα μετεωρολογικά δεδομένα για τις επόμενες ώρες και τις τωρινές μετρήσεις. Η μέθοδος θεωρείται απλή και χωρίζεται σε βασισμένα σε χρονοσειρές μοντέλα και μεθόδους νευρωνικών δικτύων. Είναι σχετικά αποτελεσματικό για πολύ βραχυπρόθεσμους και βραχυπρόθεσμους χρονικούς ορίζοντες.

1.3.1.2.4 Μοντέλα χρονοσειρών

Αυτά τα μοντέλα, τα οποία προτάθηκαν από τους Box-Jenkins, εφαρμόζουν ιστορικά δεδομένα για τη δημιουργία ενός μαθηματικού μοντέλου, για την εκτίμηση παραμέτρων και τον έλεγχο προσομοίωσης. Η γενική μορφή του μοντέλου μπορεί να περιγραφεί ως:

$$X_t = \sum_{i=1}^p \varphi_i X_{t-1} + \alpha_t - \sum_{j=1}^1 \theta_j \alpha_{t-1}$$

Όπου φ_i είναι παράμετρος autoregressive και θ_j είναι παράμετρος του κινητού μέσου όρου, α_t αποτελεί τον λευκό θόρυβο. Το μοντέλο ονομάζεται στην βιβλιογραφία ARMA. Αυτή και παρόμοιες μέθοδοι είναι αποτελεσματικές σε βραχυπρόθεσμες προβλέψεις [93].

1.3.1.2.5 Τεχνητά νευρωνικά δίκτυα

Τα ANN, ως μια από τις πιο συχνά χρησιμοποιούμενες μεθόδους για την πρόβλεψη της αιολικής ενέργειας, αφού μπορούν να αναγνωρίσουν τις μη γραμμικές σχέσεις μεταξύ των χαρακτηριστικών εισόδου και των δεδομένων εξόδου [94]. Ένας από τους λόγους για την τάση χρήσης νευρωνικών δικτύων είναι να αποφευχθεί η πολυπλοκότητα της μηχανικής δομής στον στρόβιλο [95]. Συνήθως, ένα μοντέλο ANN αποτελείται από ένα επίπεδο εισόδου, ένα ή περισσότερα κρυφά επίπεδα, και ένα επίπεδο εξόδου, όπου τα ιστορικά δεδομένα / χαρακτηριστικά τροφοδοτούνται για εκπαίδευση και δοκιμές.

Η απόδοση των ANN εξαρτάται από πολλούς διαφορετικούς παράγοντες, συμπεριλαμβανομένης της προεπεξεργασίας δεδομένων, δομής δεδομένων, μέθοδος μάθησης, συνδέσεις μεταξύ δεδομένων εισόδου και εξόδου και ούτω καθεξής [96]. Υπάρχουν πολλές μορφές ANN, συμπεριλαμβανομένων των πολυεπίπεδων νευρωνικών (MLP), νευρωνικά δίκτυα κυμάτων (wavelet neural network) (WNN), νευρωνικό δίκτυο οπίσθιας διάδοσης (back propagation neural network) (BPNN), νευρωνικό δίκτυο ακτινικής βάσης (RBFNN), νευρωνικό δίκτυο Elman (elman neural network) (ENN), μακροπρόθεσμης μνήμης (LSTM), συνελκτικό νευρωνικό δίκτυο (CNN), κ.λπ. Ο σχεδιασμός ενός μοντέλου ANN απαιτεί την αντιμετώπιση δύο βημάτων: πρώτο, την επιλογή της σωστής δομής του δικτύου και στη συνέχεια τον καθορισμό της κατεύθυνσης των πληροφοριών. Υπάρχουν δύο σημαντικές τοπολογίες, συμπεριλαμβανομένης της προώθησης για τη μετάδοση δεδομένων σε μία κατεύθυνση από τα επίπεδα εισόδου σε εξόδου και για αμοιβαίες κατευθύνσεις. Το δεύτερο βήμα είναι η επιλογή του αλγορίθμου σωστής μάθησης μεταξύ εποπτευόμενης, μη εποπτευόμενης και ενισχυτικής μάθησης [92].

Οι Jyothish και Rao [97] χρησιμοποίησαν ένα προσαρμοστικό νευρωνικό δίκτυο κύματος (WNN) για βραχεία πρόβλεψη αιολικής ενέργειας. Το κανονικοποιημένο τετραγωνικό μέσο ριζικό μέσο σφάλμα (NRMSE) που πέτυχαν ήταν 0,02. Οι Bilal et al. [98] σχεδίασε ένα δίκτυο MLP για να προβλέψει την αιολική ενέργεια τεσσάρων διαφορετικών αιολικών πάρκων στο Σενεγάλη. Η κύρια είσοδος του μοντέλου τους ήταν η ταχύτητα του ανέμου, αλλά αξιολόγησαν επίσης διαφορετικούς συνδυασμούς

μεταβλητών εισόδου όπως κατεύθυνση ανέμου, θερμοκρασία, υγρασία και ηλιακή ακτινοβολία. Τα αποτελέσματα έδειξαν ότι, εκτός από την ταχύτητα του ανέμου, η θερμοκρασία του αέρα έχει το μεγαλύτερο αντίκτυπο στη βελτίωση της ακρίβειας του μοντέλου.

Σε μια άλλη έρευνα, ο Chang [99] ανέπτυξε ένα μοντέλο βασισμένο στο BPNN για 10 λεπτά μπροστά. Τα ιστορικά δεδομένα αιολικής ενέργειας μιας ανεμογεννήτριας στην Ταϊβάν χρησιμοποιήθηκαν για την επαλήθευση της αποτελεσματικότητας αυτής της μεθόδου. Τα αποτελέσματα έδειξαν ότι το προτεινόμενο νευρικό δίκτυο θα μπορούσε να προβλέψει την αιολική ισχύ με μέσο απόλυτο σφάλμα 0,278%.

1.3.1.2.6 Υβριδικές προσεγγίσεις

Οι συνδυασμοί διαφορετικών μεθόδων πρόβλεψης, όπως ANN και μοντέλα ασαφούς λογικής, ονομάζονται υβριδικές προσεγγίσεις [100]. Ο κύριος στόχος αυτής της μεθόδου είναι να διατηρήσει τα πλεονεκτήματα κάθε τεχνικής και να βελτιώσει τη συνολική ακρίβεια. Στη στατιστική και τη μηχανική μάθηση, υπάρχουν διάφορα μοντέλα πρόβλεψης συχνά αναπτύσσεται χρησιμοποιώντας πολλαπλούς αλγόριθμους και διαφορετικά σύνολα δεδομένων εκπαίδευσης.

Οι Hong and Rioflorido [100] πρότειναν ένα υβριδικό μοντέλο πρόβλεψης αιολικής ενέργειας 24 ώρες μπροστά με βάση CNN. Χρησιμοποιήθηκαν διαφορετικές λειτουργίες στο CNN, όπως συνελεύσεις, ομαδοποίηση και πυρήνας στα χαρακτηριστικά εισαγωγής. Τα καθορισμένα χαρακτηριστικά στη συνέχεια τροφοδοτήθηκαν σε ένα RBFNN, εφαρμόζοντας το descend gradient function (DGF) ως μέθοδο βελτιστοποίησης. Οι συγγραφείς χρησιμοποίησαν επίσης τον ADAM για περαιτέρω βελτίωση των CNN και RBFNN. Χρησιμοποιώντας ιστορικά δεδομένα ισχύος ενός έτους από ένα αιολικό πάρκο στην Ταϊβάν, η προτεινόμενη προσέγγιση παρείχε την καλύτερη απόδοση σε σύγκριση με άλλες μεθόδους όπως πολυεπίπεδο νευρικό δίκτυο και MLNN-GA (Γενετικός Αλγόριθμος), RBFNN-GA, RBFNN-DGF, CNN-MFNN και CNN-RBFNN. Οι συγγραφείς κατέληξαν επίσης στο συμπέρασμα ότι η εφαρμογή του DGF στο RBFNN παρήγαγε καλύτερα αποτελέσματα από τα συμβατικά RBFNN με τη συνάρτηση Gauss.

Οι Zhang et al. [82] χρησιμοποίησε το δίκτυο LSTM για να προβλέψει την παραγωγή αιολικής ενέργειας ενός αιολικού πάρκου στο Κίνα. Τριμηνιαία δεδομένα ταχύτητας ανέμου από NWP χρησιμοποιήθηκαν ως είσοδοι και η παραγόμενη αιολική ενέργεια αντιμετωπίστηκε ως έξοδος. Λαμβάνοντας υπόψη το πρότυπο του Κινέζικου δικτύου, οι συγγραφείς συνέκριναν το δικό τους μοντέλο με λειτουργία Radial Basis Function (RBF), wavelet, δίκτυο βαθιάς πεποίθησης (deep belief network) (DBN), οπίσθια διάδοση (BP) και Elman. Τα αποτελέσματα έδειξαν ότι το προτεινόμενο μοντέλο είχε βελτιώσει την ακρίβεια των προβλέψεων, αν και ο χρόνος λειτουργίας του ήταν μεγαλύτερος από τους άλλους. Πρότεινε επίσης ότι η απόδοση του μοντέλου εξαρτάται σε μεγάλο βαθμό από το εύρος της ταχύτητας του ανέμου. Σε υψηλές ταχύτητες, το wavelet παρείχε καλύτερη απόδοση, ενώ οι άλλες μέθοδοι προέβλεπαν καλύτερα σε περιοχές χαμηλότερης ταχύτητας.

1.3.2 Παράγοντες σύγκρισης διαφορετικών μεθόδων

Οι μέθοδοι εκτίμησης της αιολικής ενέργειας μπορούν να συγκριθούν με διάφορες πτυχές, με σημαντικότερες την ακρίβεια, τα χαρακτηριστικά εισαγωγής, τον υπολογιστικό χρόνο.

1.3.2.1 Ακρίβεια

Η ακρίβεια της πρόβλεψης της αιολικής ενέργειας είναι ο πιο σημαντικός παράγοντας για τη σύγκριση διαφορετικών προγνωστικών μεθόδων, οι οποίες μπορούν να καθοριστούν από μια συγκεκριμένη μέτρηση αξιολόγησης. Συνήθως, προβλέπονται διαφορετικά επίπεδα ακρίβειας ανάλογα με την μελέτη και την επιθυμητή εφαρμογή. Για παράδειγμα, σε ορισμένες αναφορές, έχει αναφερθεί ότι το RMSE πρέπει να είναι εντός του 10% της εγκατεστημένης χωρητικότητας για τα περισσότερα από τα μοντέλα. Στην Κίνα, η κρατική εταιρία του δικτύου ισχύος έχει ορίσει 20% για το μέγιστο αποδεκτό RMSE για βραχυπρόθεσμη αιολική ενέργεια πρόβλεψη και 15% για την προβλεπόμενη τιμή των 4 ωρών μπροστά [38]. Στην Ιρλανδία, οι διαχειριστές του δικτύου (EirGrid και SONI) απαιτούν έναν στόχο ακρίβεια 6-8% [101].

1.3.2.2 Χαρακτηριστικά εισαγωγής

Όσο λιγότερα τα χαρακτηριστικά εισαγωγής για επεξεργασία τόσο πιο ευέλικτο και εύκολο να χρησιμοποιηθεί είναι ένα μοντέλο. Έτσι, επιμένουσες μέθοδοι δεν έχουν απαίτηση για δεδομένα ενώ μοντέλα μηχανικής μάθησης απαιτούν ένα μεγάλο όγκο. Με την ανάπτυξη της τεχνολογίας και της πληροφορικής γίνεται ολοένα και ευκολότερη η συλλογή, μεταφορά και επεξεργασία μεγάλου όγκου δεδομένων που απαιτείται για την δημιουργία πολύπλοκων και μεγαλύτερης ακρίβειας, μοντέλων πρόβλεψης.

1.3.2.3 Υπολογιστικός χρόνος

Ο υπολογιστικός χρόνος (χρόνος που απαιτείται για εκπαίδευση / μάθηση) θεωρείται άλλος σημαντικός παράγοντας για την επιλογή κατάλληλων μοντέλων πρόβλεψης, ειδικά για βραχυπρόθεσμες προβλέψεις. Είναι επίσης χρήσιμο να κατανοηθεί εάν μπορεί να εφαρμοστεί σε πραγματικό χρόνο.

1.3.2.4 Απόδοση του μοντέλου πρόβλεψης

Όπως έχει συζητηθεί στην παράγραφο 1.2.5 της παρούσας εργασίας υπάρχουν μετρικές για τον υπολογισμό των σφαλμάτων και την απόφαση για το εάν ένα μοντέλο είναι ακριβές με κύριες όσες έχουν περιγραφεί.

1.3.3 Βελτίωση της ακρίβειας πρόβλεψης

Σχεδόν όλες οι τρέχουσες προσπάθειες μοντελοποίησης που γίνονται για την πρόβλεψη της παραγωγής αιολικής ενέργειας πρόκειται να μειώσουν τα σφάλματα πρόβλεψης. Αυτές οι προσπάθειες έχουν οδηγήσει σε διάφορες βελτιώσεις, οι οποίες συνοψίζονται παρακάτω.

1.3.3.1 Φίλτρο Kalman

Δεδομένου ότι η ακρίβεια των δεδομένων από αριθμητικά καιρικά μοντέλα έχει πολύ σημαντική επίδραση στην ακρίβεια της πρόβλεψης αιολικής ενέργειας, ένας τρόπος βελτίωσης της απόδοσής του είναι η μείωση της αβεβαιότητας των καιρικών δεδομένων. Για το σκοπό αυτό, ο αλγόριθμος φιλτραρίσματος Kalman χρησιμοποιείται για την εξάλειψη συστηματικών σφαλμάτων. Αυτή η μέθοδος μπορεί εύκολα να προσαρμοστεί σε οποιαδήποτε αλλαγή στις παρατηρήσεις και δεν

χρειάζεται μια μακρά σειρά βασικών πληροφοριών. Σε μια έρευνα των Louka et al. [102], το φίλτρο Kalman χρησιμοποιήθηκε για τη βελτίωση των δεδομένων εισόδου για το μοντέλο που προέβλεπε την αιολική ενέργεια.

1.3.3.2 Εξωτερική ανίχνευση

Τα δεδομένα από επίβλεψη με συστήματα SCADA, μπορούν να οδηγήσουν στην ανακρίβεια της πρόβλεψης της αιολικής ενέργειας, που συνήθως προκαλείται από τη μη βαθμονόμηση των αισθητήρων ή την υποβάθμιση τους με την πάροδο του χρόνου [103]. Ως τεχνική βελτίωσης της ακρίβειας του μοντέλου, η ανίχνευση και η εξάλειψη αυτών των ακραίων τιμών έχουν διερευνηθεί σε προηγούμενες μελέτες. Οι Yang et al. [104] χρησιμοποίησαν έναν αλγόριθμο για την προεπεξεργασία δεδομένων SCADA για βελτίωση της ποιότητας, μετά από εξέταση των παραγόντων που επηρεάζουν μια ανεμογεννήτρια, συμπεριλαμβανομένης της δομικής ακεραιότητας και της τύρβης.

1.3.3.3 Κατάλληλος συνδυασμός δεδομένων εισόδου

Για τον καθορισμό του πιο αποτελεσματικού μοντέλου πρόβλεψης αιολικής ενέργειας, ο επόμενος κρίσιμος παράγοντας είναι η επιλογή των καλύτερων δεδομένων εισόδου από το σύστημα [105]. Αυτή η επιλογή είναι εξαιρετικά σημαντική στην αύξηση την ακρίβεια των μοντέλων πρόβλεψης. Η ταχύτητα του ανέμου είναι η πιο συχνά χρησιμοποιούμενη είσοδος μεταβλητή για πρόβλεψη αιολικής ενέργειας. Αυτό συμβαίνει επειδή η αιολική ενέργεια είναι ανάλογη με τον κύβο της ταχύτητας ανέμου σύμφωνα με την εξίσωση [106].

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

Οι Zhang et al. [82] εξέτασαν τρία διαφορετικά σύνολα δεδομένων στη Βόρεια Κίνα κατά τις έρευνές τους. Τα αποτελέσματα έδειξαν ότι η ταχύτητα του ανέμου, μεταξύ όλων των καιρικών δεδομένων NWP, είναι η πιο σημαντική παράμετρος που επηρεάζει την ακρίβεια. Οι συγγραφείς σημείωσαν επίσης ότι η αλλαγή στη θέση των ανεμογεννητριών είναι πολύ ευαίσθητη για την απόδοση της μεθόδου πρόβλεψης, λόγω του φαινομένου του απόρου, και της «σκίασης».

Η κατεύθυνση του ανέμου είναι ένας άλλος παράγοντας που επηρεάζει την παραγωγή ενέργειας. Λαμβάνοντας υπόψη τον σχεδιασμό μιας ανεμογεννήτριας, οι

ανεμογεννήτριες πρέπει να στρέφονται στον άνεμο κατά τη διάρκεια της λειτουργίας [95]. Singh et al. [85] έδειξε ότι η ταχύτητα και η κατεύθυνση του ανέμου ήταν οι δύο κορυφαίοι παράγοντες επιρροής στην πρόβλεψη ισχύος μέσω του μοντέλου πρόβλεψης MLP.

Ο Lin και ο Liu [95] παρουσίασαν ότι η ταχύτητα του ανέμου, η κατεύθυνση του ανέμου, η θερμοκρασία και η υγρασία ήταν από τα πιο χρησιμοποιούμενα δεδομένα εισαγωγής. Πρότειναν ένα νέο υβριδικό μοντέλο, που χρησιμοποιεί ταχύτητα ανέμου σε διαφορετικά ύψη, γωνία pitch, θερμοκρασία, σφάλμα γωνίας yaw και προσανατολισμού της α/γ ως χαρακτηριστικά εισαγωγής. Η γωνία pitch του πτερυγίου χρησιμοποιήθηκε επειδή παίζει ζωτικό ρόλο στην προσαρμογή του πτερυγίου για ασφαλή παραγωγή ενέργειας. Μετά από συζήτηση της επίδρασης της πυκνότητας αέρα στην αιολική ενέργεια (σύμφωνα με την εξίσωση), οι συγγραφείς διαπίστωσαν ότι η πυκνότητα του αέρα εξαρτάται από τη θερμοκρασία του αέρα, την ατμοσφαιρική πίεση και τη σχετική υγρασία. Έτσι οι παραπάνω μεταβλητές αποτελούν τα κύρια δεδομένα που πρέπει να αναζητήσει κάποιος που θέλει να ερευνήσει το πρόβλημα της πρόβλεψης ηλεκτρικής ισχύος προερχόμενης από αιολική ισχύ.

1.3.4 Συμπεράσματα για την αιολική ενέργεια

Με βάση την βιβλιογραφία που μελετήθηκε, συνοψίζονται τα συμπεράσματα ως εξής:

1. Με τη συνεχή ανάπτυξη ανεμογεννητριών, η πρόβλεψη ισχύος θα διατηρηθεί αυξάνοντας τον σημαντικότητά της, στα στάδια λειτουργίας της ανεμογεννήτριας. Πρέπει να αναπτυχθούν μέθοδοι πρόβλεψης οικονομικοί και προηγμένοι για την καλύτερη πρόβλεψη παραγόμενης ισχύος από άνεμο, ειδικά σε μεγάλες αιολικές εγκαταστάσεις. Πιο συγκεκριμένα, νέες υβριδικές μέθοδοι, συμπεριλαμβανομένης της ενσωμάτωσης αριθμητικών προσομοιώσεων και νευρωνικά δίκτυα, βαθιά μάθηση και πιο προηγμένος συνδυασμός τους, συνιστώνται.
2. Η ανάπτυξη σύγχρονων υπολογιστών και μεθόδων αποθήκευσης επιτρέπει τον χειρισμό μεγαλύτερου όγκου δεδομένων. Εν τω μεταξύ, το

μεγαλύτερο μέγεθος δεδομένων έχει δημιουργήσει νέες προκλήσεις όσον αφορά προεπεξεργασία δεδομένων και την μεταεπεξεργασία. Οι μελλοντικές μελέτες θα πρέπει να επικεντρώνονται στην ανάπτυξη λιγότερο εκτεταμένων υπολογιστικών μεθόδων και αφαίρεση του θορύβου των πρωτογενών δεδομένων.

3. Για την επίλυση της πρόβλεψης της αιολικής ενέργειας, το τέλειο μοντέλο πρόβλεψης θα παρείχε μηδενικό σφάλμα, το οποίο είναι η καλύτερη απόδοση. Ωστόσο, όλα τα μοντέλα πρόβλεψης αιολικής ενέργειας περιέχουν σφάλματα λόγω της στοχαστικής φύσης του ανέμου και της υψηλής μη γραμμικότητας του προβλήματος. Πολλοί παράγοντες μπορούν να επηρεάσουν την ακρίβεια ενός προγνωστικού μοντέλου, όπως συγκεκριμένα μεγέθη και ποσοστά δειγματοληψίας συνόλων δεδομένων εκπαίδευσης / δοκιμών / επικύρωσης, χρησιμοποιημένων αλγορίθμων και βελτιστοποιήσεων των μοντέλων. Ωστόσο, μια ευρεία και αποδεκτή βασική μέθοδος πρόβλεψης αιολικής ενέργειας δεν υπάρχει στην τρέχουσα ερευνητική κοινότητα. Απαιτείται ακόμη περαιτέρω έρευνα για την ανάπτυξη μιας βάσης μοντέλου, που λειτουργεί αξιόπιστα στη συγκριτική αξιολόγηση άλλων μεθόδων πρόβλεψης.

1.4 Σκοπός της διπλωματικής εργασίας

Από τα παραπάνω συμπεραίνεται ότι η πρόβλεψη της ηλεκτρικής ενέργειας προερχόμενης από φωτοβολταϊκά και ανεμογεννήτριες, αποτελεί ένα σημαντικό παράγοντα για την δημιουργία ενός εξελιγμένου δικτύου ισχύος επόμενης γενιάς, φιλικού προς το περιβάλλον. Ακόμη η πρόβλεψη της ηλεκτρικής ισχύος προερχόμενης από ΑΠΕ, φαίνεται ότι αποτελεί ένα ανοικτό και με μεγάλες προκλήσεις ερευνητικό ζήτημα. Σκοπός της παρούσας εργασίας λοιπόν, είναι να δημιουργηθούν και να αξιολογηθούν δύο καινοτόμα μοντέλα βαθιάς μάθησης, τόσο για την πρόβλεψη φωτοβολταϊκής όσο και για την πρόβλεψη αιολικής ισχύος, αλλά και να συγκριθούν με υπάρχοντα μοντέλα μηχανικής και βαθιάς μάθησης.

1.5 Μεθοδολογία της διπλωματικής εργασίας

Για την πρόβλεψη της ηλεκτρικής ισχύος δημιουργήθηκαν δύο καινοτόμα υπολογιστικά μοντέλα.

Το ένα αναφέρεται στην πρόβλεψη ηλεκτρικής ισχύος προερχόμενης από φωτοβολταϊκά και διερευνάται η απόδοσή του σε δύο χρονικούς ορίζοντες. Οι ορίζοντες είναι αυτοί της ημέρας μπροστά και ο ενδοωριαίος χρονικός ορίζοντας. Το ίδιο μοντέλο χρησιμοποιείται και για την αιολική πρόβλεψη μόνο όμως για τον ενδοωριαίο χρονικό ορίζοντα. Για να γίνει αυτό το αρχικό σήμα εξόδου ισχύος αποδομείται σε 4 συνιστώσες κυμάτων με την μέθοδο του διακριτού μετασχηματισμού κυμάτων. Η μία συνιστώσα αποτελεί το κύριο σήμα και οι άλλες τρεις είναι συνιστώσες λευκού θορύβου. Στην συνέχεια κάθε μία συνιστώσα της χρονοσειράς τροφοδοτείται ως είσοδος μαζί με μετεωρολογικές παραμέτρους σε ένα μοντέλο πρόβλεψης συνελκτικού νευρωνικού δικτύου (CNN). Το μοντέλο εκπαιδεύεται και στην συνέχεια του δίνονται δεδομένα εισόδου για πραγματοποίηση προβλέψεων. Αφού πραγματοποιηθεί η πρόβλεψη για την διάρκεια ενός χρόνου για κάθε συνιστώσα ξεχωριστά, η χρονοσειρά ανακατασκευάζεται, και πραγματοποιείται ο υπολογισμός της ακρίβειας και σύγκριση με άλλα μοντέλα πρόβλεψης βαθιάς και μηχανικής μάθησης για τους δύο χρονικούς ορίζοντες για το ηλιακό πρόβλημα και μόνο για τον ενδοωριαίο για το αιολικό.

Για την πρόβλεψη της ηλεκτρικής ισχύος προερχόμενης από ανεμογεννήτρια το καινοτόμο υπολογιστικό μοντέλο προς διερεύνηση κάνει χρήση της τεχνικής του ολισθαίνοντος παραθύρου. Σε αυτήν την περίπτωση κατά την ίδια διαδικασία το αρχικό σήμα της χρονοσειράς παραγωγής ηλεκτρικής ισχύος αποδομείται σε τέσσερις συνιστώσες κυμάτων. Η μία αποτελεί την κύρια και οι άλλες τρεις, συνιστώσες λευκού θορύβου. Όπως και στο πρόβλημα της φ/β ισχύος κάθε συνιστώσα αποτελεί δεδομένο εισόδου σε ένα συνελκτικό νευρωνικό δίκτυο (CNN), για εκπαίδευση μαζί με μετεωρολογικές παραμέτρους που σχετίζονται περισσότερο με τον άνεμο αυτή την φορά. Όμως το μοντέλο έχει δημιουργηθεί για να βελτιώσει την απόδοση προσαρμοσμένο στην μεγάλη στοχαστική φύση του ανέμου και άρα της ηλεκτρικής

ισχύος προερχόμενης από αιολική. Έτσι, η χρονοσειρά σαρώνεται από ένα 'παράθυρο' το οποίο ορίζει τα δεδομένα εισόδου για εκπαίδευση και τα δεδομένα με τα οποία τροφοδοτείται το μοντέλο, για να κάνει την πρόβλεψη. Όσο η πρόβλεψη έχει επιθυμητό σφάλμα το μοντέλο συνεχίζει να εκπαιδεύεται και να προβλέπει. Στην περίπτωση όμως που το σφάλμα είναι μεγαλύτερο από το επιθυμητό ένα νέο μοντέλο εκπαιδεύεται πάνω στα δεδομένα του τρέχοντος 'παραθύρου' δεδομένων και κάνει πρόβλεψη. Αν η πρόβλεψη του τελευταίου μοντέλου είναι καλύτερη τότε παίρνει την θέση του παλιού μοντέλου πρόβλεψης και η διαδικασία συνεχίζεται με αυτό. Τα δεδομένα εκπαίδευσης αναφέρονται κάθε φορά στην προηγούμενη ώρα και ο ορίζοντας πρόβλεψης είναι ενδοωριαίος.

1.6 Δομή της διπλωματικής εργασίας

Μέχρι στιγμής έχει αναφερθεί η σημαντικότητα των ΑΠΕ σε ένα δίκτυο ισχύος και έχει παρουσιαστεί ο σκοπός και η μεθοδολογία της εργασίας. Στην συνέχεια ακολουθεί, στο Κεφάλαιο 2 η μαθηματική θεμελίωση των μοντέλων πρόβλεψης, όπου γίνεται εκτενής αναφορά στα μαθηματικά εργαλεία που χρησιμοποιήθηκαν για πρόβλεψη και άλλων μεθόδων που σκοπό έχουν να γίνει σύγκριση και αξιολόγηση των αποτελεσμάτων. Στο επόμενο Κεφάλαιο 3 πραγματοποιείται ανάλυση των αποτελεσμάτων. Ξεκινά με την μελέτη περίπτωσης για τα δύο προβλήματα πρόβλεψης, φωτοβολταϊκής ισχύος και ισχύος εξόδου της ανεμογεννήτριας, και έπειτα παρουσιάζονται τα αποτελέσματα για τις δύο περιπτώσεις. Στο τελευταίο Κεφάλαιο 4 υπάρχουν τα συμπεράσματα και προτάσεις για περαιτέρω έρευνα.

ΚΕΦΑΛΑΙΟ 2

2. ΜΑΘΗΜΑΤΙΚΗ ΘΕΜΕΛΙΩΣΗ ΤΟΥ ΜΟΝΤΕΛΟΥ ΠΡΟΒΛΕΨΗΣ

2.1 Διαμόρφωση του προβλήματος της πρόβλεψης παραγωγής

Τα τελευταία χρόνια, έχει προταθεί μεγάλος αριθμός μεθόδων πρόβλεψης. Η τεχνητή νοημοσύνη και τα εργαλεία που προσφέρει, είναι μια πολλά υποσχόμενη επιλογή για εργασίες πρόβλεψης. Η ανάπτυξη ενός αλγορίθμου θα πρέπει να λαμβάνει υπόψη τους ακόλουθους παράγοντες:

- Η δυναμική ανάλυση των χρονοσειρών. Η αλλαγή φορτίου μεταξύ εποχών και η εξάρτησή της από εξωτερικές μεταβλητές όπως οι καιρικές συνθήκες και οι τιμές της αγοράς δίνουν το δυναμικό χαρακτηριστικό της σχέσης μεταξύ δεδομένων εισόδου και εξόδου.
- Προσαρμοστικότητα του μοντέλου πρόβλεψης. Το μοντέλο πρόβλεψης πρέπει να προσαρμόζεται γρήγορα στις νέες συνθήκες που επικρατούν ώστε να δώσει μια ακριβή πρόβλεψη.
- Αξιοπιστία του μοντέλου πρόβλεψης. Το μοντέλο πρέπει να λαμβάνει υπόψη όλους τους πιθανούς παράγοντες που επηρεάζουν το φορτίο παραγωγής. Πρέπει επίσης να πληροί τις αντίστοιχες προϋποθέσεις που περιλαμβάνουν διαφορετικές περιοχές του συστήματος ισχύος, διαφορετικό επίπεδο φόρτισης, χρονική περίοδο και άλλα.

Γενικά, η επιλογή ενός αλγορίθμου για ένα πρόβλημα πρόβλεψης υπό μελέτη λαμβάνει υπόψη τρεις παράγοντες: α) Διαθεσιμότητα, β) ολοκληρωμένη λειτουργία και γ) ευελιξία. Η διαθεσιμότητα αναφέρεται αν ο αλγόριθμος είναι δωρεάν λογισμικό, συνοδεύεται από εμπορικά πακέτα λογισμικού ή απαιτείται κωδικοποίηση εντός ορισμένου χώρου. Η ολοκληρωμένη λειτουργία αναφέρεται στο επίπεδο πολυπλοκότητας. Η ευελιξία προσπαθεί να απαντήσει σε ερωτήσεις όπως "μπορεί ο αλγόριθμος να τροποποιηθεί εύκολα;", "μπορεί ο αλγόριθμος να συνδυαστεί με άλλους;" και άλλα.

2.2 Διακριτός μετασχηματισμός κυματιδίων-Discrete wavelet transformation (DWT)

Η πρόβλεψη της παραγωγής ηλεκτρικής ισχύος αφορά χρονοσειρές δηλαδή σήματα μεταβαλλόμενα στον χρόνο. Σε πολλές περιπτώσεις, η χρονική εξάρτηση των αποτελεσμάτων και των μεταβλητών χαρακτηρίζονται από υψηλή μη γραμμικότητα. Το γεγονός αυτό περιορίζει την απόδοση του αλγορίθμου στην πρόβλεψη. Η μοντελοποίηση χρονοσειρών χρησιμοποιεί τεχνικές για την αφαίρεση του θορύβου και την προσαρμογή των παραγόντων μη γραμμικότητας. Σε μελέτες επεξεργασίας σήματος μια κοινή προσέγγιση είναι η μετατροπή του σήματος από το πεδίο του χρόνου στο πεδίο της συχνότητας. Μια δημοφιλής τεχνική είναι ο Fast Fourier Transformation. Ο μετασχηματισμός αυτός παρέχει στιβαρή ανάλυση συχνότητας στην επεξεργασία αλλά όχι χρονική ανάλυση. Ο μετασχηματισμός κυματιδίων υπερνικά αυτόν τον περιορισμό και παρέχει συνδυασμό πληροφορίας στα δύο πεδία της συχνότητας και του χρόνου.

Ο μετασχηματισμός αναφέρεται στην αποσύνθεση του αρχικού σήματος σε πεπερασμένο αριθμό υποσειρών.. Στη συνέχεια για κάθε υποσειρά, μεμονωμένα, μπορεί να εφαρμοστεί ένας αλγόριθμος πρόβλεψης. Οι μεμονωμένες έξοδοι πρόβλεψης συνδυάζονται για να ανακατασκευάσουν το αρχικό σήμα δηλαδή για την δημιουργία της προβλεπόμενης χρονοσειράς στο πεδίο του χρόνου. Ο μετασχηματισμός κυματιδίων χωρίζεται στον συνεχή (Continuous Wavelet Transform) (CWT) και διακριτό (Discrete Wavelet Transform) (DWT). Έστω $x(t)$ είναι το αρχικό σήμα στο πεδίο του χρόνου. Το βασικό σχέδιο είναι ότι μια συνέλιξη μεταξύ του αρχικού σήματος $x(t)$ και μια συνάρτησης βάσης $\Psi(x)$, που καλείται μητρικό κυματίδιο, και οι μεταφρασμένοι παράγοντες $\Psi_{a,b}$, που αποκαλούνται κυματίδια κόρες, δημιουργούνται. Το αρχικό σήμα πολλαπλασιάζεται με την συνάρτηση βάσης και τα τμήματα που δημιουργούνται, επεξεργάζονται για διάφορες χρονικές περιπτώσεις. Η χρονική διάρκεια της βασικής συνάρτησης αλλάζει όσο αναλύονται μεγαλύτερες συχνότητες. Ο CWT $\Psi(a, b)$ ενός σήματος $x(t)$ δίνεται από:

$$\Psi_{a,b}(t) = \int_{-\infty}^{+\infty} x(t)\Psi_{a,b}^*(t)$$

Όπου $\Psi_{a,b}^*$ είναι ο μιγαδικός συζυγής του $\Psi_{a,b}$ με:

$$\Psi_{a,b} = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-\beta}{a}\right)$$

Όπου a είναι ο συντελεστής κλίμακας και b ο συντελεστής μετάφρασης. Ο συντελεστής κλίμακας ελέγχει την έκταση του κυματιδίου δηλαδή το πλάτος αλλαγής στο χρονικό διάστημα. Ο συντελεστής μετάφρασης χρησιμοποιείται για την μεταφορά της βασικής συνάρτησης γύρω από την χρονική περίπτωση t . Ο συντελεστής αυτός καθορίζει την θέση του μητρικού κυματιδίου στο πεδίο του χρόνου. Ο συντελεστής μετάφρασης παρέχει την χρονική πληροφορία στο CWT. Ο συντελεστής κλίμακας καθορίζει την διάρκεια του μητρικού κυματιδίου και παρέχει την πληροφορία της συχνότητας στο CWT. Κλίμακα και συχνότητα είναι αντίστροφες. Έτσι μικρές κλίμακες ανταποκρίνονται σε υψηλές συχνότητες και το αντίστροφο. Στο αρχικό κυματίδιο οι συντελεστές αρχικοποιούνται ως $a = 1$ και $b = 0$ στην $t = 0$. Στη συνέχεια πολλαπλασιάζεται με το σήμα $x(t)$ και ολοκληρώνεται από $-\infty$ στο $+\infty$.

Το αποτέλεσμα της ολοκλήρωσης πολλαπλασιάζεται με $\frac{1}{\sqrt{a}}$ έτσι ώστε το μετασχηματισμένο σήμα να έχει την ίδια ενέργεια με για της διάφορες τιμές του συντελεστή κλίμακας a . Το αποτέλεσμα του υπολογισμού είναι $\Psi(1,0)$. Επιπροσθέτως η συνάρτηση κυματιδίου μετακινείται δεξιά με $b = b_1$ χρησιμοποιώντας την συνάρτηση $\Psi\left(\frac{t-\beta_1}{a}\right)$ και ο προηγούμενος υπολογισμός χρησιμοποιείται για να παραχθεί η τιμή $\Psi(1,\beta_1)$. Η ίδια διαδικασία επαναλαμβάνεται μέχρι το τέλος του σήματος $x(t)$. Στη συνέχεια η τιμή του a αυξάνεται και η προαναφερθείσα διαδικασία επαναλαμβάνεται για να παραχθεί η $\Psi(a,b)$.

Έτσι το μητρικό κυματίδιο είναι ικανό για την κατασκευή ενός συνόλου από άλλες συναρτήσεις. Αυτές οι συναρτήσεις δημιουργούνται εφαρμόζοντας διαφορετικές τιμές των συντελεστών κλίμακας και μετάφρασης στο μητρικό κυματίδιο. Το αρχικό σήμα λοιπόν εκφράζεται στο πεδίο του χρόνου και αποδομείται σε σύνολα υποσειρών με διαφορετική ανάλυση χρόνου και συχνότητας. Το CWT επιτυγχάνεται με συνεχή εφαρμογή κλίμακας και μετάφρασης στην βασική συνάρτηση. Αυτή η προσέγγιση όμως μπορεί να οδηγήσει σε αυξημένη πλεονάζουσα πληροφορία. Μια

εναλλακτική του CWT, είναι να θεωρηθεί μια συγκεκριμένη κλίμακα. Το DWT $\Psi_{j,n}(t)$ μπορεί να παραχθεί από την εξίσωση του όρου Ψ αντικαθιστώντας τα a και b , με $a = a^{-j}$ και $b = nba^{-j}$. Είναι:

$$\Psi_{j,n}(t) = a^{j/2} \Psi(a^j t - nb)$$

Όπου $j \in Z$ ο συντελεστής κλίμακας και $b \in Z$ ο συντελεστής θέσης. Λαμβάνοντας ως μητρική συνάρτηση κυματιδίων το Daubechies κυματίδιο η παραπάνω εξίσωση γίνεται:

$$\Psi_{j,n}(t) = \frac{1}{2^j} \Psi\left(\frac{t-2^j n}{2^j}\right)$$

Το αρχικό σήμα $x(t)$ εκφράζεται σε διακριτά μορφές $x(n)$ ως:

$$x(n) = \langle x, \Psi_{j,n} \rangle$$

Όπου n είναι το επίπεδο αποδόμησης. Η διακριτή εκδοχή του αρχικού σήματος εκφράζεται σαν σύνολο εσωτερικών γινομένων. Η συνάρτηση Ψ είναι μια υπερπερατή ταλάντωση. Μια ακόμη μη περιοδική υπερπερατή συνάρτηση χρησιμοποιείται και συμβολίζεται με Φ . Ο fast Wavelet Transform χρησιμοποιεί το wavelet ως συνάρτηση κλίμακας, αλλά δύο υπερπερατά και χαμηλοπερατά φίλτρα H και L , αντίστοιχα που ορίζονται ως:

$$H(n) = \frac{1}{\sqrt{2}} \langle \Phi(t/2), \Phi(t-n) \rangle$$

$$L(n) = \frac{1}{\sqrt{2}} \langle \Psi(t/2), \Phi(t-n) \rangle$$

Το Σχήμα 2.1 δείχνει το πολλαπλό επίπεδο αποδόμησης της διαδικασίας. Μπορεί να διακρίνει κανείς ότι ο μετασχηματισμός είναι η εφαρμογή χαμηλοπερατών και υπερπερατών φίλτρων στην συνεχόμενη δειγματοληψία. Έστω A και D να εκφράζουν το χαμηλοπερατό και υπερπερατό φίλτρο αντίστοιχα. Το σήμα $x(t)$ αποδομείται σε σύνολα χαμηλοπερατών (D_1, D_2, \dots, D_n) και σύνολα υπερπερατών σημάτων (A_1, A_2, \dots, A_n) . Είναι:

$$D = (x * g) \downarrow 2$$

$$A = (x * h) \downarrow 2$$

Η αποδόμηση συνεχίζει μετακινώντας την κλίμακα j στο $j - 1$ χρησιμοποιώντας

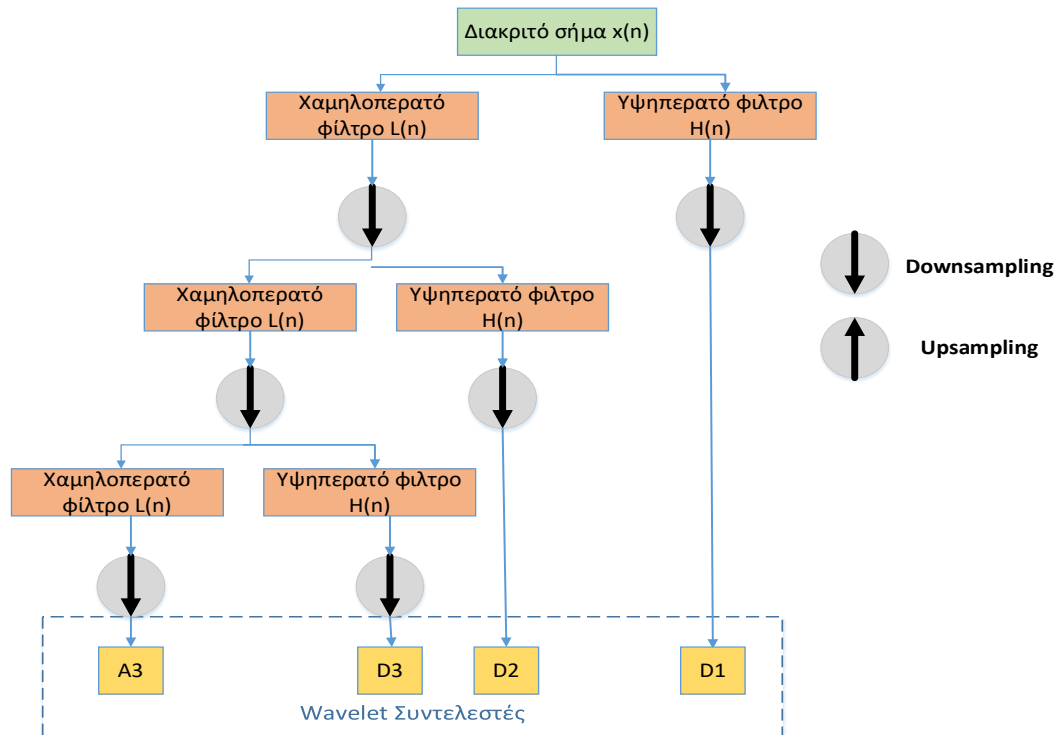
φίλτρα και υποδειματοποίηση. Είναι:

$$D_{j-1} = (A_j * g) \downarrow 2$$

$$A_{j-1} = (A_j * h) \downarrow 2$$

Το χαμηλής συχνότητας υποσήμα καλείται ως προσεγγιστικός παράγοντας και το υψηλής συχνότητας καλείται λεπτομερής παράγοντας. Όταν το επίπεδο αποδόμησης αυξάνεται, η πυκνότητα της διασποράς του σήματος μειώνεται.

Το Daubechies κυματίδιο σε επίπεδο 4 χρησιμοποιείται σε ένα συγκεκριμένο μοντέλο. Αυτό αποτελείται από 4 φίλτρα: αποδόμηση χαμηλοπερατό, αποδόμηση υψηπερατό, επαναδημιουργία χαμηλοπερατό και επαναδημιουργία υψηπερατό φίλτρο. Η αρχική χρονοσειρά χωρίζεται με διαδοχικές αποδομήσεις σε χαμηλότερης συχνότητας παράγοντες. Το Σχήμα 2.1 δείχνει ένα παράδειγμα από ένα αρχικό σήμα και τις υποσειρές D_1, D_2, D_3 και A_3 . Η αρχική χρονοσειρά αναφέρεται στην παραγωγή από 1/1/2017 ως και 31/12/2018 για τα δεδομένα εκπαίδευσης και για τα δύο προβλήματα ηλιακής και αιολικής ισχύος. Άρα και για τα δύο προβλήματα ακολουθείται η ίδια διαδικασία αποδόμησης του αρχικού σήματος σε 4 συνιστώσες κυματιδίων με χαμηλοπερατά και υψηπερατά φίλτρα.



Σχήμα 2.1 Διαδικασία DWT

Ο Inverse Discrete Wavelet Transform (IDWT) είναι η διαδικασία ανακατασκευής του αρχικού σήματος. Αυτό συμβαίνει αντιστρέφοντας διαδικασία φιλτραρίσματος με κυματίδια και υποδειγματοποιώντας τα επίπεδα. Είναι:

$$A_{j+1} = (A_j \uparrow 2) * h[-n] + (D_j \uparrow 2) * g[-n]$$

Το επανακατασκευασμένο σήμα $x(t)$ είναι:

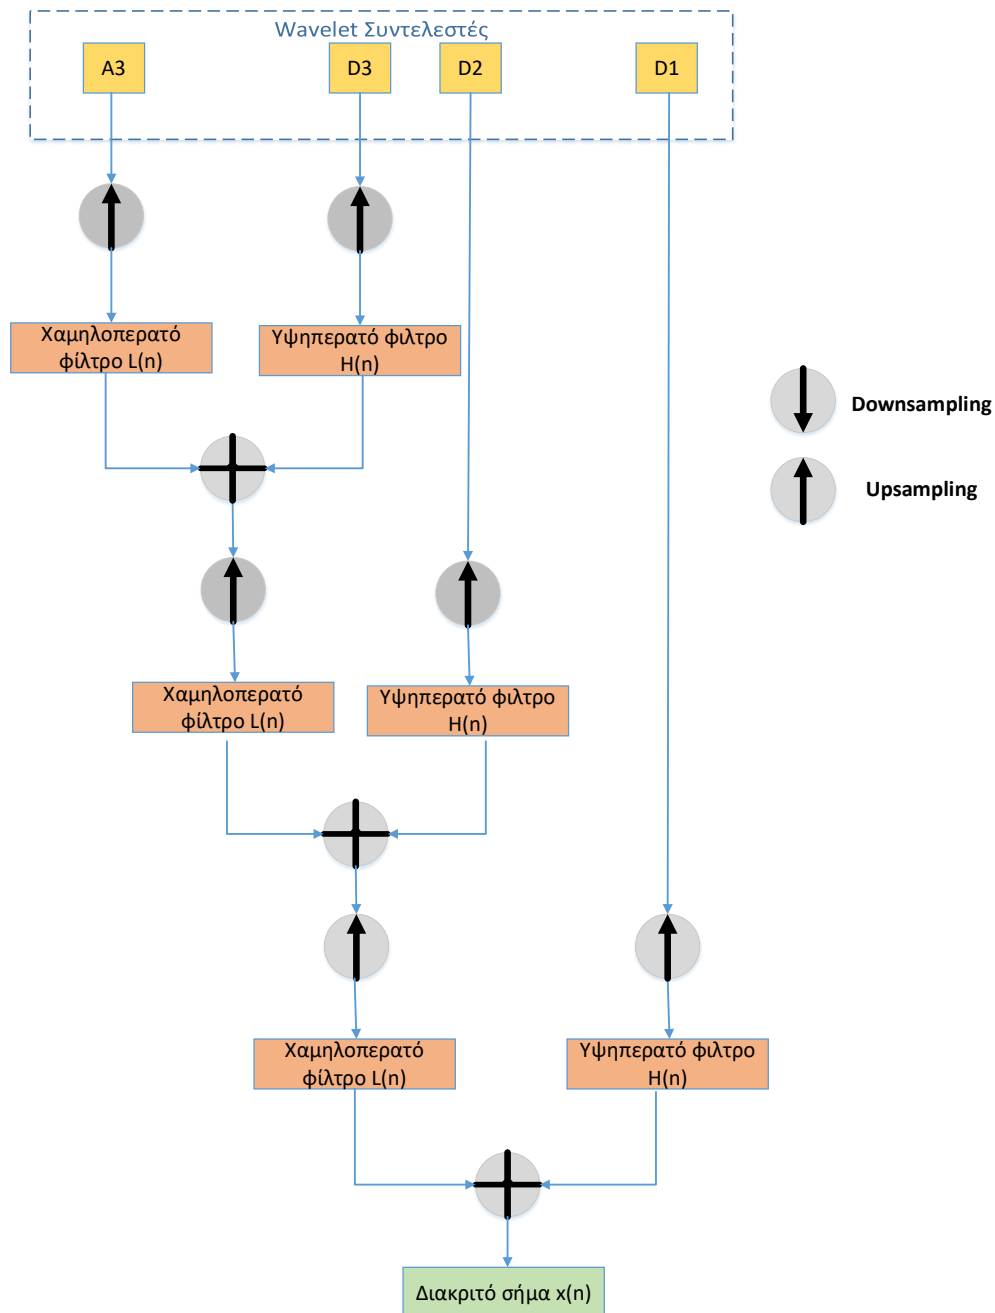
$$x(t) = D_1 + D_2 + D_3 + A_3$$

Το DWT εφαρμόζεται σε ιστορικά παραγωγής που εξυπηρετούν ως εισόδοι. Έστω $x_{DWTi}(t)$ και $x_{DWTi}(t + q)$ είναι ο συντελεστής του wavelet του $x_i(t + q)$ και $x_i(t)$ αντίστοιχα. Όπου x_i μία εκ των μεταβλητών εισαγωγής και q μεταβλητή που αναφέρεται στο χρονικό ιστορικό. Το σύνολο των δεδομένων εκπαίδευσης του μοντέλου αποτελείται από ζεύγη από μοτίβα εκπαίδευσης $(x_m^{Train}, y_m^{Train})$, $m = 1, 2, \dots, M$ όπου m υποδεικνύει το m - στο μοτίβο εκπαίδευσης και M είναι το σύνολο των μοτίβων εκπαίδευσης. Τα μοτίβα εκπαίδευσης αποτελούνται από εισόδους και εξόδους. Η έξοδος ισχύος είτε φ/β είτε ανεμογεννήτριας την χρονική στιγμή $t + 1$ εξυπηρετεί σαν στόχος του μοντέλου πρόβλεψης, ή ως επιθυμητή έξοδος. Τα δύο μοντέλα έχουν διαφορετική περίοδο δειγματοληψίας. Η περίοδος Δt είναι 15 λεπτά για τα φ/β και 10 λεπτά για την πρόβλεψη που αφορά ηλεκτρική ισχύ προερχόμενη από αιολική.

$$y_m^{Train} = P(t + 1)_m^{Train}$$

Δίνεται δηλαδή ως στόχος του μοντέλου εκπαίδευσης η έξοδος του φωτοβολταϊκού ή της ανεμογεννήτριας την επόμενη χρονική στιγμή. Αφού η περίοδος δειγματοληψίας για το φωτοβολταϊκό πρόβλημα είναι 15 λεπτά της ώρας ο στόχος του μοντέλου αναφέρεται 15 λεπτά μπροστά από την παρούσα χρονική στιγμή. Αντίστοιχα αφού η περίοδος δειγματοληψίας είναι 10 λεπτά για το πρόβλημα της πρόβλεψης ηλεκτρικής ισχύος από αιολική ο στόχος αναφέρεται 10 λεπτά μπροστά. Επομένως και οι προβλέψεις αφού δοθούν τα δεδομένα ελέγχου ως είσοδος θα αναφέρονται 15 λεπτά μπροστά για την έξοδος ισχύος από φωτοβολταϊκό και 10 λεπτά μπροστά για την έξοδο ηλεκτρικής ισχύος που προέρχεται από την ανεμογεννήτρια.

Το Σχήμα 2.2 δείχνει την γενική δομή ενός μοντέλου. Το μοντέλο εφαρμόζεται ξεχωριστά για τις D_1, D_2, D_3 και A_3 . Στη συνέχεια, με χρήση της επόμενης εξίσωσης εκλαμβάνεται η προβλεπόμενη χρονοσειρά. Μετά την αποπεράτωση της εκπαίδευσης, η επικυρωποίηση του μοντέλου πραγματοποιείται χρησιμοποιώντας ένα test σύνολο δεδομένων. Σε αυτή τη φάση, οι έξοδοι του συνόλου test $y_p^{Test}, p = 1, 2, \dots, P$, όπου p υποδεικνύει το P – στο μοτίβο του συνόλου test και P είναι το



Σχήμα 2.2 Διαδικασία IDWT

πλήθος των μοτίβων του συνόλου test που δεν είναι γνωστά. Η έξοδος y_p^{Test} αναφέρεται στο στόχο εξόδου της παραγόμενης ισχύος $P(t + 1)_p^{Test}$:

$$y_p^{Test} = P(t + 1)_p^{Test}$$

2.3 Convolutional Neural Network

Το CNN που αναπτύσσεται για την προβλεπόμενη ζήτηση αποτελείται από 1 στρώμα, 2 συνελκτικά στρώματα, 1 συγκεντρωτικό στρώμα, 1 πυκνό στρώμα και 1 στρώμα εξόδου. Το στρώμα εισόδου λαμβάνει τα δεδομένα εισόδου που παρουσιάζονται σε ένα προηγούμενο τμήμα. Το συνελκτικό και συγκεντρωτικό στρώμα είναι υπεύθυνα για την εξαγωγή των μη γραμμικών χαρακτηριστικών της χρονικής σειράς του φορτίου. Το συνελκτικό στρώμα εξαγει το τοπικό χαρακτηριστικό των δεδομένων. Το στρώμα εισόδου απασχολεί τα δεδομένα σε διάσταση 2D. Αυτό σημαίνει ότι δεν απασχολούνται ως χρονικές σειρές αλλά ως τανυστές. Η λειτουργία του CNN περιλαμβάνει μια προωθητική και μια οπισθοδρομική διάδοση. Η προωθητική διάδοση λαμβάνει τα δεδομένα εισόδου, κάνει τους σχετικούς υπολογισμούς στα διάφορα στρώματα και παράγει μια έξοδο. Το σφάλμα, δηλαδή, στη διαφορά ανάμεσα στην επιθυμητή (δηλ. εκπαίδευση) έξοδο και στην πραγματική έξοδο είναι ο υπολογισμός. Έπειτα, για να ελαχιστοποιήσουμε το σφάλμα, η οπισθοδρομική διάδοση αναβαθμίζει τις παραμέτρους σε διάφορα στρώματα όπως βάρη, πολώσεις και άλλα. Τα φίλτρα απεικονίζουν συγκεκριμένα χαρακτηριστικά της εισόδου. Τα δεδομένα μεταμορφώνονται σε τανυστές, δομές δεδομένων που έχουν ιδιότητες μήκους, πλάτους και ύψους. Έστω $l = 1, 2, \dots, L$ ο αριθμός των στρωμάτων στο δίκτυο, $j = 1, 2, \dots, J$ ο αριθμός των χαρτών χαρακτηριστικών και $i = 1, 2, \dots, I$ ο αριθμός εισόδων των διαφόρων στρωμάτων. Στην προωθημένη διάδοση, το συνελκτικό στρώμα εκτελεί τη συνελκτική λειτουργία ανάμεσα στην είσοδο του προηγούμενου στρώματος και το βάρος του συνελκτικού στρώματος. Έστω y_j^l η j -th είσοδος του l -th στρώματος. Δίνεται από την ακόλουθη εξίσωση:

$$y_j^l = f \left(\sum_{i \in N_j} x_i^{l-1} * k_{ij}^l + b_j^l \right)$$

Όπου $*$ υποδηλώνει τους συνελκτικούς τελεστές, N_j είναι η τοποθέτηση των χαρτών χαρακτηριστικών εισόδου, x_i^{l-1} είναι η i - th είσοδος του $(l - 1) - th$ στρώματος,

k_{ij}^l είναι ο πυρήνας της μήτρας βάρους του k_{ij}^l ου στρώματος, b_j^l είναι οι πολώσεις μήτρας του l ου στρώματος και $f(\cdot)$ είναι η συνάρτηση ενεργοποίησης. Η συνάρτηση ενεργοποίησης είναι η γραμμική μονάδα ανόρθωσης (ReLU), $f(x)$, η οποία εκφράζεται ως:

$$f(x) = \max(0, x)$$

Τα συγκεντρωτικά στρώματα μειώνουν τις διαστάσεις των δεδομένων συνδυάζοντας τις εξόδους των νευρωνικών ομάδων από ένα στρώμα σε ένα μοναδικό νευρώνα στο επόμενο στρώμα. Ένα συγκεντρωτικό στρώμα λειτουργεί πάνω σε κάθε χάρτη χαρακτηριστικών ξεχωριστά για να δημιουργήσει μια νέα τοποθέτηση στον ίδιο αριθμό συγκεντρωμένων χαρτών χαρακτηριστικών. Παρέχει ένα φιλτράρισμα στους χάρτες χαρακτηριστικών. Η έξοδος του συγκεντρωτικού στρώματος y_j^l δίνεται από:

$$y_j^l = f(\beta_j^l \cdot \text{down}(x_j^{l-1}) + c_j^l)$$

όπου $\text{down}(\cdot)$ είναι η συνάρτηση μείωσης μεγέθους και β_j^l και c_j^l είναι οι μήτρες βάρους. Το είδος της συνάρτησης μείωσης μεγέθους είναι MaxPooling το οποίο υπολογίζει τη μέγιστη τιμή του χαρακτηριστικού.

$$\text{down}(x_j^{l-1}) = \max(x_{ijh})$$

όπου x_{ijh} είναι τανυστής με i μήκος, j πλάτος και h ύψος.

Το βάρος και οι πολώσεις αρχικοποιούνται τυχαία στην προωθημένη διάδοση. Η οπισθοδρομική διάδοση τοποθετεί συγκεκριμένες τιμές σε αυτές τις παραμέτρους ώστε να βελτιστοποιήσει τη δομή του δικτύου. Τα συμβατικά ANN εκπαιδεύονται περισσότερο με τον αλγόριθμο στοχαστικής κλίσης καθόδου (SGD). Έστω θ η παράμετρος για την αναβάθμιση, δηλ., βάρη και πολώσεις. Ο διδακτικός κανόνας αναβάθμισης της θ που προσαρμόζεται από τον αλγόριθμο SGD είναι:

$$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta} J(\theta; x^{Train}, y^{Train})$$

όπου θ_{t+1} είναι η παράμετρος της στην εποχή $t + 1$, θ_t είναι η παράμετρος στην εποχή t , η είναι ο διδακτικός ρυθμός, J είναι η αντικειμενική συνάρτηση, x^{Train} και y^{Train} αναφέρονται στην είσοδο και στην έξοδο ενός τυχαίου μοτίβου εκπαίδευσης. Η αντικειμενική συνάρτηση αναφέρεται στο μέσο τετραγωνικό σφάλμα:

$$J = \frac{1}{I} \sum_{i=1}^I \sum_{j \in h_t} f(W_{hx}x_t + W_{hh}h_{t-1} + b_h) = 1 (z_j^i - y_j^i)^2$$

όπου z_j^i είναι η επιθυμητή έξοδος.

Αντί για τον αλγόριθμο SGD, το CNN χρησιμοποιεί τον εκπαιδευτικό αλγόριθμο προσαρμοστικής στιγμιαίας εκτίμησης (ADAM). Ο κανόνας αναβάθμισης εκφράζεται ως:

$$\theta_{t+1} = \theta_t - \frac{\eta \cdot \widehat{m}_t}{\sqrt{\widehat{v}_t + \varepsilon}}$$

όπου:

$$\widehat{m}_t = \frac{m_t}{1 - \beta_1^t}$$

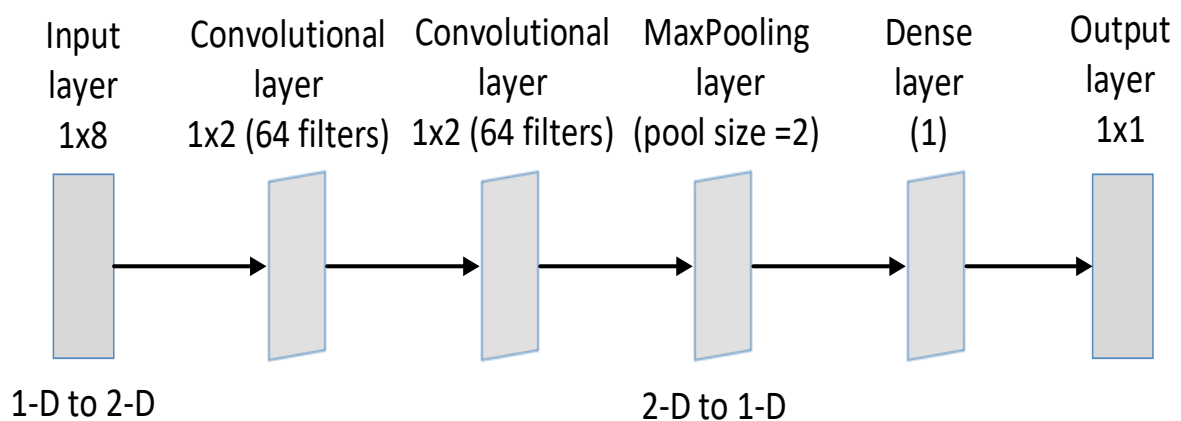
$$\widehat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

$$m_t = (1 - \beta_1)g_t + \beta_1 m_{t-1}$$

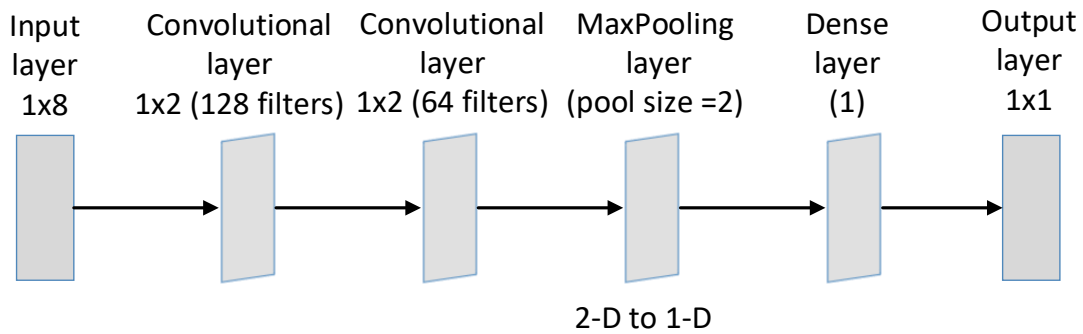
$$v_t = (1 - \beta_2)g_t^2 + \beta_2 v_{t-1}$$

όπου m_t είναι το μέσο της εποχής t , v_t είναι η δίχως κέντρο απόκλιση στην εποχή t , ε είναι μια σταθερά, β_1 και β_2 είναι πολώσεις και $g = \nabla J(\theta_{t,i})$. Οι τιμές έχουν θεωρηθεί: $\eta = 10^{-3}$, $\beta_1 = 0.90$, $\beta_2 = 0.99$ και $\varepsilon = 10^{-8}$ [14].

Δημιουργήθηκαν δύο αρχιτεκτονικές δικτύου CNN για την πρόβλεψη οι οποίες παρουσιάζονται στα Σχήματα 2.3 και 2.4.



Σχήμα 2.3 Αρχιτεκτονική CNN για πρόβλεψη ϕ/β



Σχήμα 2.4 Αρχιτεκτονική CNN για πρόβλεψη α/γ

2.4 Adam Optimizer

Για την πρόβλεψη ελέγχθηκαν δύο βελτιστοποιητές ο Adam και ο Stochastic Gradient Descent (SGD). Με την μέθοδο του trial and error φάνηκε ότι ο Adam παρείχε καλύτερα αποτελέσματα οπότε αυτός περιγράφεται στην συνέχεια.

Ο Adam είναι ένας βελτιστοποιητής που εκμεταλλεύεται τα οφέλη των ροπών και της μεθόδου RMSprop, χρησιμοποιώντας εκτιμήσεις της πρώτης και της δεύτερης ροπής.

Τα βάρη ενημερώνονται με την ακόλουθη εξίσωση:

$$w_{t+1} = w_t - \frac{\alpha}{\sqrt{\hat{v}_t} + \epsilon} \cdot \hat{m}_t$$

όπου ϵ είναι μια σταθερή τιμή που αποτρέπει τη μηδενική διαίρεση και είναι οι διορθώσεις θορύβου και δηλώνονται ως:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

όπου m είναι ο εκθετικός κινούμενος μέσος όρος των κλίσεων και v είναι ο εκθετικός κινούμενος μέσος όρος των τετραγωνικών βαθμίδων που υποδηλώνονται ως:

$$m_t = \beta_1 v_{t-1} + (1 - \beta_1) \left(\frac{\partial L}{\partial w_t} \right)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) \left(\frac{\partial L}{\partial w_t} \right)^2$$

Για την λειτουργία του χρησιμοποιήθηκαν οι προκαθορισμένες τιμές του βελτιστοποιητή Adam χωρίς να γίνει κάποια περαιτέρω ανάλυση, οι οποίες για το Tensorflow έχουν ως εξής:

$$\text{learning rate} = 0.001$$

$$\text{beta1} = 0.9$$

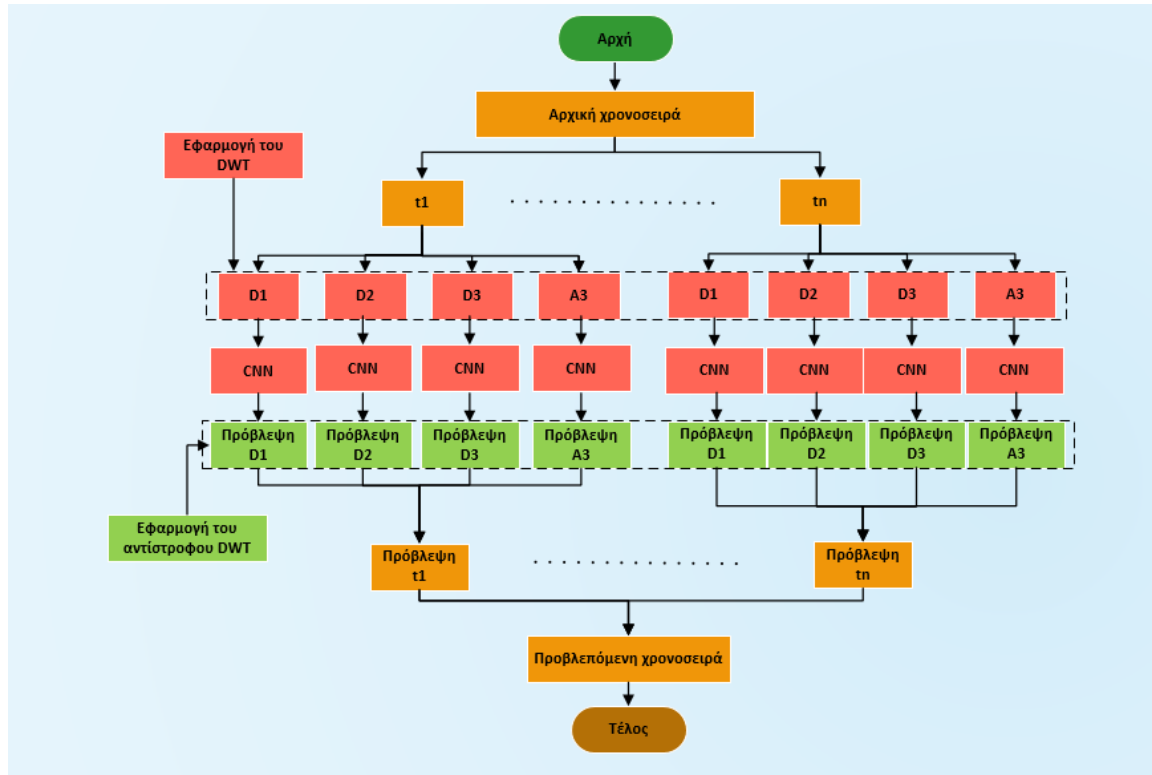
$$\text{beta2} = 0.999$$

$$\text{epsilon} = 10^{-8}$$

2.5 Προτεινόμενα Μοντέλα

Για την πραγματοποίηση της πρόβλεψης μελετήθηκε το μοντέλο συνελκτικού νευρωνικού δικτύου (CNN). Αυτού του τύπου τα νευρωνικά δίκτυα ανήκουν στην κατηγορία των δικτύων βαθιάς μάθησης και έχουν χρησιμοποιηθεί κατά κύριο λόγο στην ανάλυση εικόνας και βίντεο αλλά και στην πρόβλεψη χρονοσειρών που σχετίζονται με οικονομικά μεγέθη όπως μετοχές χρηματιστηρίου. Αποτελείται συνήθως από πολλαπλά στρώματα νευρώνων και αυτού του τύπου τα δίκτυα έχουν δημιουργηθεί με βάση την βιολογική λειτουργία των νευρώνων και την σύνδεση αυτών στην διαδικασία της όρασης.

Με σκοπό την αφαίρεση του θορύβου από την χρονοσειρά ηλεκτρικής ισχύος χρησιμοποιήθηκε ο διακριτός μετασχηματισμός κυματιδίων. Έτσι, το συνελκτικό νευρωνικό δίκτυο και στο φωτοβολταϊκό αλλά και στο αιολικό πρόβλημα τροφοδοτείται από 4 συνιστώσες που αποτελούν χρονοσειρές που αναφέρονται στην ισχύ εξόδου. Η μία είναι κύρια συνιστώσα και οι άλλες συνιστώσες λευκού θορύβου. Έτσι στην χρονοσειρά για τον μέγεθος της ηλεκτρικής ισχύος γίνεται εφαρμογή του διακριτού μετασχηματισμού κυματιδίων και αποδόμηση του σήματος. Για κάθε συνιστώσα και χρονική στιγμή γίνεται ξεχωριστά πρόβλεψη από ένα ταυτόσημο συνελκτικό νευρωνικό δίκτυο. Το τελευταίο βήμα είναι η ανασύνθεση του αρχικού σήματος με την εφαρμογή του αντίστροφου διακριτού μετασχηματισμού κυματιδίων ώστε να προκύψει η πρόβλεψη του μεγέθους της παραγόμενης ηλεκτρικής ισχύος. Το Σχήμα 2.5 αποσαφηνίζει την αρχιτεκτονική και την διαδικασία που περιγράφεται.



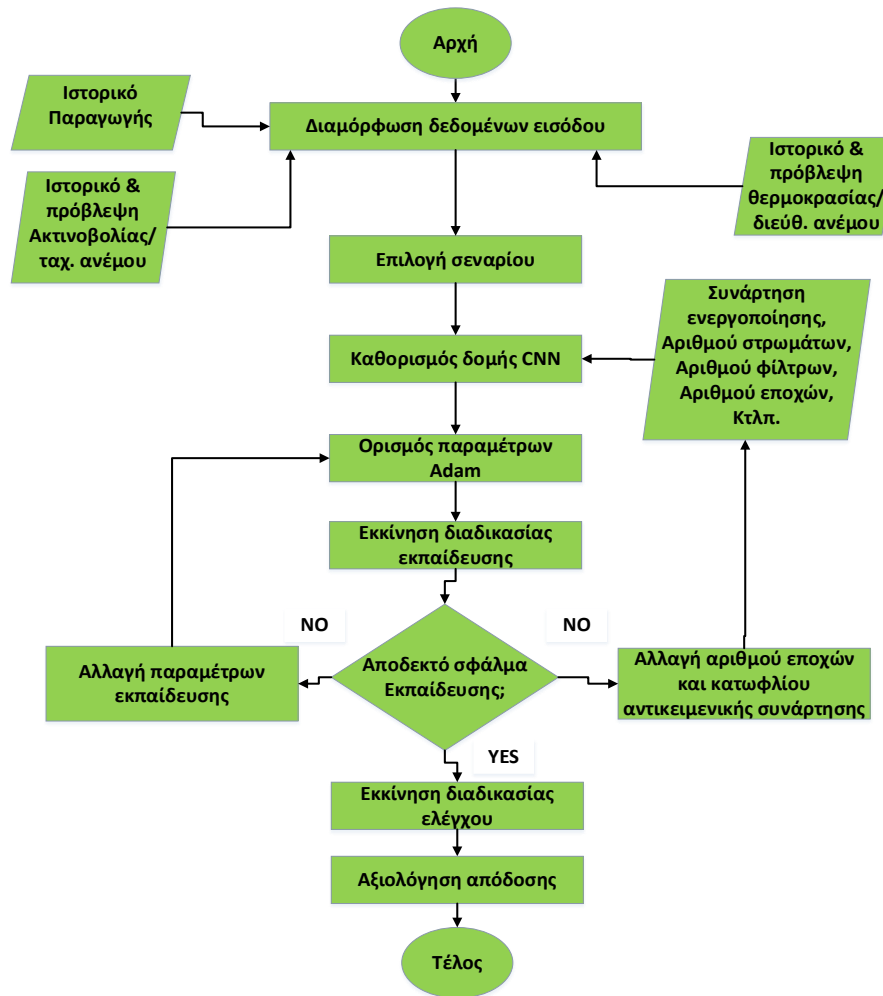
Σχήμα 2.5 Αποδόμηση και ανακατασκευή σήματος των προτεινόμενων μοντέλων

2.5.1 Μεταβλητές μοντέλου φ/β παραγωγής

Οι μεταβλητές του μοντέλου όσον αφορά την ηλεκτρική ισχύ προερχόμενη από φ/β και α/γ είναι οι παρακάτω:

- Epochs=200
- Βελτιστοποιητής Adam
- Batch size=64
- Συνάρτηση ενεργοποίησης ReLU
- Loss=mse

Αρχικά επιλέγονται και διαμορφώνονται κατάλληλα οι μεταβλητές εισόδου. Επιλέγεται το σενάριο πρόβλεψης με βάση τον χρονικό ορίζοντα στον οποίο αναφέρεται και καθορίζεται μια δομή πρόβλεψης CNN. Έπειτα ορίζονται οι παράμετροι του βελτιστοποιητή και ξεκινά η διαδικασία εκπαίδευσης. Αν το σφάλμα δεν είναι αποδεκτό πραγματοποιούνται αλλαγές στον βελτιστοποιητή ή στην αρχιτεκτονική του νευρωνικού δικτύου. Αν το σφάλμα είναι αποδεκτό ξεκινά η διαδικασία με τα δεδομένα ελέγχου και αξιολογείται η απόδοση του μοντέλου.



Σχήμα 2.6 Διάγραμμα ροής για την φ/β και αιολική πρόβλεψη χωρίς ολισθαίνον παράθυρο

2.5.2 Αλγόριθμος πρόβλεψης για την ηλεκτρική ισχύ προερχόμενη από την α/γ

Ειδικά για την πρόβλεψη της ηλεκτρικής ισχύος από α/γ χρησιμοποιήθηκε η μέθοδος sliding window για την τροφοδότηση του μοντέλου με δεδομένα. Το μοντέλο τροφοδοτείται από σύνολα δεδομένων ή «παράθυρα» με τις μεταβλητές εισόδου και εξόδου να έχουν περιγραφεί ως μαθηματικό πρότυπο και αναφέρονται παρακάτω. Μετά από ανάλυση συσχέτισης του ιστορικού αποφασίστηκε τα δεδομένα εισόδου στο σύνολο του παραθύρου να είναι τα ακόλουθα:

- Παραγωγή t έως $t-4$
- Παραγωγή $t-1$ έως $t-5$
- Ταχύτητα ανέμου $t+1$ έως $t-3$ (Πρόβλεψη)

- Ταχύτητα ανέμου t έως $t-4$
- Ταχύτητα ανέμου $t-1$ έως $t-5$
- Διεύθυνση ανέμου $t+1$ έως $t-3$ (Πρόβλεψη)
- Διεύθυνση ανέμου t έως $t-3$
- Διεύθυνση ανέμου $t-1$ έως $t-5$

Ο αλγόριθμος πρόβλεψης προσαρμόζεται κάθε φορά σαρώνοντας την χρονοσειρά ανά παράθυρο. Η αποσαφήνιση της μεθόδου που χρησιμοποιήθηκε φαίνεται στο λογικό διάγραμμα Σχήμα 2.7.

Το αποδεκτό σφάλμα ορίστηκε 20% για την συνιστώσα A3 και 50% για τις συνιστώσες λευκού θορύβου D1, D2, D3.

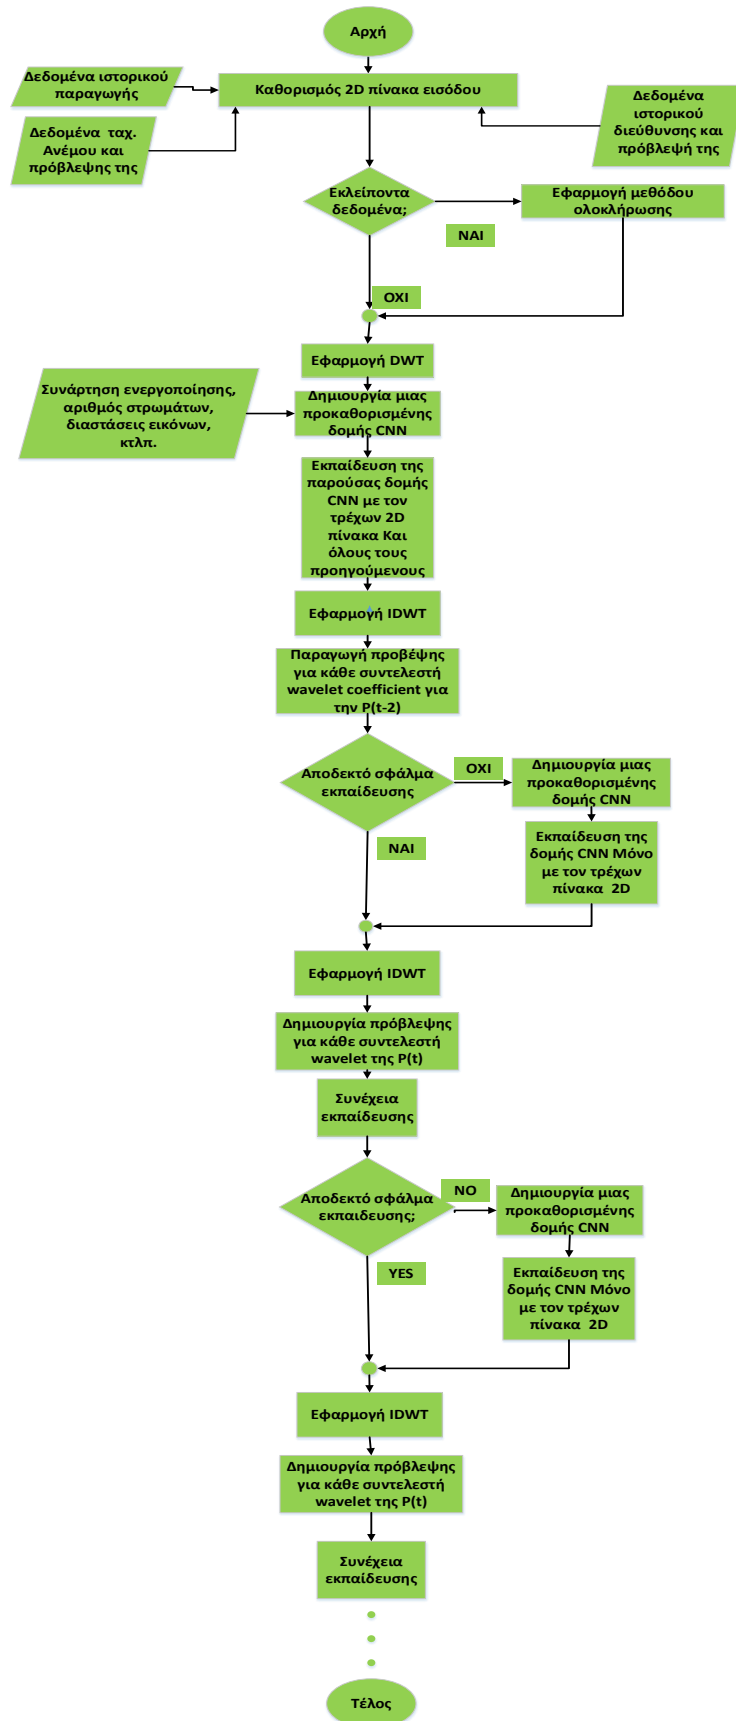
Η παράμετρος των εποχών για το πρώτο μοντέλο που δημιουργείται είναι ίση με 40 και συνεχίζει να είναι ίση με 40 για κάθε παράθυρο δεδομένων με το οποίο τροφοδοτείται το μοντέλο όταν το σφάλμα πρόβλεψης είναι μικρότερο από 20% ή όταν το σφάλμα πρόβλεψης είναι μικρότερο του νεοεκπαιδευθέντου μοντέλου, άρα το μοντέλο κρατείται για συνέχιση της διαδικασίας.

Η παράμετρος των εποχών για το νέο στην εκπαίδευση μοντέλο πρόβλεψης είναι ίση με 5 και με αυτήν την παράμετρο ίση με 5 πραγματοποιείται και από την πρώτη του πρόβλεψη.

Η παράμετρος είναι $batch\ size = 64$, ο βελτιστοποιητής Adam, συνάρτηση ενεργοποίησης ReLu και $loss=mse$ σε όλα τα στρώματα.

Η αρχιτεκτονική το μοντέλου όσον αφορά τα φίλτρα και τους κόμβους αναφέρεται στην παράγραφο που περιγράφει το CNN Παράγραφος 2.3.

Οι παραπάνω παράμετροι προέκυψαν με την μέθοδο του trial and error σε συνάρτηση με το υπολογιστικό κόστος ώστε να υλοποιείται εντός του 12ώρου που είναι η διαθέσιμη ώρα στην πλατφόρμα Google Colab και για TPU υπολογιστική μονάδα.



Σχήμα 2.7 Λογικό διάγραμμα ροής αλγορίθμου επίλυσης για την ανεμογεννήτρια

2.6 Λοιπά Μοντέλα πρόβλεψης

2.6.1 Long Short-Term Memory

Η LSTM χρησιμοποιήθηκε ως δομή βαθιάς μάθησης στο tensorflow και πραγματοποιήθηκαν πρόβλεψης με σκοπό την σύγκριση των αποτελεσμάτων της CNN.


Η LSTM είναι μια αρχιτεκτονική RNN η οποία σχεδιάστηκε για να προσεγγίσει και να διαμορφώσει τις χρονικές ακολουθίες και τη μεγάλη ποικιλία των εξαρτήσεων με μεγαλύτερη ακρίβεια από άλλα είδη RNN. Η έννοια των RNN είναι ότι χρησιμοποιούν διαδοχικές πληροφορίες. Σε ένα συμβατικό νευρωνικό δίκτυο προσωτροφοδότησης (FFNN), η είσοδος και η έξοδος είναι ανεξάρτητες μεταξύ τους. Η επαναληπτική λειτουργία έγκειται στο γεγονός ότι μια RNN εκτελεί την ίδια διαδικασία για κάθε στοιχείο μιας αλληλουχίας όπου η είσοδος εξαρτάται από προηγούμενους υπολογισμούς. Οι RNN έχουν μνήμη που συγκεντρώνει πληροφορίες για το τι έχει υπολογιστεί μέχρι στιγμής, δηλαδή σε μια συγκεκριμένη χρονική κατάσταση. Αυτό σημαίνει ότι μπορούν να ερευνούν τις χρονικές σχέσεις. Το διάγραμμα 5 παρουσιάζει μια RNN που εκτυλίσσεται σε ένα πλήρες δίκτυο. Η εκτύλιξη απεικονίζει το νευρωνικό δίκτυο ως μια πλήρη αλληλουχία κρυφών μονάδων απλής δομής. Έστω $x = \{x_1, x_2, \dots, x_t\}$ διάνυσμα που απεικονίζει τις χρονικές σειρές, το x_t απεικονίζει την είσοδο σε χρονική στιγμή t . Η RNN υπολογίζει τις αλληλουχίες κρυφής κατάστασης $h = \{h_1, h_2, \dots, h_t\}$, όπου h_t απεικονίζει την κρυφή κατάσταση σε χρονική στιγμή t και στην πραγματικότητα είναι η μνήμη του δικτύου. Το τελευταίο υπολογίζεται βασισμένο στην προηγούμενη κρυφή κατάσταση h_{t-1} και στην είσοδο x_t :

$$h_t = f(W_{hx}x_t + W_{hh}h_{t-1} + b_h)$$

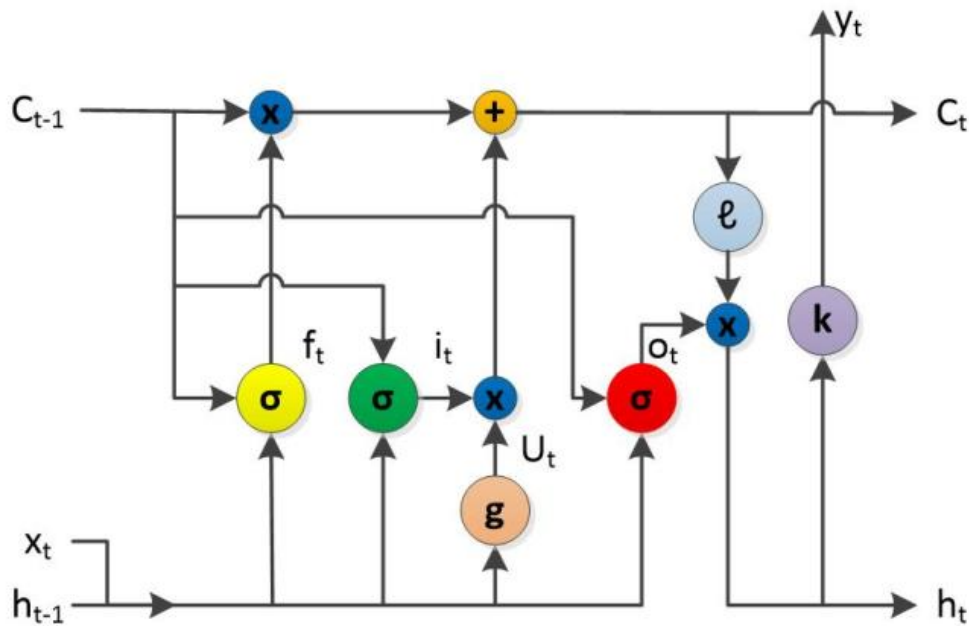
όπου W_{hx} και W_{hh} αναφέρονται στις μήτρες βάρους στην είσοδο/κρυφή και κρυφές/κρυφές αντίστοιχα και b_h είναι η πόλωση του κρυφού στρώματος. Η συνάρτηση ενεργοποίησης f είναι συνήθως μη γραμμική όπως μια απόλυτη γραμμική μονάδα ή σιγμοειδής εφαπτομένη. Η έξοδος y_t σε χρονική στιγμή t εκφράζεται ως:

$$y_t = g(W_{hy}h_t + b_y)$$

όπου g είναι η συνάρτηση ενεργοποίησης του στρώματος εξόδου, W_{hy} είναι η κρυφή/έξοδος μήτρας βάρους και b_y είναι η πόλωση του στρώματος εξόδου. Η εκπαιδευτική διαδικασία μιας RNN είναι παρόμοια με αυτή του FFNN. Ο αλγόριθμος ανάστροφης διάδοσης χρησιμοποιείται, αλλά σε μια τροποποιημένη έκδοση, δηλαδή η κλίση της κάθε εισόδου εξαρτάται όχι μόνο από τους υπολογισμούς στην τρέχουσα χρονική περίσταση, αλλά και από τις προηγούμενες χρονικές περιστάσεις [38]. Η δομή της LSTM δίνεται στο διάγραμμα 6. Οι LSTM δεν παρουσιάζουν ουσιώδεις διαφορές στην αρχιτεκτονική τους σε σχέση με αυτήν στις RNN. Ωστόσο, χρησιμοποιούν μια διαφορετική συνάρτηση για να υπολογίσουν την κρυφή κατάσταση. Η μνήμη στην LSTM ονομάζεται κελί και λαμβάνει εισόδους όπως h_{t-1} και x_t . Εσωτερικά, το κελί καθορίζει τι θα κρατήσει και τι θα σβήσει από τη μνήμη. Έπειτα, συνδυάζουν την προηγούμενη κατάσταση, την τρέχουσα μνήμη και την είσοδο.



Σχήμα 2.8 Εκτύλιξη της RNN [107]



Σχήμα 2.9 Δομή της LSTM [107]

Μια περιοχή κελιών αποτελείται από μια πύλη εισόδου i , μια forget πύλη f , ένα κελί αυτοσυνδεδεμένης μνήμης C και μια πύλη εξόδου o . Ονομάζονται πύλες επειδή η σιγμοειδής συνάρτηση συμπιέζει τις τιμές αυτών των διανυσμάτων ανάμεσα στο 0 και 1 και πολλαπλασιάζοντας τις με ένα άλλο διάνυσμα, είναι εφικτό να ελέγξουμε σε τι βαθμό το διάνυσμα αυτό θα επηρεάσει την έξοδο. Η πύλη εισόδου καθορίζει τη ποσότητα νέας υπολογισμένης κατάστασης για την τρέχουσα είσοδο απαιτείται να περάσει. Η πύλη εισόδου ελέγχει την είσοδο των ενεργοποιήσεων στη μνήμη του κελιού. Η forget πύλη καθορίζει τη ποσότητα της προηγούμενης κατάστασης θα περάσει και τέλος, η πύλη εξόδου καθορίζει την ποσότητα της εσωτερικής κατάστασης που απαιτείται για να εξέλθει από το δίκτυο. Όλες οι πύλες έχουν τις ίδιες διαστάσεις, δηλαδή έχουν το ίδιο μέγεθος κρυφών καταστάσεων. Ο όρος g υποδηλώνει την υποψήφια κρυφή κατάσταση η οποία υπολογίζεται χρησιμοποιώντας την είσοδο της τρέχουσας χρονικής περιόδου και την κρυφή κατάσταση της προηγούμενης χρονικής περιόδου. Η μνήμη C είναι ένας συνδυασμός της εσωτερικής μνήμης από την προηγούμενη χρονική περίοδο που πολλαπλασιάζεται από τη forget πύλη και τη νέα κρυφή κατάσταση g που πολλαπλασιάζεται από την πύλη εισόδου. Πρώτα απ' όλα, η forget πύλη εφαρμόζεται ώστε να αποκωδικοποιήσουμε ποιες πληροφορίες θα κρατηθούν ή θα

απορριφθούν. Η έξοδος της forget πύλης σε μια χρονική στιγμή t και f λαμβάνει τιμές ανάμεσα σε 0 και 1 και υπολογίζεται ως:

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

όπου σ είναι η σιγμοειδής συνάρτηση ενεργοποίησης της forget πύλης, W_{fx} , W_{fh} και W_{fc} είναι οι μήτρες βάρους forget /εισόδου, forget-κρυφές και forget/μνήμης αντίστοιχα. Η C είναι η κατάσταση μνήμης στη στιγμή $t-1$ και b_f είναι η πόλωση της forget πύλης. Η έξοδος στο στρώμα πύλης εισόδου i δίνεται από:

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + W_{ic}C_{t-1} + b_i)$$

όπου W_{ix} , W_{ih} και W_{ic} είναι οι μήτρες βάρους της πύλης εισόδου/εισόδου, της πύλης εισόδου/κρυφής και της πύλης εισόδου/μνήμης, αντίστοιχα, και b_i είναι η πόλωση της πύλης εισόδου. Στην πύλη εισόδου, αποφασίζεται ποιες πληροφορίες θα κρατηθούν ή όχι. Ένα διάνυσμα U_i σχηματίζεται για να αποθηκεύσει τις νέες υποψήφιας τιμές που θα προστεθούν στη νέα κατάσταση του κελιού:

$$U_t = \sigma(W_{cx}x_t + W_{ch}h_{t-1} + b_c)$$

όπου W_{cx} και W_{ch} είναι οι μήτρες βάρους της κατάστασης του κελιού/εισόδου και της κατάστασης του κελιού/κρυφής, αντίστοιχα, και b_c είναι η πόλωση της κατάστασης του κελιού. Η νέα κατάσταση του κελιού C_t αποκτάται συνδυάζοντας τις τιμές των C_{t-1} , U_t , i_t και f_t :

$$C_t = U_t i_t + C_{t-1} f_t$$

Ένα σιγμοειδές στρώμα χρησιμοποιείται ως πύλη εξόδου για να παρέχει φίλτρο στην κατάσταση του κελιού o_t :

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

όπου W_{ox} , W_{oh} και W_{oc} είναι οι μήτρες βάρους της πύλης εξόδου/εισόδου, της πύλης εξόδου/κρυφής και της πύλης εξόδου/μνήμης, αντίστοιχα, και b_o είναι η πόλωση της

πύλης εξόδου. Έπειτα, μια σιγμοειδής συνάρτηση ενεργοποίησης εξόδου κελιού εφαρμόζεται στην κατάσταση του κελιού:

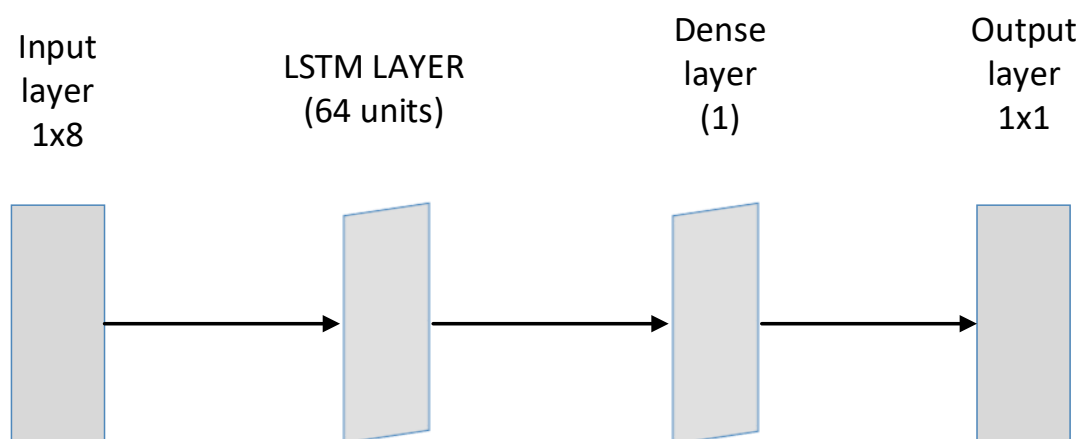
$$h_t = o_t I(C_t)$$

Η έξοδος του μπλοκ μνήμης y_t υπολογίζεται μέσω της ακόλουθης εξίσωσης:

$$y_t = k(W_{yh}h_t + b_y)$$

όπου k είναι η συνάρτηση ενεργοποίησης εξόδου, W_{yh} είναι η μήτρα βάρους της εξόδου/κρυφής και b_y είναι η πόλωση της εξόδου.

Η περιγραφή του LSTM δικτύου που χρησιμοποιήθηκε δίνεται στο Σχήμα 2.10.




Σχήμα 2.10 Αρχιτεκτονική του LSTM που χρησιμοποιήθηκε για σύγκριση


2.6.2 Άλλα μοντέλα μηχανικής μάθησης

Για την σύγκριση των αποτελεσμάτων εκτός από το δίκτυο LSTM έγιναν προβλέψεις και με ακόμα τρία μοντέλα μηχανικής μάθησης. Αυτά είναι το Elman, Regression Tree και τα δίκτυα GMDH. Η περιγραφή των παραπάνω μοντέλων βρίσκεται στις αναφορές [108]- [109]- [110]. Τα δίκτυα αυτά έχουν χρησιμοποιηθεί ευρέως στην πρόβλεψη και παλινδρόμηση μεταβλητών σχεδόν σε όλους τους τομείς της επιστήμης. Έχουν δοκιμαστεί και είναι αξιόπιστα μοντέλα πρόβλεψης. Η βελτίωση των αποτελεσμάτων σχετικά με αυτά αποτελεί λοιπόν μία ερευνητική πρόκληση.


Η αρχιτεκτονική των δικτύων φαίνεται στα Σχήματα 2.11, 2.12 και 2.13. Το πρώτο σχήμα δείχνει δύο αρχιτεκτονικές από δέντρα παλινδρόμησης, ακολουθεί το νευρωνικό δίκτυο τύπου Elman και τέλος το δίκτυο GMDH από άλλες εφαρμογές.



Σχήμα 2.11 Δίκτυο Regression Tree [111]



Σχήμα 2.12 Elman νευρωνικό δίκτυο [112]



Σχήμα 2.13 GMDH νευρωνικό δίκτυο [113]

2.7 Αποτίμηση της πρόβλεψης

Για την αποτίμηση της πρόβλεψης και την σύγκριση των αποτελεσμάτων είναι απαραίτητο να χρησιμοποιηθούν μετρικές σφαλμάτων. Αυτές πρέπει να είναι όσο το δυνατόν πιο αμερόληπτες γίνεται, ώστε να είναι ουσιαστική η σύγκριση των μοντέλων. Σύμφωνα με τις μετρικές σφαλμάτων γίνεται η αποτίμηση της απόδοσης ενός μοντέλου πρόβλεψης και άρα είναι εφικτή και η σύγκριση διαφορετικών μοντέλων. Για τον υπολογισμό της ακρίβειας των μοντέλων που δημιουργήθηκαν και λοιπών μοντέλων είτε βαθείας είτε μηχανικής μάθησης χρησιμοποιήθηκαν τέσσερις κλασσικές μετρικές σφάλματος. Αυτές είναι, το μέσο απόλυτο σφάλμα (MAE), σφάλμα ρίζας μέσου τετραγώνου (RMSE) και το μέσο κανονικοποιημένο σφάλμα απόλυτου εύρους (MARNE). Άλλα αποτελούν κανονικούς αριθμούς και άλλα έχουν μονάδες μέτρησης. Οι μαθηματικές εξισώσεις των σφαλμάτων που χρησιμοποιήθηκαν για αποτίμηση της ακρίβειας και σύγκριση των μοντέλων ακολουθούν [26]- [114]:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - t_i|$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2}$$

$$MARNE = \frac{1}{M} \sum_{i=1}^N \frac{|y_i - t_i|}{\max(y_i)} \times 100$$

ΚΕΦΑΛΑΙΟ 3

3. ΑΝΑΛΥΣΗ ΑΠΟΤΕΛΕΣΜΑΤΩΝ

3.1 Μελέτη Περίπτωσης


Τα δύο φωτοβολταϊκά μεγέθους 1.5 MW και 2.45 MW αποτελούν ιδιωτικά πάρκα στην βόρεια Ελλάδα. Η περιγραφή της ορογραφίας το υψόμετρο, αναφορές στο μικροκλίμα της περιοχής και η ακριβής τοποθεσία τους αποφασίστηκε να μην αναφερθούν επειδή αποτελούν ιδιωτικά έργα. Οι μεταβλητές που μετρούνται είναι η παραγωγή ηλεκτρικής ισχύος, η θερμοκρασία και η ηλιακή ακτινοβολία.

Η ανεμογεννήτρια είναι και αυτή ιδιωτική στην βόρεια Ελλάδα και οι μεταβλητές που μετρούνται είναι η παραγωγή η ταχύτητα και η διεύθυνση ανέμου. Για τον ίδιο λόγο, αυτόν της ιδιωτικής περιουσίας δεν αναφέρεται η ακριβής τοποθεσία της ανεμογεννήτριας, άρα δεν γίνεται και αναφορά στο ανάγλυφο της περιοχής.

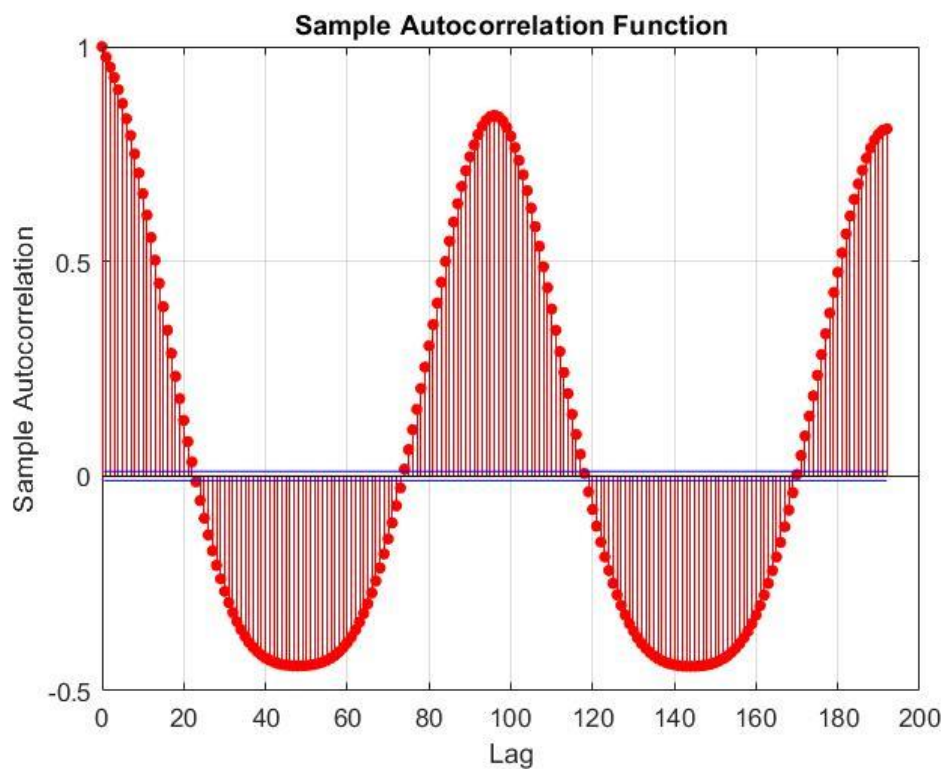
3.1.1 Ιστορική Συσχέτιση Παραγωγής Ηλεκτρικής Ισχύος

Για την απόφαση των μεταβλητών εισόδου έγινε έλεγχος συσχέτισης στο σύνολο των δεδομένων ελέγχου δύο ημέρες πριν για το ηλιακό πρόβλημα και για το αιολικό πρόβλημα 192 δεκάλεπτα πίσω. Η μέθοδος που χρησιμοποιήθηκε είναι η συσχέτιση με την συνάρτηση autocorr(y) στο Matlab. Η συνάρτηση autocorr μετρά τη συσχέτιση μεταξύ y_t και y_{t+k} , όπου $k = 0, \dots, K$ και y_t είναι μια στοχαστική διαδικασία. Όσο πιο κοντά στην μονάδα είναι ο συντελεστής αυτοσυσχέτισης, τόσο πιο μεγάλη η σχέση της παρούσας τιμής της χρονοσειράς με κάποια τιμή η οποία παρουσιάζει χρονική υστέρηση.

Στα Σχήματα 3.1 και 3.2 φαίνεται η φθίνουσα πορεία της συσχέτισης των τιμών, στο ιστορικό της χρονοσειράς με μεγάλη κλίση. Τιμές συντελεστή αυτοσυσχέτισης κοντά στη μονάδα παρουσιάζουν οι τιμές της χρονοσειράς που έχουν χρονική υστέρηση μία και δύο θέσεις από την παρούσα τιμή. Έτσι επιλέχθηκε οι μεταβλητές εισόδου να αναφέρονται ως μια χρονική περίοδο δειγματοληψίας πριν την παρούσα τιμή και έως μία χρονική περίοδο μπροστά για τις μεταβλητές που αποτελούν προβλέψεις μετεωρολογικών δεδομένων.



Σχήμα 3.1 Συσχέτιση για φ/β 1.5MW έως και δύο ημέρες υστέρηση



Σχήμα 3.2 Συσχέτιση για φ/β 2.45 MW έως και 2 ημέρες υστέρηση

Για το πρόβλημα της εντός ημέρας πρόβλεψης, φαίνεται ότι την τιμή που είναι πιο κοντά στην μονάδα και άρα καταδεικνύει μεγαλύτερη συσχέτιση, την έχει η τιμή της χρονοσειράς που αναφέρεται στην ίδια ώρα με την ώρα που εξετάζεται και ένα 24ωρο πριν. Έτσι αφού η δειγματοληψία είναι ανά δεκαπέντε λεπτά της ώρας στο ηλιακό πρόβλημα ως δεδομένα εισόδου επιλέχθηκαν τα δεδομένα που αναφέρονται στην ίδια ώρα αλλά για την προηγούμενη ημέρα, δηλαδή 96 θέσεις ή τέταρτα της ώρας χρονική υστέρηση, ως 97 για τις τιμές ιστορικού και 95 για τις τιμές που αποτελούν θεωρητικά προβλέψεις των μετεωρολογικών δεδομένων. Οι τιμές είναι γύρω από την κορυφή του δεύτερου όρους της αυτοσυσχέτισης.

Οι εισοδοί δίνονται στην ακόλουθη μορφή:

Είσοδοι για χρονικό ορίζοντα εντός ώρας,

$$x_m^{Train} = \begin{pmatrix} P_{DWT}(t)_m^{Train} \\ P_{DWT}(t-1)_m^{Train} \\ T(t+1)_m^{Train} \\ T(t)_m^{Train} \\ T(t-1)_m^{Train} \\ Ir(t+1)_m^{Train} \\ Ir(t)_m^{Train} \\ Ir(t-1)_m^{Train} \end{pmatrix}$$

Οι πρώτες δύο μεταβλητές του διανύσματος, είναι η παρούσα συνιστώσα κυματιδίου που αναφέρεται στην παραγωγή P του φ/β και η φ/β παραγωγή ισχύος με χρονική υστέρηση δεκαπέντε λεπτών. Με T αναφέρεται η θερμοκρασία. Η θερμοκρασία αποτελεί μετεωρολογική μεταβλητή. Οπότε συμπεριλαμβάνεται και η μετεωρολογική πρόβλεψή της $T(t+1)_m^{Train}$ εκτός από την παρούσα τιμή και την θερμοκρασία περιβάλλοντος που μετρήθηκε δεκαπέντε λεπτά πριν. Όπως η

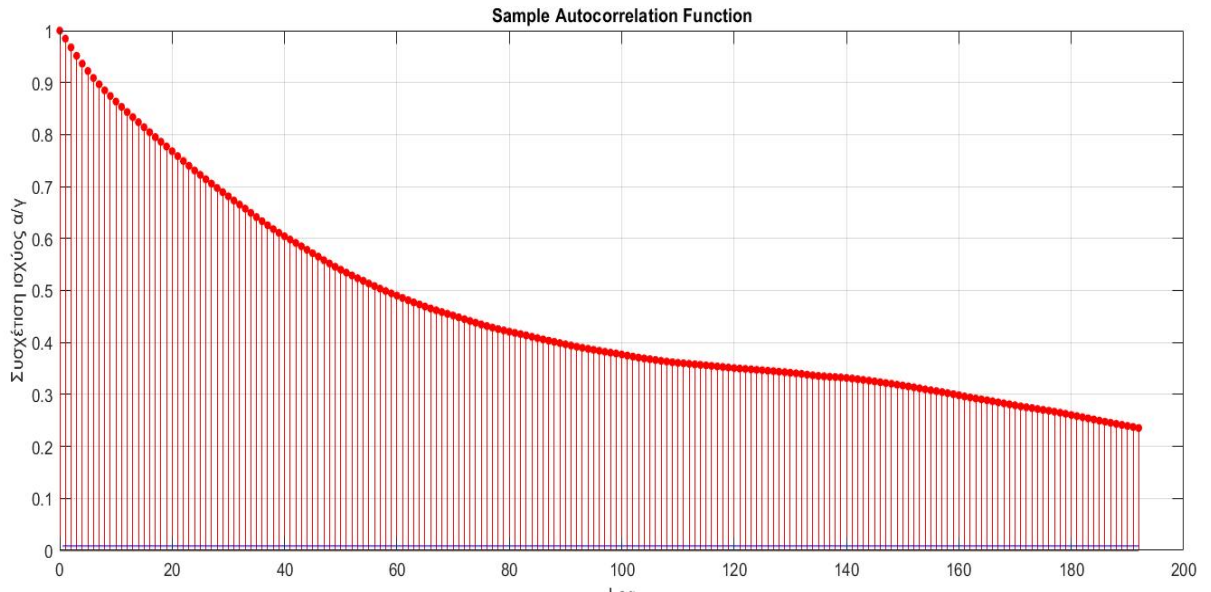
θερμοκρασία έτσι και η ακτινοβολία I_r αποτελεί μετεωρολογική μεταβλητή οπότε εκτός από την παρούσα και την προηγούμενη τιμή λαμβάνεται υπ' όψη και η μετεωρολογική πρόβλεψη.

Για χρονικό ορίζοντα ημέρας μπροστά υφίσταται το διάνυσμα εισόδων εκπαίδευσης,

$$x_m^{Train} = \begin{pmatrix} P_{DWT}(t - 96)_m^{Train} \\ P_{DWT}(t - 97)_m^{Train} \\ T(t - 95)_m^{Train} \\ T(t - 96)_m^{Train} \\ T(t - 97)_m^{Train} \\ I_r(t - 95)_m^{Train} \\ I_r(t - 96)_m^{Train} \\ I_r(t - 97)_m^{Train} \end{pmatrix}$$

Στο διάνυσμα εισόδων εκπαίδευσης για χρονικό ορίζοντα ημέρας μπροστά των ϕ/β οι δύο πρώτες μεταβλητές P , είναι μεταβλητές συνιστωσών κυματιδίων και σχετίζονται με την παραγωγή του ϕ/β την προηγούμενη ημέρα. Η μεταβλητή T είναι μεταβλητή θερμοκρασίας την προηγούμενη μέρα, αναφέρεται στην ίδια ώρα και δεκαπέντε λεπτά πριν και μετά. Ομοίως και η μεταβλητή ακτινοβολίας I_r .

Η συσχέτιση του μεγέθους της ηλεκτρικής ισχύος προερχόμενης από την α/γ ακολουθεί στο Σχήμα 3.3 και φαίνεται χαρακτηριστικά η μείωση της αυτοσυσχέτισης στο χρονικό ιστορικό. Το διάγραμμα περιέχει 192 μετρήσεις ιστορικού οι οποίες έχουν πραγματοποιηθεί ανά δεκάλεπτο. Υψηλή συσχέτιση κοντά στην μονάδα εμφανίζουν οι τιμές με χρονική υστέρηση δέκα και είκοσι λεπτών δηλαδή με υστέρηση 1 και 2 θέσεις. Για μείωση του υπολογιστικού κόστους χρησιμοποιήθηκαν οι τιμές με υστέρηση μιας θέσης ή δέκα λεπτών κατά την δειγματοληψία.



Σχήμα 3.3 Συσχέτιση για α/γ

Έτσι αποφασίστηκε οι εισοδοί εκπαίδευσης του μοντέλου για την πρόβλεψη εξόδου της α/γ να είναι οι ακόλουθες:

$$x_m^{Train} = \begin{matrix} P_{DWT}(t)_m^{Train} \\ P_{DWT}(t-1)_m^{Train} \\ V(t+1)_m^{Train} \\ V(t)_m^{Train} \\ V(t-1)_m^{Train} \\ Dir(t+1)_m^{Train} \\ Dir(t)_m^{Train} \\ Dir(t-1)_m^{Train} \end{matrix}$$

Στο διάνυσμα εισόδων εκπαίδευσης για την α/γ οι δύο πρώτες μεταβλητές P, είναι οι συνιστώσες κυματιδίων που σχετίζονται με την έξοδο ισχύος της ανεμογεννήτριας. Ο χρόνος στον οποίο αναφέρονται είναι, η παρούσα έξοδος και η έξοδος πριν από δέκα

λεπτά. Οι μεταβλητές V είναι μετεωρολογικές μεταβλητές ταχύτητας ανέμου. Στις μετεωρολογικές μεταβλητές περιλαμβάνεται και η πρόβλεψη του μεγέθους. Οπότε για την ταχύτητα του ανέμου υπάρχει είσοδος δεδομένων για την παρούσα χρονική στιγμή, για χρονική στιγμή με υστέρηση δέκα λεπτών, και τέλος η πρόβλεψη. Όσα ισχύουν για την ταχύτητα του ανέμου ισχύουν και για το μετεωρολογικό μέγεθος της διεύθυνσης Dir .

Για τα δύο προβλήματα τα μοντέλα τροφοδοτούνται με δεδομένα test. Το ϕ/β μοντέλο δέχεται εισόδους test x_p^{Test} για ενδοωριαίο,

$$x_m^{Test} = \begin{array}{|c} P_{DWT}(t)_m^{Test} \\ P_{DWT}(t-1)_m^{Test} \\ T(t+1)_m^{Test} \\ T(t)_m^{Train} \\ T(t-1)_m^{Test} \\ Ir(t+1)_m^{Test} \\ Ir(t)_m^{Test} \\ Ir(t-1)_m^{Test} \end{array}$$

και ορίζοντα ημέρας μπροστά

$$x_m^{Test} = \begin{array}{|c} P_{DWT}(t-96)_m^{Test} \\ P_{DWT}(t-97)_m^{Test} \\ T(t-95)_m^{Test} \\ T(t-96)_m^{Test} \\ T(t-97)_m^{Test} \\ Ir(t-95)_m^{Test} \\ Ir(t-96)_m^{Test} \\ Ir(t-97)_m^{Test} \end{array}$$

Οι χρονικοί δείκτες είναι οι ίδιοι και έχουν περιγραφεί για τα δεδομένα εκπαίδευσης.


Στα δύο προβλήματα ηλιακής και αιολικής ισχύος τα δεδομένα test αναφέρονται στο χρονικό διάστημα 1/1/2019 ως 31/12/2019. Οι εισοδοι δεδομένων ελέγχου του μοντέλου αποτελούνται από τις ίδιες μεταβλητές και χρονικές αναφορές με τα μοντέλα εκπαίδευσης.

Οι εισοδοι είναι οι ίδιοι και για το κανονικό μοντέλο και για το μοντέλο που χρησιμοποιεί την τεχνική ολισθαίνοντος παραθύρου.


Είσοδοι test για α/γ που αναφέρονται και στα δύο μοντέλα πρόβλεψης

$$x_m^{Test} = \begin{matrix} P_{DWT}(t)_m^{Test} \\ P_{DWT}(t-1)_m^{Test} \\ V(t+1)_m^{Test} \\ V(t)_m^{Test} \\ V(t-1)_m^{Test} \\ Dir(t+1)_m^{Test} \\ Dir(t)_m^{Test} \\ Dir(t-1)_m^{Test} \end{matrix}$$

Όπως έχει αναφερθεί οι δύο πρώτες μεταβλητές εισόδου αποτελούν συνιστώσες κυματιδίων που σχετίζονται με την παραγωγή ηλεκτρικής ισχύος προερχόμενης από ϕ/β και α/γ . Αυτή η διαδικασία πραγματοποιήθηκε με σκοπό την αφαίρεση του θορύβου από την χρονοσειρά ισχύος. Ενδεικτικά στα Σχήματα 3.4 και 3.5 φαίνονται οι εισοδοι εκπαίδευσης των συνιστωσών κυματιδίων για την παραγωγή του ϕ/β μεγέθους 1.5 MW και χρονικό ορίζοντα ημέρας μπροστά και για την α/γ . Η συνιστώσα A3 αποτελεί την κύρια συνιστώσα και οι συνιστώσες D1, D2, D3 αποτελούν συνιστώσες λευκού θορύβου. Οι συνιστώσες κυματιδίων αποφασίστηκε να είναι 4 μια κύρια και τρεις θορύβου με την μέθοδο δοκιμών δηλαδή trial and error.



Σχήμα 3.4 Συνιστώσες κυματιδίων για ϕ/β 1.5MW και οριζοντα ημέρας μπροστά



Σχήμα 3.5 Συνιστώσες κυματιδίων για την α/γ

3.2 Αποτελέσματα πρόβλεψης για το φωτοβολταϊκό πρόβλημα

3.2.1 Πρόβλεψη με χρονικό ορίζοντα ημέρας μπροστά και Φ/B 1.5 MW

Στο πρόβλημα της πρόβλεψης παραγωγής ισχύος με χρονικό ορίζοντα ημέρα μπροστά το μοντέλο κυματιδίων και δικτύου CNN επέφερε καλύτερα αποτελέσματα για τρεις τύπους σφάλματος από τρία μοντέλα μηχανικής μάθησης με τα οποία συγκρίθηκε αλλά και από μοντέλο που συνδυάζει κυματίδια με LSTM δίκτυο.

Πίνακας 3.1 Σύγκριση των μοντέλων για προβλέψεις Φ/B παραγωγής της επόμενης ημέρας για το Φ/B σύστημα 1.5 MW


	MAE (kW)	RMSE (kW)	MARNE (%)
WT/CNN	6.51	19.11	0.52
WT/LSTM	7.76	20.86	0.62
WT/ENN	9.47	21.57	0.76
WT/GMDH	9.98	21.12	0.72
WT/RT	9.85	26.69	0.79

Ειδικότερα το σφάλμα MARNE που αποτελεί και καθαρό αριθμό είναι 0.52 % όταν τα κλασσικά μοντέλα κινούνται σε επίπεδα πάνω από 0.7 % και το LSTM στο 0.62 %. Στην μέτρηση της ακρίβειας με μετρική το RMSE το μοντέλο WT/CNN έχει το μικρότερο σφάλμα με τιμή 19.11 kW. Ακολουθεί το WT/LSTM 20.86 kW και τέλος τα κλασσικά μοντέλα με λίγο μεγαλύτερο σφάλμα. Για το MAE το καινοτόμο μοντέλο που δημιουργήθηκε παρουσιάζει και σε αυτή την περίπτωση το μικρότερο σφάλμα με τιμή 6.51 kW.


Ένα άλλο μέτρο για το πόσο καλά το μοντέλο πρόβλεψης έχει ακρίβεια στα δεδομένα είναι το ιστόγραμμα κατανομής σφάλματος. Αυτό δείχνει πώς κατανέμονται τα μεγέθη σφαλμάτων. Συνήθως τα περισσότερα σφάλματα είναι σχεδόν μηδέν, με πολύ λίγα σφάλματα μακριά από αυτό. Όσο πιο κοντά στο μηδέν είναι η τιμή της κύριας μπάρας του ιστογράμματος και όσο μικρότερα τα ύψη και οι κεντρικές τιμές των διπλανών ορθοφωνίων τόσο καλύτερη η απόδοση του μοντέλου.

Ακολουθούν τα ιστογράμματα σφαλμάτων για το πρόβλημα της πρόβλεψης με χρονικό ορίζοντα ημέρας μπροστά και για το Φ/B μεγέθους 1.5 MW. Φαίνεται ότι το μοντέλο WT/CNN δημιουργεί καλύτερες προβλέψεις. Η κύρια μπάρα ιστογράμματος


είναι στην τιμή -6.79 χωρίς να περιβάλλεται από ορθογώνια με μεγάλα ύψη. Στο WT/LSTM το μεγάλο ορθογώνιο του ιστογράμματος έχει τιμή 11.22 και διπλανό ορθογώνιο με κεντρική τιμή -50.04 και εμφανίζεται περίπου 2500 φορές. Στο WT/EMM μοντέλο πρόβλεψης που αποτελεί κλασσικό μοντέλο πρόβλεψης η τιμή του κεντρικού ορθογωνίου είναι -11.79 και δίπλα υπάρχει ορθογώνιο με κεντρική τιμή 19.73 και ύψος μεγαλύτερο του 5000. Στο WT/GMDH η κεντρική τιμή του μεγάλου ορθογωνίου είναι αρκετά κοντά στο μηδέν, -3.006, όμως περιβάλλεται από δύο ορθογώνια με αρκετά μεγάλες κεντρικές τιμές. Αυτές είναι -33.9 και 27.89. Το ύψος των δύο ορθογωνίων είναι κοντά στο 2500 πράγμα που σημαίνει ότι τέτοιου μεγέθους σφάλματα εμφανίζονται στο σύνολο περίπου 5000 φορές στο σύνολο 35040 προβλέψεων. Παρόμοια συμπεριφορά δείχνει και το μοντέλο WT/RT. Εδώ η κεντρική τιμή του μεγάλου ορθογωνίου είναι μικρή, 2.351 όμως τα δύο διπλανά ορθογώνια έχουν τιμές μεγαλύτερες του 40 κατά απόλυτη τιμή με τέτοια σφάλματα να εμφανίζονται περίπου 5000 φορές και σε αυτή την περίπτωση.




Σχήμα 3.6 Ιστογράμμο σχετικών σφαλμάτων για το μοντέλο WT/CNN για προβλέψεις Φ/Β παραγωγής της επόμενης ημέρας για το Φ/Β σύστημα 1.5 MW




Σχήμα 3.7 Ιστόγραμμα σχετικών σφαλμάτων για το μοντέλο WT/LSTM για προβλέψεις Φ/Β παραγωγής της επόμενης ημέρας για το Φ/Β σύστημα 1.5 MW



Σχήμα 3.8 Ιστόγραμμα σχετικών σφαλμάτων για το μοντέλο WT/ENN για προβλέψεις Φ/Β παραγωγής της επόμενης ημέρας για το Φ/Β σύστημα 1.5 MW



Σχήμα 3.9 Ιστόγραμμα σχετικών σφαλμάτων για το μοντέλο WT/GMDH για προβλέψεις Φ/Β παραγωγής της επόμενης ημέρας για το Φ/Β σύστημα 1.5 MW



Σχήμα 3.10 Ιστόγραμμα σχετικών σφαλμάτων για το μοντέλο WT/RT για προβλέψεις Φ/Β παραγωγής της επόμενης ημέρας

Ένα άλλο μέτρο για το πόσο καλά μοντέλο εκπαιδεύεται στα δεδομένα είναι το διάγραμμα παλινδρόμησης. Το γράφημα παλινδρόμησης δείχνει τις πραγματικές εξόδους δικτύου που απεικονίζονται σε σχέση με τις σχετικές τιμές-στόχους. Εάν το δίκτυο έχει μάθει να ταιριάζει καλά στα δεδομένα, η γραμμική προσαρμογή σε αυτήν τη σχέση εξόδου-στόχου θα πρέπει να τέμνει στενά την κάτω αριστερή και την επάνω δεξιά γωνία της πλοκής. Ο δείκτης R^2 είναι ένα μέτρο για το πόσο καλό είναι το μοντέλο. Όσο πιο κοντά στην μονάδα είναι αυτός ο συντελεστής τόσο πιο αποδοτικό το μοντέλο πρόβλεψης. Ο συντελεστής R^2 ορίζεται ως:

$$R^2 = 1 - \frac{RSS}{SYY}$$

$$SYY = \sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (Y_i)^2 - n\bar{Y}^2$$

Όπου Y_i η πραγματική τιμή και \bar{Y} η μέση τιμή. RSS είναι το άθροισμα των τετραγώνων των υπολοίπων.

Στην συνέχεια παρουσιάζονται οι συσχετίσεις των μεταβλητών πραγματικής ισχύος εξόδου και προβλεπόμενης ισχύος εξόδου. Για τα 5 μοντέλα πρόβλεψης ο δείκτης R^2 για το καθένα είναι:

$$R^2 \text{ WT/CNN}=0.9983$$

$$R^2 \text{ WT/LSTM}=0.998$$

$$R^2 \text{ WT/ENN}=0.9978$$

$$R^2 \text{ WT/GMDH}=0.9979$$

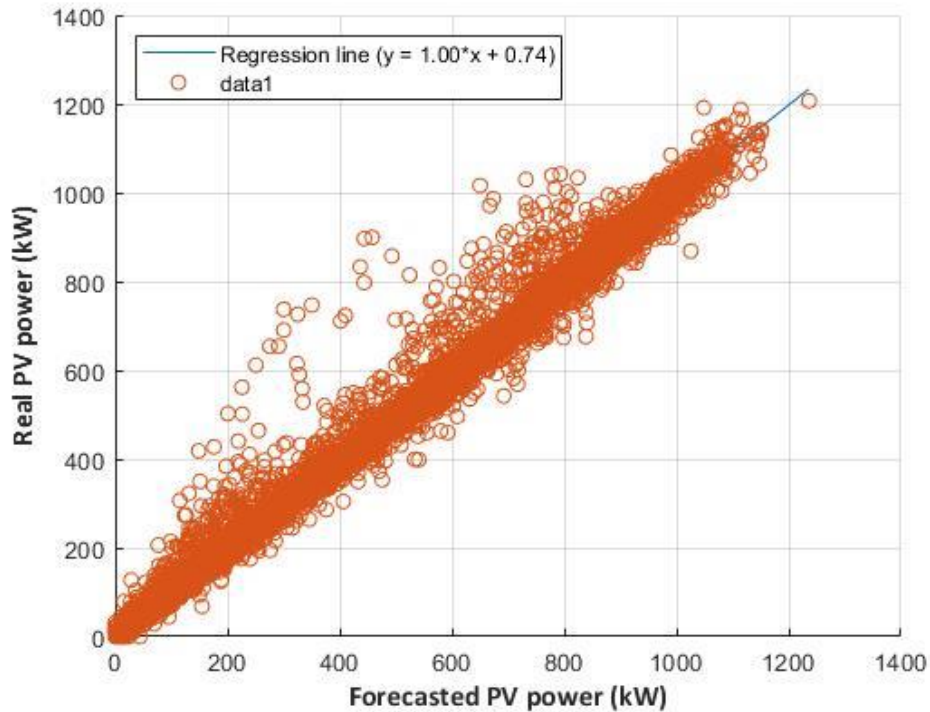
$$R^2 \text{ WT/RT}=0.9971$$

Έτσι το WT/CNN παρουσιάζει την μεγαλύτερη συσχέτιση μεταξύ των μεταβλητών. Με τον συντελεστή $R^2=0.9983$ πολύ κοντά στη μονάδα και ακολουθούν το WT/LSTM, WT/GMDH, WT/ENN και τέλος WT/RT.

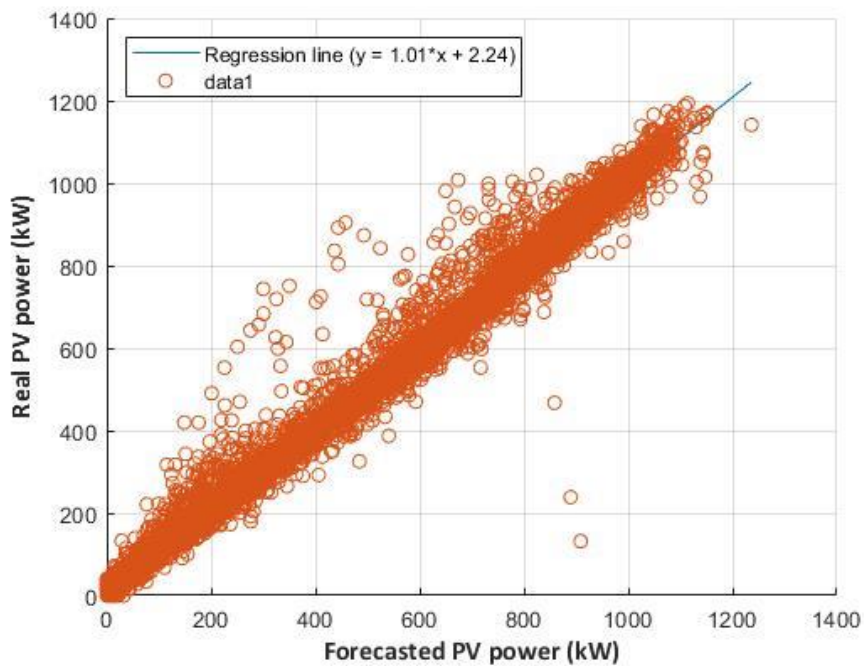
Επίσης οι γραμμές παλινδρόμησης των μοντέλων είναι ικανοποιητικές με τον συντελεστή διεύθυνσης της ευθείας να είναι για όλα τα μοντέλα σχεδόν ίσος με την μονάδα και παντού υπάρχει μικρή κατακόρυφη μετατόπιση.

Από αυτή την ανάλυση επειδή όλες οι γραμμές είναι ικανοποιητικές ο συντελεστής


R^2 δείχνει ότι το μοντέλο με την μεγαλύτερη ακρίβεια είναι το νέο καινοτόμο μοντέλο κυματιδίων και συνελκτικού νευρωνικού δικτύου.




Σχήμα 3.11 Συσχέτιση πραγματικής-προβλεπόμενης ισχύος για το μοντέλο WT/CNN




Σχήμα 3.12 Συσχέτιση πραγματικής-προβλεπόμενης ισχύος για το μοντέλο WT/LSTM



Σχήμα 3.13 Συσχέτιση πραγματικής-προβλεπόμενης ισχύος για το μοντέλο WT/ENN




Σχήμα 3.14 Συσχέτιση πραγματικής-προβλεπόμενης ισχύος για το μοντέλο WT/GMDH




Σχήμα 3.15 Συσχέτιση πραγματικής-προβλεπόμενης ισχύος για το μοντέλο WT/RT


Τέλος αναζητήθηκαν ημέρες διαφορετικού προφίλ παραγωγής για να φανεί η προσαρμογή των μοντέλων στην πρόβλεψη της χρονοσειράς. Επιλέχθηκαν τέσσερις ημέρες. Οι 10/7/2019, 17/2/2019, 27/4/2019 και 20/8/2019. Οι μέρες είναι από διαφορετικές εποχές, άρα υπάρχει διαφορά στην χρονική διάρκεια παραγωγής και δεν αποτελούν όλες ομαλές καμπύλες αλλά διαφέρουν. Συγκεκριμένα, η 17/7/2019 έχει μεγάλες διακυμάνσεις μετά το μεσημέρι η 17/2/2019 μικρότερες αλλά πιο περιοδικές η 27/4/2019 παρουσιάζει μεταβολές από νωρίτερα και η 20/8/2019 αποτελεί μία ομαλή καμπύλη παραγωγής. Όλα τα μοντέλα πρόβλεψης ακολουθούν την χρονοσειρά παραγωγής ηλεκτρικής ισχύος από του φωτοβολταϊκό μεγέθους 1.5 MW. Έτσι αν συνυπολογίστουν τα ιστογράμματα των σφαλμάτων και το μέγεθος των μεταβλητών σφάλματος και συσχέτισης συμπεραίνεται το γεγονός ότι η πρόβλεψη για χρονικό ορίζοντα ημέρας μπροστά από το μοντέλο συνδυασμού κυματιδίων και συνελκτικού νευρωνικού δικτύου παράγει βέλτιστα αποτελέσματα.




Σχήμα 3.16 Προφίλ πραγματικής παραγωγής και προβλέψεων για την 10/07/2019



Σχήμα 3.17 Προφίλ πραγματικής παραγωγής και προβλέψεων για την 10/07/2019



Σχήμα 3.18 Προφίλ πραγματικής παραγωγής και προβλέψεων για την 27/04/2019



Σχήμα 3.19 Προφίλ πραγματικής παραγωγής και προβλέψεων για την 20/08/2019

3.2.2 Πρόβλεψη με χρονικό ενδοωριαίο χρονικό ορίζοντα για τα δύο φ/β

Όπως και το πρόβλημα του χρονικού ορίζοντα ημέρα μπροστά έτσι και για ενδοωριαίο χρονικό ορίζοντα το καλύτερο μοντέλο αποτελεί το WT/CNN για το πάρκο των 1.5 MW. Τα σφάλματα στον ενδοωριαίο χρονικό ορίζοντα είναι μικρότερα σε σχέση με τον ορίζοντα ημέρας μπροστά όπως ήταν αναμενόμενο.

Πίνακας 3.2 Σφάλματα για ενδοωριαίο ορίζοντα και φ/β μεγέθους 1.5 MW

	MAE (kW)	RMSE (kW)	MARNE (%)
WT/CNN	2.67	7.32	0.21
WT/LSTM	2.78	7.94	0.22
WT/ENN	5.97	14.48	0.48
WT/GMDH	4.47	12.24	0.36
WT/RT	6.91	16.48	0.55

Πίνακας 3.3 Σφάλματα για ενδοωριαίο ορίζοντα και φ/β μεγέθους 2.45 MW

	MAE (kW)	RMSE (kW)	MARNE (%)
WT/CNN	6.27	97.49	0.03
WT/LSTM	7.54	86.19	0.04
WT/ENN	10.06	88.67	0.06
WT/GMDH	12.77	75.19	0.06
WT/RT	9.30	111.88	0.05

Το σφάλμα MARNE που αποτελεί την πιο αντικειμενική μετρική σφάλματος από όσες υπολογίστηκαν είναι μικρότερο για το WT/CNN και στην περίπτωση πρόβλεψης ενδοωριαίου χρονικού ορίζοντα για το φ/β πάρκο μεγέθους 1.5 MW, με τιμή $MARNE_{WT/CNN} = 0.21 \%$. Έπειτα για τον δείκτη MARNE καλύτερη απόδοση έχει το WT/LSTM δίκτυο, ακολουθεί το WT/GMDH και τέλος τα WT/ENN και WT/RT. Όμως το WT/CNN μοντέλο έχει καλύτερη απόδοση και στους άλλου δύο δείκτες σφάλματος RMSE και MAE με τα σφάλματα εκεί να είναι 7.32 kW και 2.67 kW αντίστοιχα τα μικρότερα που παρουσιάζονται.

Όσον αφορά το φ/β πάρκο των 2.45 MW το σφάλμα MARNE του καινοτόμου μοντέλου WT/CNN, είναι και σε αυτήν την περίπτωση το μικρότερο με τιμή 0.03 %. Ακολουθούν για αυτόν τον τύπο σφάλματος το WT/LSTM, WT/RT, WT/ENN, WT/GMDH με αυξανόμενο σφάλμα κατά σειρά. Για την μετρική σφάλματος RMSE σε

αυτή την περίπτωση το WT/CNN μοντέλο δεν έχει την καλύτερη απόδοση αλλά έρχεται τέταρτο. Όμως παρουσιάζει και πάλι την μεγαλύτερη ακρίβεια σύμφωνα με τον δείκτη σφάλματος MAE με το $MAE_{WT/CNN}=6.27$ kW.

Τέλος φαίνεται το μέγεθος του πάρκου να επηρεάζει την ακρίβεια της πρόβλεψης, αφού το σφάλμα MARNE είναι για τα μοντέλα κατά μία τάξη μεγέθους μικρότερο για το φ/β πάρκο των 2.45 MW σε σύγκριση με το πάρκο των 1.5 MW.


3.3 Αποτελέσματα πρόβλεψης για το αιολικό πρόβλημα WT/CNN

Στον Πίνακα 3.4 παρατίθενται συγκεντρωτικά τα σφάλματα για την α/γ.


Πίνακας 3.4 Σύγκριση των μοντέλων για προβλέψεις παραγωγής από Α/Γ της επόμενης ώρας για το σύστημα 4.25 MW

	MAE (kW)	RMSE (kW)	MARNE (%)
WT/CNN	1534.24	2604.15	1.06
WT/LSTM	1875.85	3433.93	1.30
WT/ENN	3819.34	6650.34	2.65
WT/GMDH	1865.45	3165.62	1.28
WT/RT	1673.98	3073.401	1.16


Τα σφάλματα σε αυτό το πρόβλημα είναι μικρότερα για το WT/CNN μοντέλο και για τους τρεις τύπους σφάλματος. Αν και αυξημένα σε σχέση με το φωτοβολταϊκό πρόβλημα αποτελούν καλές προβλέψεις αν αναλογιστεί κάποιος την μεγαλύτερη στοχαστικότητα του φαινομένου του ανέμου άρα και της χρονοσειράς παραγωγής. Συγκεκριμένα στον σημαντικότερο δείκτη MARNE, το σφάλμα για το WT/CNN είναι 1.06 % το μικρότερο που παρουσιάζεται. Ακολουθούν με αύξουσα σειρά τα WT/RT, WT/GMDH, WT/LSTM και WT/ENN. Στην περίπτωση του σφάλματος RMSE το μοντέλο WT/CNN το οποίο δημιουργήθηκε έχει το μικρότερο σφάλμα με τιμή $RMSE_{WT/CNN} = 2604.15$ kW. Το σφάλμα σε αυτή την περίπτωση αυξάνει με την ίδια σειρά. Δηλαδή την καλύτερη απόδοση μετά το WT/CNN την έχει το WT/RT με $RMSE_{WT/RT}=3073.401$ kW και ακολουθούν $RMSE_{WT/GMDH} = 3165.62$ kW, $RMSE_{WT/LSTM} = 3433.93$ kW και $RMSE_{WT/ENN} = 6650.34$ kW. Τέλος για το MAE και πάλι την καλύτερη απόδοση την έχει το μοντέλο WT/CNN που δημιουργήθηκε με τιμή $MAE_{WT/CNN} = 1534.24$ kW. Ακολουθούν WT/RT, WT/GMDH, WT/LSTM και WT/ENN από την καλύτερη προς την χειρότερη απόδοση.




Σχήμα 3.20 Ιστόγραμμα σφαλμάτων για το WT/CNN για α/γ




Σχήμα 3.21 Ιστόγραμμα σφαλμάτων για το WT/LSTM για α/γ



Σχήμα 3.22 Ιστόγραμμα σφαλμάτων για το WT/ENN για α/γ




Σχήμα 3.23 Ιστόγραμμα σφαλμάτων για το WT/GMDH για α/γ




Σχήμα 3.24 Ιστόγραμμα σφαλμάτων για το WT/RT για α/γ

Από τα ιστογράμματα κατανομής των σφαλμάτων εξάγεται το ίδιο συμπέρασμα καλύτερης απόδοσης του WT/CNN στο πρόβλημα πρόβλεψης της ηλεκτρικής ισχύος προερχόμενης από την ανεμογεννήτρια με τα σφάλματα να έχουν εμφανώς κατανομή με κεντρική τιμή πιο κοντά στο μηδέν.


Όπως και στο πρόβλημα πρόβλεψης από φωτοβολταϊκά παρατίθενται ενδεικτικά ημερήσιες παραγωγές από την ανεμογεννήτρια. Οι ημερομηνίες αναφέρονται στις 16/07/2019, 29/10/2019, 14/10/2019, 27/02/2019. Όλα τα μοντέλα φαίνεται να ακολουθούν ικανοποιητικά την χρονοσειρά παραγωγής ηλεκτρικής ισχύος προερχόμενης από αιολική. Φαίνεται όμως ότι το μοντέλο κυματιδίων και συνελκτικού νευρωνικού δικτύου έχει καλύτερη προσαρμογή στις διακυμάνσεις του σήματος και ειδικότερα καλύτερη συμπεριφορά σε τιμές κοντά στο μηδέν. Αυτό σε συνδυασμό με τις μικρότερες μετρικές σφάλματος οδηγεί στο συμπέρασμα ότι το συγκεκριμένο μοντέλο υπερτερεί σε σύγκριση με τα υπόλοιπα μοντέλα μηχανικής μάθησης WT/ENN, WT/GMDH, WT/RT αλλά και το πιο σύγχρονο μοντέλο σε σύγκριση με τα προηγούμενα WT/LSTM.




Σχήμα 3.25 Πραγματική και προβλεπόμενη ισχύς για την 16/07/2019



Σχήμα 3.26 Πραγματική και προβλεπόμενη ισχύς για την 29/10/2019



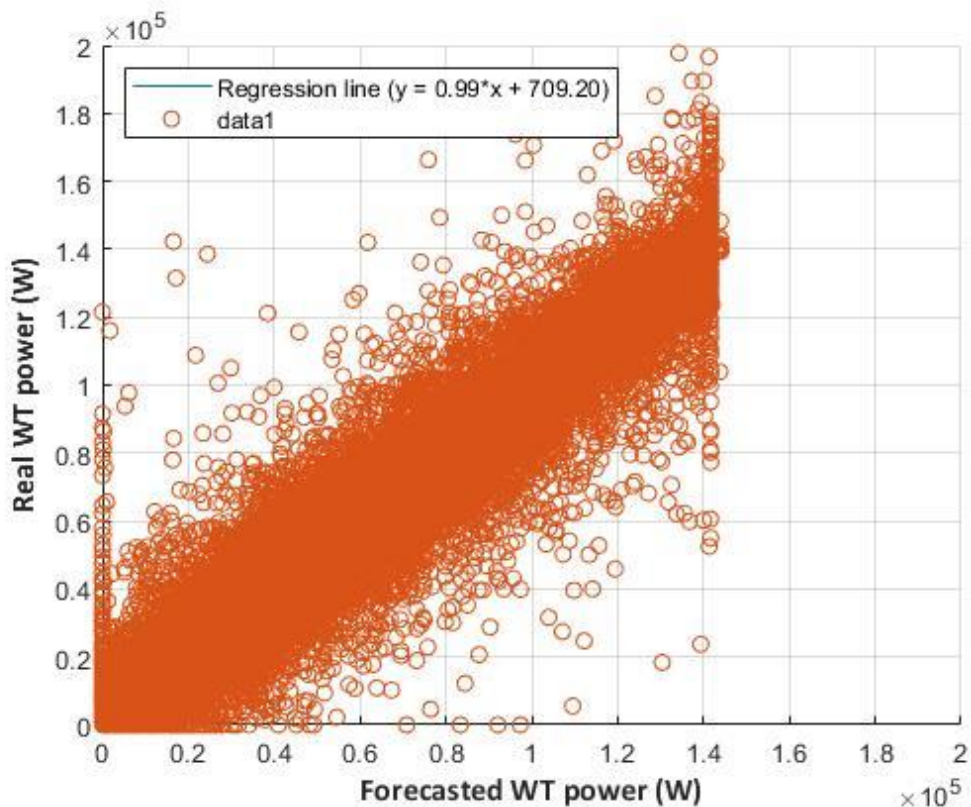
Σχήμα 3.27 Πραγματική και προβλεπόμενη ισχύς για την 14/10/2019



Σχήμα 3.28 Πραγματική και προβλεπόμενη ισχύς για την 27/02/2019

3.4 Μοντέλο πρόβλεψης προσαρμοζόμενου στην χρονοσειρά με τη μέθοδο του ολισθαίνοντος παραθύρου (Ο.Π.)

Με σκοπό την αντιμετώπιση της μεγάλης στοχαστικότητας του ανέμου δημιουργήθηκε ένα μοντέλο πρόβλεψης που απαιτεί πολύ λιγότερα δεδομένα για εκπαίδευση και πρόβλεψη. Η τεχνική είχε μεγαλύτερο σφάλμα όμως δεν μπορεί απαραίτητα να συγκριθεί με τα υπόλοιπα μοντέλα πρόβλεψης αφού απαιτεί πολύ λιγότερα δεδομένα εκπαίδευσης. Για το μοντέλο χρησιμοποιήθηκαν τα δεδομένα για το έτος 2019 και για εκπαίδευση και για έλεγχο της ακρίβειας όπως έχει περιγραφεί στις προηγούμενες παραγράφους. Ο δείκτης συσχέτισης πραγματικής παραγωγής και προβλεπόμενης από το μοντέλο είναι αρκετά υψηλός $R^2=0.9826$ Σχήμα 3.27.



Σχήμα 3.29 Συντελεστής συσχέτισης πραγματικής και προβλεπόμενης ισχύος για το προσαρμοζόμενο στα δεδομένα μοντέλο


Στον πίνακα σφαλμάτων φαίνεται η διαφορά που υπήρχε στις μετρικές των σφαλμάτων. Το σφάλμα MARNE είναι μεγαλύτερο όμως στην ίδια τάξη μεγέθους με τα κλασικά μοντέλα πρόβλεψης. Ενθαρρυντικό είναι το γεγονός ότι το μοντέλο

χρησιμοποίησε πολύ λιγότερα δεδομένα για την πρόβλεψη με συγκρίσιμο με τα κλασσικά μοντέλα σφάλμα.


Πίνακας 3.5 Σύγκριση των μοντέλων για προβλέψεις παραγωγής από Α/Γ της επόμενης ώρας για το σύστημα 4.25 MW

	MAE (kW)	RMSE (kW)	MARNE (%)
WT/CNN	4542.85	8380.88	3.14
WT/LSTM	-	-	-
WT/ENN	3819.34	6650.34	2.65
WT/GMDH	1865.45	3165.62	1.28
WT/RT	1673.98	3073.401	1.16


Ακολουθούν ημερήσια διαγράμματα πραγματικής και προβλεπόμενης ηλεκτρικής ισχύος. Τα διαγράμματα αναφέρονται σε 4 ημέρες. Οι μέρες είναι οι 08/03/2019, 10/04/2019, 30/05/2019, 30/05/2019, 16/12/2019. Φαίνεται η ικανοποιητική προσαρμογή του μοντέλου στο σήμα της χρονοσειράς παραγωγής.




Σχήμα 3.30 Πραγματική και προβλεπόμενη ισχύς για την 8/03/2019 και μοντέλο Ο.Π.



Σχήμα 3.31 Πραγματική και προβλεπόμενη ισχύς για την 10/04/2019 και μοντέλο Ο.Π.



Σχήμα 3.32 Πραγματική και προβλεπόμενη ισχύς για την 30/05/2019 και μοντέλο Ο.Π.



Σχήμα 3.33 Πραγματική και προβλεπόμενη ισχύς για την 16/14/2019 και μοντέλο Ο.Π.

ΚΕΦΑΛΑΙΟ 4

4. ΣΥΜΠΕΡΑΣΜΑΤΑ

Τα τελευταία χρόνια και με γνώμονα την κλιματική αλλαγή και άρα την προστασία του περιβάλλοντος, κυβερνήσεις και επιχειρηματική δραστηριότητα, στρέφονται προς την προώθηση εναλλακτικών καυσίμων και ανανεώσιμων πηγών ενέργειας, για την παραγωγή ηλεκτρικής ισχύος. Αποτελεί λοιπόν μονόδρομο η εισχώρηση ανανεώσιμων πηγών ενέργειας στα δίκτυα ισχύος. Αν και έχουν το πλεονέκτημα, ότι μπορούν να θεωρηθούν καθαρές μορφές ενέργειας και φιλικές προς το περιβάλλον, δημιουργούν μια σειρά προβλημάτων. Αυτά σχετίζονται με την ευστάθεια και την αξιοπιστία του δικτύου, την αύξηση του κόστους λειτουργίας και του κόστους προγραμματισμού. Πιο συγκεκριμένα προκαλούν υποβάθμιση της ισχύος, μπορούν να προκαλέσουν απότομη αύξηση της τάσης, αντίστροφη ροή ισχύος, διακυμάνσεις στην αρμονική, παραμόρφωση συχνότητας σε κυματομορφές ρεύματος και τάσης και αβεβαιότητα στην παραγόμενη ποσότητα ενέργειας. Αυτή η αβεβαιότητα μπορεί να αυξήσει το κόστος λειτουργίας του δικτύου δυσκολεύοντας τις αποφάσεις για δέσμευση μονάδων παραγωγής και το κόστος προγραμματισμού, αφού ανοίγεται ένα ζήτημα που είναι απαραίτητο να λυθεί. Έτσι είναι επιτακτική η ανάγκη, για την δημιουργία αξιόπιστων και στιβαρών μοντέλων πρόβλεψης, της παραγόμενης ισχύος από ΑΠΕ. Αυτό θα έχει ως αποτέλεσμα την μείωση του συνολικού κόστους λειτουργίας του δικτύου, αλλά δίνει και την δυνατότητα για ακόμη μεγαλύτερη εισχώρηση των ΑΠΕ στα δίκτυα ισχύος, παράγοντα ευεργετικό για το περιβαλλοντικό πρόβλημα. Τα μοντέλα πρόβλεψης μπορούν να διαχωριστούν ανάλογα με τον χρονικό ορίζοντα στον οποίο αναφέρονται

Στην παρούσα εργασία, παρουσιάζεται το πρόβλημα της πρόβλεψης παραγωγής ηλεκτρικής ισχύος από ανανεώσιμες πηγές ενέργειας και κάποιες από τις προκλήσεις που περιέχει. Η μεγαλύτερη δυσκολία δημιουργείται από την στοχαστικότητα των συνθηκών στις οποίες λειτουργούν, επειδή εξαρτώνται άμεσα από αυτές. Στην φωτοβολταϊκή πρόβλεψη, μεγάλη στοχαστικότητα εισάγει στο πρόβλημα η ηλιακή ακτινοβολία. Όσο για την πρόβλεψη παραγωγής ηλεκτρικής ισχύος από

ανεμογεννήτρια, η στοχαστικότητα του προβλήματος εμπεριέχεται στο μέγεθος της ταχύτητας και διεύθυνσης του ανέμου. Με την ανάπτυξη της πληροφορικής και της τεχνολογίας μπορούν να δημιουργηθούν σύγχρονα μοντέλα και να γίνονται ακριβέστερες καταγραφές συνόλου δεδομένων, για την επίλυση του προβλήματος. Με στόχο την ακριβέστερη πρόβλεψη δημιουργήθηκαν δύο καινοτόμα μοντέλα πρόβλεψης ηλεκτρικής ισχύος, από ηλιακή ή αιολική ισχύ. Οι ορίζοντες πρόβλεψής τους είναι εντός ώρας και ημέρας μπροστά για το φωτοβολταϊκό πρόβλημα και ενδοωριαία πρόβλεψη για το αιολικό. Αποτελούν υβριδικά μοντέλα πρόβλεψης που βασίζονται στην μηχανική μάθηση και ειδικότερα, στο νευρωνικό δίκτυο CNN. Για την αφαίρεση του θορύβου από την χρονοσειρά παραγωγής, έγινε χρήση του διακριτού μετασχηματισμού κυματιδίων. Αυτά τα μοντέλα έδειξαν να έχουν ικανοποιητικά επίπεδα πρόβλεψης και μάλιστα αν συγκριθούν με παραδοσιακές τεχνικές πρόβλεψης που βασίζονται στην τεχνητή νοημοσύνη και άλλα μοντέλα βαθιάς μάθησης, δείχνουν να υπερτερούν. Συγκρίθηκαν με τα μοντέλα regression tree, gmdh και elman. Από το μοντέλο του regression tree φάνηκε να έχουν πολύ καλύτερα επίπεδα πρόβλεψης αφού τα σφάλματα είναι πολύ μικρότερα και ειδικότερα το σφάλμα MARNE είναι 50% χαμηλότερο. Σε σύγκριση με το μοντέλο gmdh και ENN το σφάλμα MARNE είναι και πάλι χαμηλότερο περίπου κατά 25%. Τα παραπάνω αποτελούν ενθαρρυντικά στοιχεία για περαιτέρω έρευνα. Το μοντέλο που δημιουργήθηκε προς διερεύνηση και χρησιμοποιεί το ολισθαίνον παράθυρο, είχε μεγαλύτερο σφάλμα από τα κλασσικά μοντέλα, όμως έχει το πλεονέκτημα ότι δεν χρειάζεται τον ίδιο όγκο δεδομένων για εκπαίδευση και μπορεί να λειτουργεί υπό ζωντανές συνθήκες στην εκπαίδευση και πρόβλεψη. Επίσης μπορεί να βελτιωθεί η απόδοσή του. Τα παραπάνω αποτελούν στοιχεία ενθαρρυντικά για περαιτέρω έρευνα.

Με σκοπό την βελτίωση των αποτελεσμάτων ακόμα περισσότερο, στην συνέχεια της ερευνητικής διαδικασίας προτείνεται να μελετηθούν τρόποι βελτίωσης του αλγορίθμου εκπαίδευσης με χρήση του μεταεωριστικού αλγορίθμου GA. Ακόμη είναι εφικτή η σύγκριση με νέες τεχνικές προεπεξεργασίας των δεδομένων. Μία επιλογή είναι η empirical mode decomposition και η σύγκριση των αποτελεσμάτων με το παρόν μοντέλο που χρησιμοποιεί κυματίδια, για αφαίρεση του θορύβου. Μία άλλη

επιλογή για περαιτέρω έρευνα είναι η σύγκριση με άλλα μοντέλα πρόβλεψης όπως το ANFIS. Στην συνέχεια θα εφαρμοστούν τεχνικές μείωσης των διαστάσεων με την μέθοδο της Principal component analysis. Οφείλεται να ερευνηθεί η ακρίβεια της πρόβλεψης, για εμπλουτισμένα με μεταβλητές σύνολα δεδομένων. Αυτές οι μεταβλητές θα μπορούσαν να είναι η θερμοκρασία κυψέλης για τα φωτοβολταϊκά και μεγέθη που σχετίζονται με την πυκνότητα του αέρα, όπως η θερμοκρασία και η σχετική υγρασία για το αιολικό πρόβλημα. Επίσης θα εξεταστεί η απόδοση των παρόντων μοντέλων σε νέα σύνολα δεδομένων που μπορούν να αναφέρονται σε οριακή τιμή συστήματος, ηλεκτρικό φορτίο, κατανάλωση φυσικού αερίου κ.α. Τέλος προτείνεται η σύγκριση με ένα υβριδικό μοντέλο βαθιάς μάθησης τύπου LSTM/CNN. Αυτό θα μπορούσε είτε χρησιμοποιεί πρώτα το δίκτυο LSTM και έπειτα να τροφοδοτείται με τις εξόδους το CNN ή το αντίστροφο.

BIBΛΙΟΓΡΑΦΙΑ

- [1] R. Ahmed, V. Sreeram, Y. Mishra and M. Arid, "A review and evaluation of the state-of-the-art in PV solar power," *Renewable and Sustainable Energy Reviews*, vol. 124, 2020.
- [2] Z. Guo, L. ZhouK, C. Zhang, X. Lu, W. Chen and S. Yang, "Residential electricity consuption behavior: influencing factors, related theories and intervencion strategies.," *Renew Sustain Energy Rev*, pp. 399-412.
- [3] E. Mocanu, P. Nguyen, M. Gibescu and W. Kling, "Deep learning for estimating building energy consumption. Sustain Energy Grids," *Networks*, pp. 91-99, Jun 2016.
- [4] S. Z., "Solar energy in progress and future research trends.," *Prog Energy Combust*, pp. 367-416, 2004.
- [5] C. Varotsos, M. Eftathiou and J. Christodoulakis, "Abrupt changes in global," *Atmos Res*, Vols. 114-119, no. 217, March 2019.
- [6] Z. A., "Renewables 2016 global status report,," *Renewables*, vol. 60, 2016.
- [7] A. C. Zervos and Muth Josche, "RE-thinking 2050-A 100% renewable energy," 2010.
- [8] M. Elhadidy and S. Shaahid, "Parametric study of hybrid (wind plus solar plus diesel)," *Renew Energy*, vol. 21, no. 2, pp. 129-139, October 2000.
- [9] V. Khare, S. Nema and P. Baredar, "Solar–wind hybrid renewable energy system: a," *Renew Sustain Energy Rev*, vol. 58, pp. 23-33, 2016.
- [10] A. Shah, H. Yokoyama and N. Kakimoto, "High-precision forecasting model of solar irradiance based on grid point value data analysis for an efficient photovoltaic system," *Ieee Trans Sustain Energy*, vol. 6, no. 2, pp. 474-481, April 2015.
- [11] E. Cojocary, J. Bravo, M. Vasallo and Santos DM, "Optimal scheduling in concentrating solar power plants oriented to low generation cycling.," *Renew Energy*, vol. 135, pp. 789-799, May 2019.
- [12] S. Comello, S. Reichelstein and A. Sahoo, "The road ahead for solar PV power," *Renewable & sustainable energy reviews*, vol. 92, pp. 744-756, September 2018.
- [13] D. U. e. al., "Forecasting of photovoltaic power generation and model optimization: a review (in English)," *Renew Sustain Energy*, pp. 912-928, January 2018.
- [14] M. Raza, M. Nadarajah and C. Ekanayake, "On recent advances in PV output power.," *Sol Energy*, vol. 136, pp. 125-144, 2016.

- [15] S. Shicashankar, S. Mekhilef, H. Mokhlis and M. Karimi, "Mitigating methods of power fluctuation of photovoltaic (PV) sources - a review," *Renew Sustain Energy Rev*, pp. 1170-1184.
- [16] M. Diagne, M. David, P. Lauret, J. Boland and N. Schmutz, "Review of solar irradiance forecasting methods and a proposition for small-scale insular grids (in English)," *Renew Sustain Energy*, vol. 27, pp. 65-76.
- [17] e. a. Voyant C, "Machine learning methods for solar radiation forecasting: a review (in English)," *Renew Energy*, vol. 105, pp. 569-582, May 2017.
- [18] M. Raza and A. Khosravi, "A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings.," *Renew Sustain Energy Rev*, no. 50, pp. 1352-1372, 2015.
- [19] R. Marcos, A. Belloa and J. Reneses, "Electricity price forecasting in the short term hybridising fundamental and econometric modelling.," *Elec Power Syst Res*, vol. 167, pp. 240-251, 2019.
- [20] N. Amral, C. Ozveren and D. King, "Short term load forecasting using Multiple Linear Regression.," in *42nd international universities power engineering conference*, 2007.
- [21] e. a. Nespoli A, "Day-ahead photovoltaic forecasting: a comparison of the most effective techniques.," *Energies*, vol. 12, no. 9, p. 1621, 2019.
- [22] S. Sobri, S. Koohi-Kamali and N. Rahim, "Solar photovoltaic generation forecasting methods: a review.," *Energy Convers Manag*, vol. 156, pp. 459-497, 2018.
- [23] Y. Ren, P. Suganthan and N. Srikanth, "Ensemble methods for wind and solar power forecasting—a state-of-the-art review.," *Renew Sustain Energy Rev*, vol. 50, pp. 82-91, 2015.
- [24] Y. Ren, P. Suganthan and N. Srikanth, "Ensemble methods for wind and solar power forecasting—a state-of-the-art review.," *Renew Sustain Energy Rev*, vol. 50, pp. 82-91, 2015.
- [25] D. M. L. P. B. J. S. N. Diagne M, "Review of solar irradiance forecasting methods and a proposition for small-scale insular grids (in English)," *Sustain Energy Rev*, vol. 27, pp. 65-76, Nov 2013.
- [26] M. Behera, I. Majumder and N. Nayak, "Solar photovoltaic power forecasting using optimized modified extreme learning machine technique.," *Eng Sci Technol*, vol. 21, no. 3, pp. 524-538, 2018.

- [27] C. Garcia-Martios, J. Rodrigues and M. Sanchez, "Forecasting electricity prices and their volatilities using Unobserved Components.," *Energy Econ*, vol. 33, no. 6, pp. 1227-1239, 2011.
- [28] S. Torbagahan, A. Motamedi, H. Zareipour and L. Tuan, "Medium-term electricity price forecasting.," 2012.
- [29] I. Vehvileainen and T. Pyykkeonen, "Stochastic factor model for electricity spot price—the case of the Nordic market.," in *Energy Econ*, 2005.
- [30] T. Hong, J. Wilson and J. Xie, "Long term probabilistic load forecasting and normalization with hourly information.," *IEEE Trans Smart Grid*, vol. 5, no. 1, pp. 456-462, 2014.
- [31] J. Zhang, R. Verschae, S. Nobuhara and J.-F. Lalonde, "Deep photovoltaic nowcasting.," *Sol Energy*, vol. 176, pp. 267-276, 2018.
- [32] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca and F. Martinez-de-Pison, "Review of photovoltaic power forecasting.," *Sol Energy*, pp. 78-111, 2016.
- [33] H. Pedro and C. Coimbra, "Assessment of forecasting techniques for solar power production with no exogenous inputs.," *Sol Energy*, vol. 86, no. 7, pp. 2017-2028, 2012.
- [34] V. Lonij, A. Brooks, A. Cronin, M. Leuthold and K. Kock, "Intra-hour forecasts of solar power production using measurements from a network of irradiance," *Sol Energy*, pp. 58-66, 2013.
- [35] Z. Li, S. Rahman, R. Vega and B. Dong, "A hierarchical approach using machine learning methods in solar photovoltaic energy production forecasting.," *Energies*, 2016.
- [36] F. Almonacid, P. Perez-Higueras, E. Fernandez and L. Hontoria, "A methodology based on dynamic artificial neural network for short-term forecasting of the power output of a PV generator," *Energy Convers Manag*, pp. 389-398, 2014.
- [37] E. Lorenz, J. Kuehnert, B. Wolff, A. Hammer, O. Kramer and D. Heinemann, "PV power predictions on different spatial and temporal scales integrating PV measurements, satellite data and numerical weather predictions.," 2014.
- [38] e. a. Zhang J, "A suite of metrics for assessing the performance of solar power forecasting.," *Sol Energy*, vol. 111, pp. 157-175, 2015.
- [39] C. Chen, S. Duan, T. Cat and B. Liu, "Online 24-h solar power forecasting based on weather type classification using artificial neural network.," *Sol Energy*, vol. 85, no. 11, pp. 2856-2870, 2011.

- [40] e. a. Lu S, "Machine learning based multi-physical-model blending for enhancing renewable energy forecast - improvement via situation dependent error correction.," *European control conference*, pp. 283-290, 2015.
- [41] M. Zamo, O. Mestre, P. Arbogast and O. Pannekoucke, "A benchmark of statistical regression methods for short-term forecasting of photovoltaic electricity production.," *Sol Energy*, pp. 792-803, 2014.
- [42] M. Lipperheide, J. Bosch and J. Kleissl, "Embedded nowcasting method using cloud speed persistence for a photovoltaic power plant.," *Sol Energy*, pp. 232-238, 2015.
- [43] S. Monjoly, M. Andre, R. Calif and T. Soubdhan, "Forecast horizon and solar variability influences on the performances of multiscale hybrid forecast model.," *Energies*, vol. 12, no. 12, p. 2264, 2019.
- [44] J. Shi, W. Lee, Y. Liu, Y. Yang and P. Wang, "Forecasting power output of photovoltaic systems based on weather classification and support vector machines.," *IEEE Trans*, pp. 1064-1069, April 2015.
- [45] M. Almeida, O. Perpiñan and L. Narvate, "PV power forecast using a nonparametric PV model.," *Sol Energy*, pp. 354-368, 2015.
- [46] H. Yang, C. Huang, Y. Huang and Y. Pai, "A weather-based hybrid method for 1-day ahead hourly forecasting of PV power output.," *IEEE Trans Sustain Energy*, vol. 5, no. 3, pp. 917-926, 2014.
- [47] e. a. Wang F, "Generative adversarial networks and convolutional neural networks based weather classification model for day ahead short-term photovoltaic power forecasting.," *Energy Convers Manag*, pp. 443-462, 2019.
- [48] F. Lima, F. Martins, E. Pereira, E. Lorenz and D. Heinemann, "Forecast for surface solar irradiance at the Brazilian Northeastern region using NWP model and artificial neural networks.," *Renew Energy*, pp. 807-818, 2016.
- [49] F. Wang, Z. Zhen, C. Liu, M. Shafie-khan and J. Catalão, "Time-section fusion pattern classification based day-ahead solar irradiance ensemble forecasting model using mutual iterative optimization.," *Energies*, p. 184, 2018.
- [50] e. a. Wang H, "Deterministic and probabilistic forecasting of photovoltaic power based on deep convolutional neural network.," *Energy Convers Manag*, pp. 409-422, 2017.
- [51] A. Alzahrani, P. Shamsi, C. Dagli and M. Ferdowsi, "Solar irradiance forecasting using deep neural networks.," *Procedia Comput Sci*, vol. 114, pp. 304-13, 2017.

- [52] A. Ahmed and M. Khalid, "A review on the selected applications of forecasting models in renewable power systems.," *Renew Sustain Energy Rev*, vol. 100, pp. 9-21, 2019.
- [53] M. De Giorgi, P. Congedo and M. Malvoni, "Photovoltaic power forecasting using," *IET Sci Meas Technol*, vol. 8, no. 3, pp. 90-97, 2014.
- [54] K. Mohammadi and N. Goudatzi, "Study of inter-correlations of solar radiation, windspeed and precipitation under the influence of El Niño Southern Oscillation in California," *Renew Energy*, vol. 120, pp. 190-200, 2018.
- [55] D. Mukherjee and S. Acton, "Cloud tracking by scale space classification.," *IEEE Trans Geosci Rem Sens*, vol. 40, no. 2, pp. 405-415, 2002.
- [56] S. Rolf, R. Martin and P. Ehrahard, "An improvement of the IGMK model to derive total and diffuse solar radiation at the surface from satellite data.," *J Appl Meteorol*, pp. 586-603, 1990.
- [57] e. a. Escrig H, "Cloud detection, classification and motion estimation using geostationary satellite imagery for cloud cover forecast.," *Energy*, pp. 853-859.
- [58] M. Martinez-Chico, F. Batlles and J. Bosch, "Cloud classification in a mediterranean location using radiation data and sky images.," *Energy*, pp. 4055-4062, 2011.
- [59] Z. Peng, D. Yu, J. Heiser and P. Kalb, "A hybrid approach to estimate the complex motions of clouds in sky images.," *Sol Energy*, vol. 138, pp. 10-25, 2016.
- [60] R. SS., "Optimal scheduling of thermal-wind-solar power system with storage.," *Renew Energy*, pp. 1357-1368, 2017.
- [61] Z. Yang and J. Wang, "A hybrid forecasting approach applied in wind speed forecasting based on a data processing strategy and an optimized artificial intelligence algorithm.," *Energy*, vol. 160, pp. 87-100, 2018.
- [62] P. Bacher, H. Madsen and H. Nielsen, "Online short-term solar power forecasting.," *Sol Energy*, Vols. 1772-1783, 2009.
- [63] Y. Kemmoku, S. Orita, S. Nakagawa and T. Sakakibara, "Daily insolation forecasting using a multi-stage neural network.," *Sol Energy*, pp. 193-199, 1999.
- [64] A. Sfetsos and A. Coonick, "Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques.," *Sol Energy*, pp. 169-178, 2000.
- [65] R. G., "Predicting solar radiation at high resolutions: a comparison of time series forecasts.," *Sol Energy*, pp. 342-349, 2009.

- [66] A. Baig, P. Akhter and A. Mufti, "A novel approach to estimate the clear day global radiation.," *Renew Energy*, pp. 119-123, 1991.
- [67] K. SN., "New methodologies to estimate the hourly global solar radiation; Comparisons with existing models.," *Renew Energy*, pp. 781-790, 2006.
- [68] B. J., "Time series modelling of solar radiation. In: V B, editor. Modeling solar radiation at the earth's surface.," 2008.
- [69] C. Yang, A. Thatte and L. Xie, "Multitime-scale data-driven spatio-temporal forecast of photovoltaic generation," *IEEE Trans Sustain Energy*, pp. 104-112, 2015.
- [70] D. Alhakeem, P. Mandal, A. Haque, A. Yona, T. Seniyu and T. Tseng, "A new strategy to quantify uncertainties of wavelet-GRNN-PSO based solar PV power forecasts using bootstrap confidence intervals.," in *In: 2015 IEEE power & energy society*.
- [71] A. Aghajani, R. Kazemzadeh and Ebrahimi, "A novel hybrid approach for predicting wind farm power production based on wavelet transform, hybrid neural networks and imperialist competitive algorithm.," *Energy Convers Manag*, vol. 121, pp. 232-240, 2016.
- [72] Z. Du, M. Qin, F. Zhang and R. Liu, "Multistep-ahead forecasting of chlorophyll a using a wavelet nonlinear autoregressive network.," *Knowl Base Syst*, pp. 61-70, 2018.
- [73] Q. M. Z. F. L. R. Du Z, "Multistep-ahead forecasting of chlorophyll a using a wavelet nonlinear autoregressive network.," 2018.
- [74] S. Al-Dahidi, O. Ayadi, J. Adeeb and B. Qawasmeh, "Extreme learning machines for solar photovoltaic power predictions.," *Energies*, vol. 11, no. 10, p. 2725, 2018.
- [75] H. Alomari Mohammad, Adeeb Jehad and O. Younis, "Solar photovoltaic power forecasting in Jordan using artificial neural networks.," *Int J Electr Comput Eng*, pp. 497-504, 2018.
- [76] A. Vaz, B. Elsinga, v. W. Sark and M. Brito, "An artificial neural network to assess the impact of neighbouring photovoltaic systems in power forecasting in Utrecht, The Netherlands.," *Renew Energy*, Vols. 631-641, 2016.
- [77] H. Zhu, X. Li, Q. Sun, L. Nie, J. Yao and G. Zhao, "A power prediction method for photovoltaic power plant based on wavelet decomposition and artificial neural networks.," *Energies*, January 2016.
- [78] J. Zhao, Z.-H. Guo, Z.-Y. Su, X. Xiao and F. Liu, "An improved multi-step forecasting model based on WRF ensembles and creative fuzzy systems for wind speed," *Appl Energy*, pp. 808-826, 2016.

- [79] A. Zammer, J. Arshad, A. Khan and M. Raja, "Intelligent and robust prediction of short term wind power using genetic programming based ensemble of neural networks.," *Energy Convers Manag*, pp. 361-372, 2017.
- [80] E. Geoffrey, O. Simon and T. Yee-Whye, "A fast learning algorithm for deep belief nets.," *Neural Comput*, pp. 527-554, 2006.
- [81] Z. Lin and X. Liu, "Assessment of wind turbine aero-hydro-servo-elastic modelling on the effects of mooring line," *Energies*, p. 2264, 2020.
- [82] J. Zhang, J. Yan, D. Infield, Y. Liu and F. Lien, " Short-term forecasting and uncertainty analysis of wind turbine power based on long short-term memory network and Gaussian mixture model.," *Appl. Energy*, pp. 229-244, 2019.
- [83] Y. Zhao, L. Ye, Z. Li, X. Song, Y. Lang and J. Su, "A novel bidirectional mechanism based on time series model for wind power forecasting.," *Appl Energy*, pp. 793-803, 2016.
- [84] X. Wang, P. Guo and X. Huang, "Energy Procedia A Review of Wind Power Forecasting Models.," *Energy Procedia*, pp. 770-778, 2011.
- [85] S. Singh, T. Bhatti and D. Kothari, "Wind power estimation using artificial neural network.," *J. Energy Eng.*, pp. 46-52, 2007.
- [86] R. Sharma and D. Singh, " A Review of Wind Power and Wind Speed Forecasting.," *Rahul Sharma J. Eng. Res. and Appl.*, pp. 1-9, 2018.
- [87] Y. Zhao, L. Ye, Z. Li, X. Song, Y. Lang and J. Su, "A novel bidirectional mechanism based on time series model for wind power forecasting.," *Appl. Energy*, pp. 793-803.
- [88] S. Soman, H. Zareipour and O. Malik, "A review of wind power and wind speed forecasting methods with different time horizons.," in *In Proceedings of the 2010 North American Power Symposium (NAPS)*, Arlington, TX, USA,, 2010.
- [89] M. De Felice, A. Alessandri and P. Ruti, "Electricity demand forecasting over Italy: Potential benefits using numerical weather prediction models.," *Electr. Power Syst. Res.*, pp. 71-79, 2013.
- [90] Y. Wu and J. Hong, "A literature review of wind forecasting technology in the world."
- [91] M. De Giorgi, A. Ficarella and M. Tarantino, "Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods.," *Energy*, pp. 3968-3978, 2011.
- [92] J. Jung and R. Broadwater, "Current status and future advances for wind speed and power forecasting.," *Renew Sustain. Energy Rev.*, pp. 762-777, 2014.

- [93] S. Jung and S. Kwon, "Weighted error functions in artificial neural networks for improved wind energy potential estimation.," *Appl Energy*, pp. 778-790, 2013.
- [94] Y. Wu and H. Zhao, "Optimization maintenance of wind turbines using Markov decision processes. In Proceedings of the 2010 International Conference on Power System Technology: Technological Innovations," in *In Proceedings of the 2010 International Conference on Power System Technology: Technological Innovations*, Hangzhou, China, 2010.
- [95] Z. Lin and X. Liu, "Wind power forecasting of an offshore wind turbine based on high-frequency SCADA data and deep learning neural network.," *Energy* 2020.
- [96] A. Marugán, F. Márquez and J. Perez, "A survey of artificial neural network in wind energy systems.," *Appl. Energy*, Vols. 1822-1836, 2018.
- [97] M. Jyothi and P. Rao, "Very-short term wind power forecasting through Adaptive wavelet neural network.," in *In Proceedings of the 2016-Biennial International Conference on Power and Energy Systems: Towards Sustainable Energy, PESTSE 2016*, Bengaluru, India,, 2016.
- [98] B. Bilal, M. Ndong, K. Adjallah, A. Sava, C. Kebe, P. Ndiaye and V. Sambou, "Wind turbine power output prediction model design based on artificial neural networks and climatic spatiotemporal data.," in *In Proceedings of the IEEE International Conference on Industrial Technology 2018*, Lyon, France,, 2018.
- [99] W. Chang, " Application of Back Propagation Neural Network for Wind Power Generation Forecasting.," 2013.
- [100] Y. Hong and C. Rioflorido, "A hybrid deep learning-based neural network for 24-h ahead wind power forecasting.," *Appl. Energy*, pp. 530-539, 2019.
- [101] A. Foley, P. Leahy, A. Marvuglia and E. McKeogh, "Current methods and advances in forecasting of wind power generation.," *Renew. Energy*, pp. 1-8, 2012.
- [102] P. Louka, G. Galanis, N. Siebert, G. Kariniotakis, P. Katsafados, I. Pytharoulis and G. Kallos, "Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering.," *J. Wind Eng. Ind. Aerodyn.*, Vols. 2348-2362, 2008.
- [103] L. Ziegler, E. Gonzalez, T. Rubert, U. Smolka and J. Melero, "Lifetime extension of onshore wind turbines: A review covering Germany, Spain, Denmark, and the UK.," *Renew. Sustain. Energy Rev*, pp. 1261-1271, 2018.
- [104] W. Yang, R. Court and J. Jiang, "Wind turbine condition monitoring by the approach of SCADA data analysis.," *Renew. Energy*, pp. 365-376, 2013.

- [105] M. De Giorgi, A. Ficarella and M. Tarantino, " Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods.," *Energy*, pp. 3968-3978, 2011.
- [106] M. Lydia, S. Kumar, A. Selvakumar and G. Prem Kumar, " A comprehensive review on wind turbine power curve modeling techniques," *Renew. Sustain. Energy Rev.*, pp. 452-460, 2014.
- [107] J. Zheng, C. Xu and X. Li, "Electric load forecasting in smart grid using long-short-term-memory based recurrent neural network," 2017.
- [108] B.Liu, "Short-term load forecasting of distributed energy supply system based on Elman neural network.," in *In Proceedings of the 2018 China International Conference on Electricity Distribution*, Ljubljana, Slovenia, 2018.
- [109] M. Zhang, "Short-term load forecasting based on support vector machines regression.," in *In Proceedings of the 2005 International Conference on Machine Learning and Cybernetics*, Guangzhou, China,, 18–21 August 2005.
- [110] R. Abdel-Aal, M. Elhadidy and S. Shaahid, "Modeling and forecasting the mean hourly wind speed time series using GMDH-based abductive networks.," *Renew. Energy*, pp. 1686-1699, 2009.
- [111] R. Mohammadmehdi , P. Giang , H. R. Gholam, H. Robert, N. Behrooz, C. Enrico and N. Ehsan, "Combination of X-ray tube and GMDH neural network as a nondestructive and potential technique for measuring characteristics of gas-oil–water three phase flows," *Measurement*, vol. 168, 2021.
- [112] W. Yaoli, W. Lipo, Y. Fangjun, D. Wenxia and C. Qing, "Advantages of direct input-to-output connections in neural networks: The Elman network for stock index forecasting," *Information Sciences*, vol. 547, pp. 1066-1079, 2021.
- [113] L. Luan, L. Shiayang, S. Sihao, Y. Yaqi and Y. Ming, "A novel efficient model for gas compressibility factor based on GMDH network," *Flow Measurement and Instrumentation*, vol. 71, 2020.
- [114] M. Behera, I. Majumder and N. Nayak, "Solar photovoltaic power forecasting using optimized modified extreme learning machine technique.," *Eng Sci Technol*, pp. 428-438, 2018.