



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

**ΠΙΘΑΝΟΤΙΚΗ ΠΡΟΒΛΕΨΗ ΑΙΟΛΙΚΗΣ  
ΠΑΡΑΓΩΓΗΣ ΜΕ ΤΗ ΧΡΗΣΗ EXTREME  
LEARNING MACHINES**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΣΚΕΥΗΣ Γ. ΔΙΟΝΥΣΗΣ

Επιβλέπων : ΝΙΚΟΛΑΟΣ ΧΑΤΖΗΑΡΓΥΡΙΟΥ  
Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2020





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

## ΠΙΘΑΝΟΤΙΚΗ ΠΡΟΒΛΕΨΗ ΑΙΟΛΙΚΗΣ ΠΑΡΑΓΩΓΗΣ ΜΕ ΤΗ ΧΡΗΣΗ EXTREME LEARNING MACHINES

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΣΚΕΥΗΣ Γ. ΔΙΟΝΥΣΗΣ

Επιβλέπων : ΝΙΚΟΛΑΟΣ ΧΑΤΖΗΑΡΓΥΡΙΟΥ  
Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 22η Οκτωβρίου 2020.

.....  
Ν. Χατζηαργυρίου  
Καθηγητής ΕΜΠ

.....  
Σ. Παπαθανασίου  
Καθηγητής ΕΜΠ

.....  
Π. Γεωργιλάκης  
Επ. Καθηγητής ΕΜΠ

Αθήνα, Οκτώβριος 2020

.....  
Σκεύης Γ. Διονύσης

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

Copyright © Σκεύης Γ. Διονύσης, 2020

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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

## Περίληψη

Τα τελευταία χρόνια έχει σημειωθεί μεγάλη αύξηση του ποσοστού της ηλεκτρικής ενέργειας που προέρχεται από αιολικούς σταθμούς παραγωγής. Η αύξηση αυτή όμως, συνοδεύεται και από προβλήματα σταθερότητας του δικτύου, καθώς η αδυναμία της ανθρώπινης παρέμβασης στην παραγωγή καθιστά αβέβαιη την εξισορρόπηση προσφοράς και ζήτησης. Το γεγονός αυτό, καθιστά υψίστης σημασίας την ακριβή πρόβλεψη αιολικής παραγωγής σε βραχυπρόθεσμο ορίζοντα πρόβλεψης για την βέλτιστη συμπαραγωγή αιολικών και συμβατικών σταθμών παραγωγής. Εφόσον η χαοτική φύση της ατμόσφαιρας καθιστά αδύνατη την ακριβή πρόβλεψη παραγωγής, τα τελευταία χρόνια αναπτύσσονται ολοένα και περισσότερα μοντέλα πιθανοτικής πρόβλεψης με σκοπό την ποσοτικοποίηση της αβεβαιότητας των σημειακών προβλέψεων.

Σκοπός της παρούσας διπλωματικής εργασίας αποτελεί η ανάπτυξη ενός τέτοιου πιθανοτικού μοντέλου πρόβλεψης αιολικής παραγωγής με χρήση Extreme Learning Machines. Πιο συγκεκριμένα, επανασχεδιάστηκε, το state-of-the-art μοντέλο πολύ-βραχυπρόθεσμης πρόβλεψης (χρονικός ορίζοντας μιας ώρας) που αναπτύχθηκε σε προηγούμενη έρευνα[8], και αξιολογήθηκε η επίδοση του στην παραγωγή βραχυπρόθεσμων προβλέψεων (χρονικός ορίζοντας μιας ημέρας). Για την ανάπτυξη και αξιολόγηση του μοντέλου χρησιμοποιήθηκαν ιστορικά δεδομένα ενός έτους, τα οποία αποτελούνταν από τις προβλέψεις ανέμου και της αντίστοιχες τιμές παραγόμενης ισχύος σε ωριαία βάση. Τα δεδομένα αποτελούν μέρος των δεδομένων που του δόθηκαν στους συμμετέχοντες στον διεθνή διαγωνισμό Global Energy Forecasting Competition 2014 και αφορούν έναν αιολικό σταθμό στην Αυστραλία.

Αρχικά, σχεδιάστηκε εκ βάθρων ένα μοντέλο ντετερμινιστικής πρόβλεψης βασισμένο στα Extreme Learning Machines, μοντελοποιώντας την μαθηματική θεωρία που διέπει την λειτουργία τους σε προγραμματιστικό περιβάλλον Python. Στην συνέχεια έγινε μια προσπάθεια προεπεξεργασίας των δεδομένων για την βελτίωση της ακρίβειας του σφάλματος ντετερμινιστικής πρόβλεψης. Για την παραγωγή πιθανοτικών προβλέψεων αιολικής παραγωγής χρησιμοποιήθηκε η μέθοδος προβλέψεων συνόλου. Με την στατιστική μέθοδο Bootstrapping δημιουργήθηκε μια πληθώρα νέων συνόλων δεδομένων εκπαίδευσης και χρησιμοποιήθηκε ο αντίστοιχος αριθμός ντετερμινιστικών μοντέλων για την παραγωγή σημειακών προβλέψεων επί του ίδιου συνόλου δεδομένων εκπαίδευσης. Τέλος, χρησιμοποιώντας την θεωρία πιθανοτήτων και στατιστικής κατασκευάστηκαν τα διαστήματα εμπιστοσύνης για την ποσοτικοποίηση την αβεβαιότητας των προβλέψεων. Εκ των αποτελεσμάτων, διαπιστώθηκε πως για την αξιόπιστη παραγωγή πιθανοτικών προβλέψεων, είναι απαραίτητη η μεταβολή του αριθμού των ντετερμινιστικών μοντέλων που θα χρησιμοποιήσουμε, ανάλογα με τον επιθυμητό βαθμό εμπιστοσύνης.

Κλείνοντας αξίζει να σημειωθεί, πως είναι απαραίτητη η θεμελίωση των αποτελεσμάτων σε ένα ευρύτερο πλαίσιο δεδομένων ώστε να αξιολογηθεί, πέραν της αξιοπιστίας, και η ποιότητα των αποτελεσμάτων που παρήγαγε το πιθανοτικό μοντέλο που αναπτύχθηκε.

**Λέξεις Κλειδιά:** πιθανοτική πρόβλεψη, Extreme Learning Machines, αιολική ισχύς, Bootstrapping, διάστημα εμπιστοσύνης, πρόβλεψη αιολικής παραγωγής, σφάλμα πρόβλεψης, αριθμητικές προβλέψεις καιρού



## Abstract

In recent years, there has been a great increase in the percentage of electrical energy that stems from wind power plants. However, this increase is also accompanied by network stability problems, since the incapacity of human intervention towards production renders the balancing between offer and demand uncertain. This fact makes, the accurate short-term prediction of wind power, of great importance for the optimal co-production of wind and conventional power plants. Since the chaotic nature of atmosphere renders the accurate production prediction unfeasible, more and more models of probabilistic prediction are developed, with the aim of quantifying the uncertainty of spot predictions.

The aim of the current thesis is the development of such a probabilistic prediction model of wind power by utilizing Extreme Learning Machines. In particular, the state-of-the-art very short-term prediction model (of a prediction horizon of one hour) that was developed in a previous study [8] has been redesigned, and its performance in the production of short-term predictions (of a prediction horizon of one day) has been evaluated. For the development and evaluation of the model, historical data of one year have been utilized, data which consist of the wind predictions and the corresponding values of produced power on an hourly basis. The data, which pertain to a wind plant in Australia, comprise part of the data that was provided to the participants in the Global Energy Forecasting Competition 2014.

Initially, a deterministic prediction model based on Extreme Learning Machines was designed, by modeling the mathematical theory that regulates their function on a Python programming interface. Subsequently, an attempt to pre-process the data for the accuracy enhancement of deterministic prediction error was made. For the production of probabilistic wind power predictions, an ensemble forecast method was employed. With the aid of the statistical method Bootstrapping, an abundance of new training data sets was created, and the respective number of deterministic models for the production of spot predictions of the total training data was utilized. Finally, by employing the theory of probability and statistics, the confidence intervals for the quantification of prediction uncertainty were devised. Ensuing from that, it was ascertained that for a reliable production of probabilistic predictions, the modification of the number of deterministic models that are going to be utilized is essential, depending on the desired confidence interval.

In closing, it should be noted that the establishment of the results on a wider data framework is essential, in order for, along with the reliability, the quality of the results produced by the developed probabilistic model to be evaluated.

**Key words:** probabilistic forecasting, Extreme Learning Machines, wind power, Bootstrapping, confidence intervals, wind power forecasting, forecast error, numerical weather prediction





Ευχαριστώ θερμά τον κ. Ν. Χατζηαργυρίου Καθηγητή ΕΜΠ για την δυνατότητα που μου έδωσε για την εκπόνηση της παρούσας διπλωματικής εργασίας.

Επίσης, ευχαριστώ ιδιαίτερα τον υποψήφιο Διδάκτορα Θ. Κωνσταντίνου για την πολύτιμη καθοδήγηση και βοήθεια του.



# Περιεχόμενα

## **Κεφάλαιο 1:** Εισαγωγή

1.1	Αιολική Παραγωγή Ενέργειας.....	15
1.2	Η Σημασία της Πρόβλεψης στην Αιολική Παραγωγή.....	16
1.3	Η Μετάβαση στα Πιθανοτικά Μοντέλα.....	17
1.4	Δομή.....	17

## **Κεφάλαιο 2:** Βιβλιογραφική Ανασκόπηση

2.1	Εισαγωγή.....	20
2.2	Πιθανοτική πρόβλεψη με Random Forests και Gradient Boosting Detection Trees.....	20
2.3	Πιθανοτική πρόβλεψη με Gradient Boosting Detection Machines.....	21

## **Κεφάλαιο 3:** Αριθμητικές Προβλέψεις Καιρού

3.1	Εισαγωγή.....	23
3.2	Λειτουργία Μοντέλων Αριθμητικών Προβλέψεων Καιρού.....	24
3.2.1	Συλλογή Παρατηρήσεων.....	25
3.2.2	Διαδικασία Αφομοίωσης Δεδομένων.....	25
3.2.3	Μαθηματική Μοντελοποίηση της Ατμόσφαιρας.....	27
3.2.4	Χαρακτηριστικά Μοντέλων Αριθμητικών Προβλέψεων Καιρού.....	28
3.2.4.1	Πλεγματικά Σημεία και Φασματική Ανάλυση.....	28
3.2.4.2	Ανάλυση Μοντέλων.....	30
3.2.4.3	Τομέας Κάλυψης.....	31

3.2.4.4 Υδροστατική και Μη-υδροστατική προσέγγιση.....	32
3.2.5 Παραμετροποίηση.....	33
3.3: Σύγχρονα Μοντέλα Αριθμητικών Προβλέψεων Καιρού.....	34

#### **Κεφάλαιο 4:** Πρόβλεψη Αιολικής Παραγωγής

4.1 Εισαγωγή.....	37
4.2 Φυσική και Στατιστική Προσέγγιση.....	37
4.3 Το Πρόβλημα της Φυσικής Προσέγγισης.....	38

#### **Κεφάλαιο 5:** Εκτίμηση Σφάλματος

5.1 Εισαγωγή.....	43
5.2 Σφάλμα πρόβλεψης.....	44
5.3 Bias.....	44
5.4 Μετρητικά Σφάλματος Σημειακής Πρόβλεψης.....	45
5.5 Μετρητικά Σφάλματος Πιθανοτικής Πρόβλεψης.....	47

#### **Κεφάλαιο 6:** Τεχνητά Νευρωνικά Δίκτυα

6.1 Εισαγωγή.....	48
6.2 Βασική Δομή Νευρωνικών Δικτύων.....	48
6.3 Εκπαίδευση Νευρωνικών Δικτύων.....	50
6.3.1 Επιτηρούμενη Μάθηση.....	51
6.3.2 Μη-Επιτηρούμενη Μάθηση.....	52
6.4 Backpropagation.....	52
6.5 Extreme Learning Machines.....	53

#### **Κεφάλαιο 7:** Μοντέλο Πιθανοτικής Πρόβλεψης

7.1 Εισαγωγή.....	57
-------------------	----

7.2	Bootstrapping.....	57
7.3	Παραγωγή Διαστημάτων Εμπιστοσύνης.....	58
7.4	Αξιολόγηση Αξιοπιστίας.....	59
7.5	Αξιολόγηση Διαστημάτων Εμπιστοσύνης.....	60

### **Κεφάλαιο 8:** Περιγραφή Πιθανοτικού Μοντέλου Αιολικής Ισχύος

8.1	Ανάλυση Δεδομένων.....	62
8.2	Ανάπτυξη μοντέλου ELM για την Παραγωγή Σημειακής Πρόβλεψης.....	63
8.3	Cross-Validation Ντετερμινιστικών Μοντέλων ELM.....	72
	8.3.1 K-Fold Cross-Validation.....	72
	8.3.2 Καθορισμός Υπερπαραμέτρων με 4-Fold Cross-Validation.....	73
8.4	Επεξεργασία δεδομένων.....	78
	8.4.1 Μετατροπή Προβλέψεων σε Πολικό Σύστημα Συντεταγμένων.....	78
	8.4.2 Κανονικοποίηση Προβλέψεων Ανέμου.....	79
8.5	Μοντέλο Πιθανοτικής Πρόβλεψης.....	80

### **Κεφάλαιο 9:** Επίλογος

9.1	Σύνοψη και Συμπεράσματα.....	92
9.2	Μελλοντικές Επεκτάσεις.....	92

### **Βιβλιογραφία:**.....95

### **Παράρτημα:**

	Περιεχόμενα σχημάτων.....	99
	Περιεχόμενα πινάκων.....	100




# Κεφάλαιο 1: Εισαγωγή

## 1.1: Αιολική Παραγωγή Ενέργειας

Την τελευταία δεκαετία παρατηρείται ραγδαία αύξηση της ηλεκτρικής ενέργειας που παρέχεται στο ηλεκτρικό δίκτυο από Ανανεώσιμες Πηγές Ενέργειας (ΑΠΕ). Η απελευθέρωση της ευρωπαϊκής αγοράς ηλεκτρικής ενέργειας σε συνδυασμό με τις επενδύσεις στον τομέα αυτόν, αναμένεται να διατηρήσουν τον ρυθμό αύξησης σε υψηλά επίπεδα. Στην Ευρώπη, η Ευρωπαϊκή Επιτροπή υπολογίζει πως το μερίδιο της παραγόμενης ηλεκτρικής ενέργειας από ΑΠΕ θα ανέλθει το 2030 τουλάχιστον στο 45% από το 21% που ήταν το 2015[1].

Από τις Ανανεώσιμες Πηγές Ενέργειας, η αιολική ενέργεια αποτελεί την ταχύτερα αναπτυσσόμενη. Με τον όρο αιολική παραγωγή ενέργειας περιγράφουμε την διαδικασία της μετατροπής της κινητικής ενέργειας του ανέμου σε ηλεκτρική μέσω των ανεμογεννητριών στους αιολικούς σταθμούς παραγωγής. Σε αρκετές ευρωπαϊκές χώρες οι αιολικοί σταθμοί παραγωγής αποτελούν τις κύριες πηγές ηλεκτρικής ενέργειας. Ενδεικτικά, στην Δανία το 2019 η αιολική ενέργεια κατείχε το 48% της αγοράς στην ετήσια ζήτηση και στην Ιρλανδία το 33%. Η ενσωμάτωση όλο και περισσότερων σταθμών αιολικής παραγωγής διαφαίνεται και σε ευρωπαϊκό επίπεδο καθώς η συνολική εγκατεστημένη αιολική ισχύς στην Ευρώπη ανερχόταν το 2019 στα 205GW από τα 77 GW συνολικής αιολικής ισχύος το 2009[2], όπως φαίνεται το σχήμα 1.1. Η ραγδαία όμως αύξηση του μεριδίου της αγοράς που καταλαμβάνει η αιολική παραγωγή ενέργειας αναδεικνύει νέα προβλήματα στην διαχείριση και την αξιοπιστία του συστήματος ηλεκτρικής ενέργειας.



Σχήμα 1.1

## 1.2: Η Σημασία της Πρόβλεψης στην Αιολική Παραγωγή Ενέργειας

Το κυριότερο πρόβλημα έγκειται στην τυχαιότητα που παρουσιάζει η ατμόσφαιρα της γης, η οποία οδηγεί σε μεγάλη μεταβλητότητα στην παραγωγή ηλεκτρικής ενέργειας από αιολικά πάρκα και δρα ως περιοριστικός παράγοντας για την αύξηση του μεριδίου της αγοράς το οποίο καταλαμβάνουν. Για την διατήρηση της σταθερότητας ενός Συστήματος Ηλεκτρικής Ενέργειας, με μεγάλη παραγωγή ηλεκτρικής ενέργειας από αιολικά πάρκα, είναι απαραίτητο να γνωρίζουμε εκ των προτέρων την ηλεκτρική ενέργεια που παρέχεται από αυτά, η οποία σε συνδυασμό με άλλες λιγότερο μεταβλητές και πιο προβλέψιμες, ως προς την παραγωγή, πηγές ενέργειας (φυσικό αέριο, λιγνίτης) να έχουν την δυνατότητα να καλύψουν την ζήτηση.

Εάν υπάρξει απόκλιση μεταξύ της προβλεπόμενης και της παραγόμενης ηλεκτρικής ενέργειας ενός αιολικού πάρκου, η διαφορά αυτή θα πρέπει να καλυφθεί από συμπληρωματικά αποθέματα ενέργειας τα οποία αυξάνουν το κόστος της λειτουργίας του εκάστοτε αιολικού πάρκου. Το γεγονός αυτό καταδεικνύει πως, η όσο το δυνατόν καλύτερη βραχυπρόθεσμη πρόβλεψη παραγωγής ενός αιολικού πάρκου, δεν είναι απαραίτητη μόνο για την ομαλή λειτουργία του δικτύου ηλεκτρικής ενέργειας αλλά αφορά άμεσα και τους διαχειριστές του εκάστοτε πάρκου, ώστε να είναι σε θέση να ελαχιστοποιήσουν το κόστος λειτουργίας. Το κόστος που οφείλεται στο σφάλμα πρόβλεψης της παραγωγής έχει υπολογιστεί πως μπορεί να φτάσει το 10% των συνολικών εσόδων από την πώληση ηλεκτρικής ενέργειας.

Η ανάγκη για ακριβείς και αξιόπιστες προβλέψεις ώστε να διασφαλιστεί η ομαλή λειτουργία του συστήματος ηλεκτρικής ενέργειας και η ελαχιστοποίηση του κόστους λειτουργίας των αιολικών πάρκων οδήγησε στην ανάπτυξη πολλών συστημάτων προβλέψεων, τα οποία χρησιμοποιούνται στην βιομηχανία. Οι προβλέψεις κατηγοριοποιούνται σε δύο ομάδες: τις ντετερμινιστικές και τις πιθανοτικές προβλέψεις. Τα προηγούμενα χρόνια, το μεγαλύτερο μέρος της έρευνα έχει επικεντρωθεί στην ντετερμινιστική πρόβλεψη, δηλαδή στην παραγωγή όσο το δυνατόν ακριβέστερων σημειακών προβλέψεων για την παραγωγή. Αν και έχουν αναπτυχθεί συστήματα με πολύ καλή ακρίβεια στην ντετερμινιστική πρόβλεψη, είναι σχεδόν απίθανη, αν όχι ακατόρθωτη, η πλήρης γνώση μελλοντικών γεγονότων ειδικά όταν αυτή αφορά την ατμοσφαιρική συμπεριφορά. Για αυτόν τον λόγο το σφάλμα, το οποίο παρουσιάζουν τα σύγχρονα συστήματα σημειακών προβλέψεων εξακολουθεί να είναι αρκετά μεγάλο, ώστε να εμποδίζει την βέλτιστη λειτουργία των αιολικών πάρκων.

Το σφάλμα πρόβλεψης παραγωγής ηλεκτρικής ενέργειας, οφείλεται τόσο στην δυνατότητα των ίδιων των μοντέλων πρόβλεψης όσο και στα συστήματα αριθμητικής πρόβλεψης καιρού. Υπάρχουν περίοδοι κατά τις οποίες οι δυναμικές που αναπτύσσονται στην ατμόσφαιρα



οδηγούν σε πολύ ακριβείς προβλέψεις, ενώ σε άλλες χρονικές περιόδους καθιστούν τη αριθμητική πρόβλεψη καιρού πολύ δύσκολη ανεξάρτητα με την μέθοδο πρόβλεψης που έχει εφαρμοστεί. Κατά συνέπεια, εφόσον οι προβλέψεις παραγωγής ισχύος προκύπτουν από μη γραμμικούς μετασχηματισμούς καιρικών προβλέψεων, το σφάλμα το οποίο υπάρχει σε αυτές μεταφέρεται και πολλαπλασιάζεται μέσω του μετασχηματισμού.

### **1.3: Η Μετάβαση στα Πιθανοτικά Μοντέλα**

Ο κορεσμός που έχει επέλθει στην βελτίωση της ντετερμινιστικής πρόβλεψης, λόγω των φυσικών περιορισμών που υπάρχουν, έχει οδηγήσει, την τελευταία δεκαετία, τους ερευνητές στην ανάπτυξη συστημάτων πιθανοτικής πρόβλεψης παραγωγής ηλεκτρικής ενέργειας. Τα συστήματα αυτά δεν περιορίζονται στην παραγωγή μια σημειακής πρόβλεψης για μια χρονική στιγμή αλλά παρέχουν συναρτήσεις πυκνότητας πιθανότητας από τις οποίες μπορούμε να υπολογίσουμε την πιθανότητα μελλοντικών γεγονότων να συμβούν. Η ανάπτυξη και εφαρμογή των πιθανοτικών μοντέλων πρόβλεψης προσφέρει νέες πληροφορίες, οι οποίες σε συνδυασμό με τα υπάρχοντα δεδομένα από τα ντετερμινιστικά μοντέλα βοηθούν στην καλύτερη πρόβλεψη μελλοντικών φαινομένων και την κατανόηση τους.

Οι πληροφορίες που μας παρέχει η πιθανοτική πρόβλεψη παραγωγής ηλεκτρικής ενέργειας και η ποσοτικοποίηση της αβεβαιότητας των προβλέψεων αποτελούν αντικείμενο ερευνών, τα αποτελέσματα των οποίων φανερώνουν πως είναι υψίστης σημασίας, όχι μόνο για την διασφάλιση της ομαλής λειτουργίας του Συστήματος Ηλεκτρικής Ενέργειας, αλλά και για τον προγραμματισμό της λειτουργίας ενός αιολικού πάρκου και την βελτιστοποίηση της οικονομικής διαχείρισής τους. Ενδεικτικά όπως αναφέρεται στο [4] οι δείκτες αβεβαιότητας που μας παρέχει η πιθανοτική πρόβλεψη μπορούν να χρησιμοποιηθούν τόσο στον προγραμματισμό της συντήρησης του εξοπλισμού, όσο και στην διαμόρφωση λιγότερο συντηρητικών στρατηγικών στην συμμετοχή στο εμπόριο ηλεκτρικής ενέργειας.

### **1.4: Δομή**

Στα πλαίσια της παρούσας διπλωματικής εργασίας, αναπτύχθηκε ένα τέτοιο σύστημα πιθανοτικής πρόβλεψης παραγωγής ηλεκτρικής ενέργειας από ανεμογεννήτριες, το οποίο είναι εμπνευσμένο και ακολουθεί την δομή ενός state-of-the-art συστήματος πρόβλεψης, όπως αυτό περιγράφεται στο [8]. Αν και η αρχιτεκτονική του συστήματος θα παρουσιαστεί αναλυτικά στα επόμενα κεφάλαια θα πρέπει να σημειωθεί πως η δομή του βασίζεται στα Extreme Learning

Machines, τα οποία αποτελούν μια νέα προσέγγιση στην εκπαίδευση νευρωνικών δικτύων. Για την εκπαίδευση και την αξιολόγηση του συστήματος, χρησιμοποιήθηκαν τα δεδομένα που δόθηκαν στους συμμετέχοντες στον διεθνή διαγωνισμό Global Energy Forecasting Competition 2014. Τα δεδομένα αυτά περιλαμβάνουν χρονοσειρές προβλέψεων αέρα σε ωριαία βάση, για δέκα αιολικά πάρκα, σε δύο υψόμετρα (10m και 100m από την επιφάνεια του εδάφους) όπως αυτά λήφθηκαν από το European Centre for Medium-range Weather Forecasts (ECMWF) καθώς επίσης και την πραγματική παραγωγή ισχύος του εκάστοτε αιολικού πάρκου, η οποία αντιστοιχεί στις προαναφερθείσες προβλέψεις. Όσον αφορά τα δεδομένα ισχύος, θα πρέπει να αναφέρουμε πως οι μετρήσεις ισχύος έχουν κανονικοποιηθεί με βάση την ονομαστική ισχύ παραγωγής του αντίστοιχου αιολικού πάρκου.

Στο κεφάλαιο 2 γίνεται η βιβλιογραφική ανασκόπηση, όπου παρουσιάζονται τα μοντέλα των τριών πρώτων ομάδων του διαγωνισμού Global Energy Forecasting Competition 2014 τα δεδομένα του οποίου χρησιμοποιήσαμε για την αξιολόγηση των μοντέλων.

Στο κεφάλαιο 3 παρουσιάζονται οι βασικές διεργασίες που απαιτούνται για την παραγωγή των αριθμητικών προβλέψεων καιρού, ο τρόπος με τον οποίο μοντελοποιείται η ατμοσφαιρική συμπεριφορά και τέλος, παρουσιάζονται δύο σύγχρονα μοντέλα παραγωγής αριθμητικών προβλέψεων καιρού.

Στο κεφάλαιο 4 αναλύεται η σημασία της πρόβλεψης αιολικής παραγωγής για την ευσταθή λειτουργία των αιολικών σταθμών και τα προβλήματα που καλείται να αντιμετωπίσει ένα μοντέλο με σκοπό την ελαχιστοποίηση του σφάλματος πρόβλεψης.

Στο κεφάλαιο 5 παρατίθενται τα πιο διαδεδομένα μετρητικά σφάλματος που χρησιμοποιούνται για την αξιολόγηση της ακρίβειας τόσο των σημειακών όσο και των πιθανοτικών προβλέψεων.

Στο κεφάλαιο 6 αρχικά γίνεται μια σύντομη παρουσίαση της γενικότερης δομής και της διαδικασίας της εκμάθησης των νευρωνικών δικτύων. Στην συνέχεια, περιγράφονται πλήρως τα Extreme Learning Machines, τα οποία αποτελούν τα τεχνητά νευρωνικά δίκτυα που χρησιμοποιήθηκαν για την ανάπτυξη των μοντέλων πρόβλεψης της παρούσας διπλωματικής εργασίας.

Στο κεφάλαιο 7 παρουσιάζεται ο τρόπος παραγωγής της πιθανοτικής πρόβλεψης παραγωγής ισχύος μέσω της δημιουργίας ενός συνόλου μοντέλων (ensemble models) χρησιμοποιώντας την τεχνική του bootstrapping, καθώς και τα στοιχεία της θεωρίας πιθανοτήτων που εφαρμόστηκαν για την παραγωγή των διαστημάτων εμπιστοσύνης.

Στο κεφάλαιο 8 παρατίθεται αρχικά η διαδικασία της ανάπτυξης του μοντέλου πιθανοτικής πρόβλεψης αιολικής παραγωγής περιγράφοντας αναλυτικά όλα τα στάδια που ακολουθήθηκαν, ξεκινώντας από το ντετερμινιστικό μοντέλο και στην συνέχεια το πιθανοτικό. Επιπρόσθετα,

παρουσιάζονται τα αποτελέσματα που προέκυψαν σε κάθε βήμα της ανάπτυξης του τελικού μοντέλου καθώς και τα τελικά αποτελέσματα της διπλωματικής εργασίας.

Στο κεφάλαιο 9, το οποίο αποτελεί και το τελευταίο κεφάλαιο της εργασίας, αναπτύσσονται τα συμπεράσματα τα οποία μπορούμε να εξάγουμε από τα αποτελέσματα του πιθανοτικού μοντέλου πρόβλεψης που αναπτύχθηκε και γίνεται αναφορά στα περιθώρια βελτίωσης που παρουσιάζει το μοντέλο.

## Κεφάλαιο 2: Βιβλιογραφική Ανασκόπηση

### 2.1: Αιολική Παραγωγή Ενέργειας

Στην ενότητα αυτή θα αναλύσουμε τα μοντέλα πιθανοτικής πρόβλεψης που αναδείχθηκαν στις δυο πρώτες θέσεις του παγκόσμιου διαγωνισμού πρόβλεψης παραγωγής ενέργειας, στον τομέα της πρόβλεψης αιολικής παραγωγής. Σκοπός του διαγωνισμού ήταν η πρόβλεψη της παραγωγής αιολικής ενέργειας για 10 προεπιλεγμένες ζώνες, όπου κάθε ζώνη αναπαριστά και μία μονάδα παραγωγής αιολικής ενέργειας στην Αυστραλία. Κάθε ομάδα κλήθηκε να δημιουργήσει παραμετρικές ή μη μεθόδους πρόβλεψης παραγωγής ενέργειας έχοντας ως δεδομένα επεξεργασίας μετρήσεις σε ύψος δέκα και εκατό μέτρων, τις οποίες παρείχε το Ευρωπαϊκό Κέντρο Μεσοπρόθεσμων Μετεωρολογικών Προγνώσεων για κάθε μία απ' τις 10 ζώνες. Κύριο κριτήριο αξιολόγησης των μεθόδων αποτέλεσε ο δείκτης Root Mean Square Error (RMSE)(ρίζα μέσου τετραγωνικού σφάλματος) ο οποίος χρησιμοποιήθηκε εκτενώς και στην αξιολόγηση των μοντέλων της παρούσας διπλωματικής.

### 2.2: Πιθανοτική πρόβλεψη με Random Forests και Gradient Boosting Detection Trees

Η πρώτη μέθοδος πιθανοτικής πρόβλεψης αιολικής παραγωγής που θα μελετήσουμε αναπτύχθηκε από την ομάδα dmlabs[47]. Για την παραγωγή πιθανοτικών προβλέψεων χρησιμοποιήθηκαν δυο διαφορετικά μοντέλα μηχανικής μάθησης, τα Random Forests (Quantile regression forest model (QRF)) και τα Gradient Boosting Detection Trees(GBDT). Χρησιμοποιήθηκαν συνολικά τέσσερις μέθοδοι παραγωγής συνόλων προβλέψεων (forecast ensembles): bagging, voting, boosting και stacking predictors. Τα Random Forests και τα Gradient Boosting Detection Trees χρησιμοποιήθηκαν από κοινού για την υλοποίηση του bagging. Κύριος σκοπός του bagging είναι ο υπολογισμός του σφάλματος πρόβλεψης. Ο αλγόριθμος δειγματοληπτεί με επανατοποθέτηση από το σετ δεδομένων εκπαίδευσης και στην συνέχεια με βάση τις ομάδες δεδομένων που προέκυψαν εκπαιδεύει νέα μοντέλα, από την έξοδο των οποίων βρίσκει την μέση τιμή (mean).

Γενικότερα, τα Random Forests βελτιώνουν την σταθερότητα και την ακρίβεια των αλγορίθμων μηχανικής εκπαίδευσης, μειώνουν την απόκλιση των μεταβλητών από την μέση τιμή (mean) και υπολογίζουν την βαρύτητα κάθε μεταβλητής. Το Quantile regression forest

model (QRF) μοντέλο που επιλέχθηκε, αποτελεί βελτιωμένη εκδοχή των Random Forests, κατά την οποία δημιουργείται ένας αριθμός δέντρων παρέχοντας έτσι τις παρατηρήσεις όλων των φύλλων κάθε δέντρου και όχι απλά τον μέσο όρο. Παρέχουν συνεπώς την δυνατότητα μη-παραμετρικού υπολογισμού των conditional quantiles χωρίς να εξαρτώνται από την μέση τιμή (mean) , διατηρώντας παράλληλα τα προαναφερθέντα πλεονεκτήματα των Random Forests. Για την εκπαίδευση των Random Forests χρησιμοποιήθηκε 10-fold Cross-Validation.

Το δεύτερο μοντέλο είναι η τεχνική μηχανικής μάθησης Gradient Boosting Detection Trees(GBDT). Η συγκεκριμένη τεχνική βασίζεται στην παραγωγή μοντέλων πρόβλεψης συνδυάζοντας προβλέψεις λιγότερο αποτελεσματικών μεθόδων υλοποίησης δέντρων απόφασης, όπου κάθε δέντρο είναι μια εφαρμογή σε μια τροποποιημένη εκδοχή του αρχικού συνόλου δεδομένων, βελτιώνοντας έτσι την απόδοσή τους. Το τελικό μοντέλο πρόβλεψης αποτελεί έναν συνδυασμό των δέντρων με τα αντίστοιχα βάρη.

## **2.3: Πιθανοτική πρόβλεψη με Gradient Boosting Detection Machines**

Το δεύτερο πιθανοτικό μοντέλο που θα αναλύσουμε αναπτύχθηκε από την ομάδα kPower[48], η οποία χρησιμοποίησε για την προσέγγισή της Gradient Boosting Machines, δομημένα σε δύο επίπεδα . Τα Gradient Boosting Machines αποτελούν εκδοχή των boosted trees , τα οποία μελετήσαμε στην προσέγγιση της προηγούμενης ομάδας, και ένα από τα κύρια χαρακτηριστικά τους είναι η δυνατότητα να παράγουν ακριβείς προβλέψεις με την μικρότερη δυνατή προεπεξεργασία δεδομένων. Για την δημιουργία των Gradient Boosting Machines βασίστηκαν στον αλγόριθμο Friedman ο οποίος αξιοποιεί την τεχνική Adaboost κατά την οποία οι έξοδοι τον αλγορίθμων μάθησης αθροίζονται με βάρη, και το άθροισμα αυτό αναπαριστά την τελική έξοδο του μοντέλου, έτσι ώστε κάθε αλγόριθμος μάθησης να δίνει έμφαση στο ποσοστό λάθους των προηγούμενων και όχι στην επιθυμητή τιμή (target value). Για την παραγωγή των εκατοστημορίων η ομάδα χρησιμοποίησε ξεχωριστό μοντέλο, δίνοντας έτσι στις προβλέψεις την δυνατότητα ανεξάρτητης αξιοποίησης των δεδομένων εισόδου, κάνοντας παράλληλα χρήση επαναληπτικών μεθόδων για την παροχή των επιθυμητών πιθανοτικών προβλέψεων. Ένα από τα κύρια πλεονεκτήματα της διεπίπεδης προσέγγισης είναι η αντιμετώπιση προβλημάτων αλληλεξάρτησης που προκύπτουν στην άσκηση λόγω των πολλαπλών(10) αιολικών.

Στο πρώτο επίπεδο η Gradient Boosting Machine εφαρμόστηκε για όλες τις ζώνες μέτρησης στο πεντηκοστό εκατοστημόριο. Στην συνέχεια οι out-of-sample προβλέψεις του πρώτου

μοντέλου χρησιμοποιήθηκαν ως δεδομένα εισόδου για το δεύτερο Gradient Boosting Machine μοντέλο . Παράλληλα η ομάδα πειραματίστηκε χρησιμοποιώντας επίσης ως είσοδο στο δεύτερο μοντέλο προβλέψεις διαμέσου και για τις δέκα ζώνες, παρατηρώντας βελτίωση μόνο για τέσσερις, για τις οποίες και διατήρησε την πρόβλεψη ως είσοδο

# Κεφάλαιο 3: Αριθμητικές Προβλέψεις Καιρού

## 3.1: Εισαγωγή

Η βασική ιδέα της αριθμητικής πρόβλεψης καιρού είναι η λύση μια σειράς μερικών διαφορικών εξισώσεων οι οποίες περιγράφουν τις μεταβολές της ατμόσφαιρας. Το 1904, ο Vilhelm Bjerknes διατύπωσε πως η πρόβλεψη του καιρού αποτελεί στην ουσία ένα πρόβλημα αρχικών τιμών. Πιο συγκεκριμένα, σύμφωνα με την προσέγγιση του, για να μπορέσουμε να προβλέψουμε μελλοντικές καταστάσεις της ατμόσφαιρας θα πρέπει να ικανοποιούνται δύο κριτήρια:

1. Οι παρούσες ατμοσφαιρικές συνθήκες θα πρέπει να χαρακτηριστούν όσο ακριβέστερα γίνεται.
2. Θα πρέπει να είναι γνωστές οι φυσικές εξισώσεις οι οποίες περιγράφουν πως διαμορφώνονται μελλοντικές καταστάσεις της ατμόσφαιρας με βάση τις παρούσες ατμοσφαιρικές συνθήκες.

Εάν ικανοποιούνται αυτά, τότε οι εξισώσεις κάθε μεταβλητής που περιγράφει την ατμόσφαιρα μπορούν να λυθούν εφαρμόζοντας τις φυσικές δυνάμεις που επιδρούν σε αυτές μέσα στον χρόνο, με σκοπό να υπολογίσουμε τις μελλοντικές τιμές αυτών των μεταβλητών.

Η πρώτη προσπάθεια αριθμητικής πρόβλεψης καιρού έγινε το 1922 από τον Lewis Fry Richardson, ο οποίος θεώρησε πως η κατάσταση της ατμόσφαιρας σε κάθε σημείο μπορεί να καθοριστεί από την πίεση, τη θερμοκρασία, την πυκνότητα, την περιεκτικότητα σε νερό και την ταχύτητα του αέρα. Τα ατμοσφαιρικά φαινόμενα συμπεριλαμβάνονταν σε ένα σύστημα 7 διαφορικών εξισώσεων. Για την επίλυσή τους, ο Richardson διαίρεσε σε διακριτές στήλες την ατμόσφαιρα σε έκταση  $3^\circ$  ανατολικά-δυτικά και 200 km βόρεια-νότια δημιουργώντας  $120 \times 100$  στήλες. Αν και η μεθοδολογία που χρησιμοποίησε ήταν σωστή, και αποτελεί την βάση για τα σύγχρονα μοντέλα αριθμητικής πρόβλεψης καιρού, η πρόβλεψη ήταν αποτυχημένη. Οι κύριοι παράγοντες που οδήγησαν στην αποτυχία της πρόβλεψης ήταν η μαθηματική μοντελοποίηση της ατμοσφαιρικής συμπεριφοράς, καθώς και λάθη στις αρχικές συνθήκες. Όπως θα διαπιστώσουμε στη συνέχεια, οι δύο αυτοί παράγοντες αποτελούν το κύριο πρόβλημα και των σύγχρονων αριθμητικών προβλέψεων καιρού.

Η πρώτη επιτυχημένη προσπάθεια για την παραγωγή αριθμητικής πρόβλεψης καιρού έγινε το 1950 από τους Charney, Fjortoft και von Neumann χρησιμοποιώντας τον υπολογιστή ENIAC. Για την παραγωγή της πρόβλεψης χρησιμοποίησαν ένα βαρομετρικό μοντέλο, το οποίο βασίστηκε στα αποτελέσματα του J. G. Charne, ο οποίος έδειξε πως οι δυναμικές εξισώσεις

μπορούν να απλοποιηθούν χρησιμοποιώντας γεοστροφικές και υδροστατικές προσεγγίσεις με σκοπό την εξάλειψη της επίδρασης των ηχητικών και βαρυτικών κυμάτων.

Πλέον, με την ανάπτυξη την τεχνολογίας των υπολογιστών η αριθμητική πρόβλεψη καιρού αποτελεί αναπόσπαστο κομμάτι της πρόβλεψης καιρού. Για παράδειγμα στις Ηνωμένες Πολιτείες της Αμερικής, η καθημερινή πρόβλεψη καιρού ξεκινάει από την παραγωγή προβλέψεων με την βοήθεια ενός υπολογιστή στο National Oceanic and Atmospheric Administration (NOAA) της Washington, DC. Ενώ στην Ευρώπη αντίστοιχα το European Centre for Medium-Range Weather Forecasts (ECMWF), το μεγαλύτερο κέντρο αριθμητικών προβλέψεων καιρού παγκοσμίως, παρέχει προβλέψεις σε όλες την χώρες της Ε.Ε. οι οποίες αποτελούν οδηγό για την παραγωγή προβλέψεων καιρού για την εκάστοτε χώρα.

## **3.2: Λειτουργία Μοντέλων Αριθμητικών Προβλέψεων Καιρού**

Ο πυρήνας κάθε μοντέλου αριθμητικής πρόβλεψης καιρού αποτελείται από ένα σύνολο διαφορικών εξισώσεων, που περιγράφουν τους βασικούς νόμους της φύσης, που διέπουν την ατμοσφαιρική συμπεριφορά για τις οποίες έχει καθιερωθεί ο όρος προγνωστικές εξισώσεις. Ως προβλήματα αρχικών τιμών όμως, τα σύγχρονα μοντέλα αριθμητικών προβλέψεων καιρού, απαιτούν και τον προσδιορισμό της παρούσας ατμοσφαιρικής κατάστασης, δηλαδή των αρχικών τιμών, ως σημείο αναφοράς. Από αυτό ξεκινάνε τα μοντέλα προβλέψεων την παραγωγή ως προς τον χρόνο των φυσικών διαφορικών εξισώσεων με σκοπό την παραγωγή των αριθμητικών προβλέψεων. Αν και από την πρώτη εμφάνιση τους το 1950 ως σήμερα έχουν αναπτυχθεί πολλά μοντέλα, διαφορετικά το ένα από το άλλο, στην βάση του το κάθε μοντέλο αποτελείται από τις εξής βασικές διεργασίες[9]:

- Την συλλογή των ατμοσφαιρικών παρατηρήσεων.
- Την διαδικασία αφομοίωσης δεδομένων (data assimilation) με σκοπό τον καλύτερο δυνατό προσδιορισμό των αρχικών συνθηκών.
- Την ανάπτυξη μοντέλων για την περιγραφή των ατμοσφαιρικών μεταβολών μέσω των προγνωστικών εξισώσεων και την επίλυση τους.
- Την ανάπτυξη σχημάτων παραμετροποίησης για την προσέγγιση φαινομένων και διεργασιών που ταξινομούνται στην μικροκλίμακα και δεν επιλύονται αναλυτικά.



### 3.2.1: Συλλογή Παρατηρήσεων

Ο κύριος περιορισμός των NWP οφείλεται στην χαοτική φύση της ατμόσφαιρας και στην μη γραμμικότητα των εξισώσεων που διέπουν τις μεταβολές της όπως διατύπωσε ο Lorenz, θεμελιωτής της «θεωρίας του χάους»[31]. Αυτό συνεπάγεται πως, υποθέτοντας αρχικές συνθήκες της ατμόσφαιρας με μικρές αποκλίσεις από τις πραγματικές, μπορούν ραγδαία να μετατραπούν σε πολύ μεγάλες αποκλίσεις στην τελική πρόβλεψη[11][18]. Επομένως η ακρίβεια και η επάρκεια των μετρήσεων, καθώς και η σωστή κατανομή του καταγραφικού εξοπλισμού σε παγκόσμιο επίπεδο, είναι απαραίτητες προϋποθέσεις για τον περιορισμό του σφάλματος στο αρχικό στάδιο της αριθμητικής πρόβλεψης καιρού.

Η σημασία των αρχικών δεδομένων οδήγησε στην ανάπτυξη του Global Observing System (GOS), ένα διεθνές πρόγραμμα του Παγκόσμιου Μετεωρολογικού Οργανισμού. Σκοπός του προγράμματος αυτού αποτελεί η καταγραφή και η παροχή των απαραίτητων μετρήσεων στα μέλη του Παγκόσμιου Μετεωρολογικού Οργανισμού. Το GOS χρησιμοποιεί ένα δίκτυο αποτελούμενο από επίγειους σταθμούς, πλοία, θαλάσσιους σημαντήρες, σταθμούς ραδιοβολίσεων και δορυφόρους για την συλλογή των δεδομένων[10]. Αν και η συλλογή των δεδομένων διεξάγεται σε παγκόσμια κλίμακα τα δεδομένα τα οποία χρησιμοποιούνται συνεχίζουν να συμβάλλουν σε μεγάλο βαθμό στα σφάλματα που παρουσιάζουν οι αριθμητικές προβλέψεις καιρού. Το γεγονός αυτό οφείλεται στην κατανομή του καταγραφικού εξοπλισμού. Οι περισσότεροι επίγειοι σταθμοί, που αποτελούν και την πλειοψηφία του εξοπλισμού, βρίσκονται σε πυκνοκατοικημένες περιοχές με αποτέλεσμα διασκορπισμένες και ανεπαρκείς παρατηρήσεις σε αραιοκατοικημένες περιοχές του πλανήτη και ωκεανούς.

### 3.2.2: Διαδικασία Αφομοίωσης Δεδομένων

Στην πραγματικότητα τα δεδομένα που μας παρέχει ο καταγραφικός εξοπλισμός είναι ατελή και αποτελούν μια εκτίμηση της πραγματικής τιμής των υπό καταγραφή ατμοσφαιρικών μεταβολών. Η απόκλιση τους από την πραγματική τιμή εξαρτάται από την ακρίβεια των οργάνων μέτρησης. Το γεγονός αυτό, σε συνδυασμό με την ανομοιογενή κατανομή του καταγραφικού εξοπλισμού σε παγκόσμιο επίπεδο, καθιστούν αδύνατη την απευθείας χρήση τους για τον προσδιορισμό την αρχικής κατάστασης της ατμόσφαιρας[12]. Όπως αναφέραμε και παραπάνω ο εσφαλμένος προσδιορισμός των αρχικών συνθηκών σε ένα πρόβλημα αρχικών τιμών, με μη γραμμικές διαφορικές εξισώσεις καθιστά αδύνατη την παραγωγή αξιόπιστων προβλέψεων. Το πρόβλημα αυτό ήταν εμφανές από τις αρχικές προσπάθειες παραγωγής

αριθμητικών προβλέψεων καιρού και για την αντιμετώπιση του αναπτύχθηκε η διαδικασία την αφομοίωσης δεδομένων (data assimilation).

Η διαδικασία της αφομοίωσης δεδομένων είναι κατά βάση ο συνδυασμός των ατμοσφαιρικών παρατηρήσεων και βραχυπρόθεσμων προβλέψεων για τον καλύτερο προσδιορισμό των αρχικών συνθηκών του προβλήματος. Για τις βραχυπρόθεσμες προβλέψεις, έχει καθιερωθεί ο όρος υπόβαθρο ('background') και συνήθως παράγονται από το προηγούμενο μοντέλο βραχυπρόθεσμης πρόβλεψης. Όπως αναφέρεται στο [13] η αφομοίωση δεδομένων μπορεί να περιγραφεί από τις παρακάτω τέσσερις επιμέρους διαδικασίες οι οποίες επαναλαμβάνονται κυκλικά:

- Ποιοτικός έλεγχος δεδομένων: κατά τον οποίο δεδομένα τα οποία περιέχουν σφάλματα οργάνων απορρίπτονται
- Αντικειμενική ανάλυση: που αποτελεί τον συνδυασμό των δεδομένων με το υπάρχον υπόβαθρο
- Αρχικοποίηση: με σκοπό την απαλοιφή των αρχικών συνθηκών από τον 'θόρυβο' βαρυτικών κυμάτων
- Βραχυπρόθεσμη πρόβλεψη: την παραγωγή του υποβάθρου που θα χρησιμοποιηθεί στον επόμενο κύκλο

Για την παραγωγή αντικειμενικής ανάλυσης, το σχήμα αφομοίωσης δεδομένων καθορίζει τα σχετικά βάρη που δίνονται στις παρατηρήσεις και τα δεδομένα του υποβάθρου και καθορίζει τον τρόπο με τον οποίο τα δεδομένα παρατηρήσεων επηρεάζουν γειτονικές περιοχές. Πιο συγκεκριμένα, σε περιοχές με μεγάλη διασπορά καταγραφικών οργάνων (π.χ. πάνω από ωκεανούς) η ανάλυση βασίζεται σε μεγάλο βαθμό στα δεδομένα του υποβάθρου ενώ σε περιοχές με πληθώρα πραγματικών μετρήσεων αυτές συμβάλλουν περισσότερο στην ανάλυση.

Οι μέθοδοι αφομοίωσης δεδομένων μπορούν να είναι είτε διακριτές, είτε συνεχείς ως προς τον χρόνο. Οι μέθοδοι συνεχούς χρόνου εισάγουν δεδομένα στο σύστημα, όποτε αυτά είναι διαθέσιμα, ενώ οι μέθοδοι διακριτού χρόνου εισάγουν δεδομένα τα οποία καταγράφηκαν μερικές ώρες πριν ή μετά από την ώρα την ανάλυσης, προσαρμόζοντας τα ώστε να αντιπροσωπεύουν την χρονική στιγμή της ανάλυσης. Τα συστήματα διακριτού χρόνου απαιτούν λιγότερη υπολογιστική ισχύ από τα συστήματα συνεχούς χρόνου τα οποία όμως παράγουν πιο ρεαλιστικές αναλύσεις με μικρότερο σφάλμα απαιτώντας την χρήση περισσότερων υπολογιστικών πόρων. Οι δυο κυριότερες μέθοδοι διακριτού χρόνου είναι η βέλτιστη παρεμβολή (Optimal Interpolation-OI) και η τρισδιάστατη παραμετρική τεχνική αφομοίωσης (3D-Var), ενώ οι δύο κυριότερες μέθοδοι συνεχούς χρόνου είναι τα φίλτρα Kalman και η τετραδιάστατη παραμετρική αφομοίωση δεδομένων (4D-Var), η οποία είναι και η πιο δημοφιλής και χρησιμοποιείται από πολλούς παγκόσμιους οργανισμούς όπως το

ECMWF (European Center for Medium-range Weather Forecasts) και το NMC (National Meteorological Center)[14].

### 3.2.3: Μαθηματική Μοντελοποίηση της Ατμόσφαιρας

Για την περιγραφή των ατμοσφαιρικών μεταβολών τα αριθμητικά μοντέλα αριθμητικών προβλέψεων καιρού χρησιμοποιούν ένα σύνολο επτά εξισώσεων με επτά αγνώστους[9]. Οι εξισώσεις αυτές είναι:

- Ο δεύτερος νόμος του Νεύτωνα ή αρχή διατήρησης της κίνησης (τρεις εξισώσεις για τις τρεις συνιστώσες της ταχύτητας)
- Η αρχή διατήρησης της μάζας
- Η αρχή της διατήρησης της συγκέντρωσης των ατμοσφαιρικών συστατικών
- Ο πρώτος θερμοδυναμικός νόμος
- Η αρχή διατήρησης της ποσότητας του νερού

Γνωρίζοντας τις αρχικές και οριακές συνθήκες του προβλήματος και έχοντας μοντελοποιήσει τις μεταβολές της ατμόσφαιρας με το παραπάνω σύστημα μερικών διαφορικών εξισώσεων, η λύση του συστήματος παρέχει τις μελλοντικές τιμές των μεταβλητών της ατμόσφαιρας. Η πολυπλοκότητα των εξισώσεων καθιστά αδύνατη την αναλυτική λύση τους και για τον λόγο αυτό χρησιμοποιούνται αριθμητικές μέθοδοι.

Η διαδικασία αυτή αποτελεί τον πυρήνα κάθε μοντέλου αριθμητικών προβλέψεων καιρού. Εντούτοις, ο τρόπος με τον οποίο εφαρμόζονται οι εξισώσεις σε κάθε μοντέλου διαφοροποιείται. Ανάλογα με την κλίμακα της υπό μελέτη περιοχής και την ακρίβεια της πρόβλεψης που το κάθε μοντέλο καλείται να παράγει, απαιτείται να γίνουν κάποιες παραδοχές για την απλοποίηση των εξισώσεων, ώστε να είναι δυνατή η παραγωγή των προβλέψεων εντός των καθορισμένων χρονικών ορίων.


### 3.2.4: Χαρακτηριστικά Μοντέλων Αριθμητικών Προβλέψεων Καιρού

#### 3.2.4.1: Πλεγματικά Σημεία και Φασματική Ανάλυση


Τα πλεγματικά σημεία και η φασματική ανάλυση αποτελούν τις δυο κύριες τεχνικές διακριτοποίησης στον χώρο οι οποίες χρησιμοποιούνται από τα αριθμητικά μοντέλα[9]. Αν και οι δύο βασίζονται στις ίδιες προγνωστικές εξισώσεις διαφοροποιούνται ως προς τις μαθηματικές τεχνικές που χρησιμοποιούν για την επίλυση τους και κατ' επέκταση τον τρόπο με τον οποίο αναπαριστώνται τα δεδομένα. Οι διαφορές που παρουσιάζουν ως προς τον τρόπο επίλυσης των προγνωστικών εξισώσεων και την αναπαράσταση των δεδομένων, εισάγουν διαφορετικά σφάλματα στις προβλέψεις.

- Πλεγματικά Σημεία:

Τα μοντέλα πλεγματικών σημείων διαχωρίζουν την ατμόσφαιρα σε τρισδιάστατους κύβους και τα πλεγματικά σημεία αποτελούν το κέντρο του εκάστοτε κύβου. Αν και οι τιμές των μεταβλητών των προγνωστικών εξισώσεων (θερμοκρασία, πίεση, υγρασία, άνεμος) μεταβάλλονται με συνεχή τρόπο, στα μοντέλα πλεγματικών σημείων αναπαριστώνται με διακριτές τιμές στα πλεγματικά σημεία. Οι τιμές της θερμοκρασίας, της πίεσης και της υγρασίας αντιπροσωπεύουν μια μέση τιμή των μεταβλητών για όλο τον πλεγματικό όγκο, ενώ οι συνιστώσες του ανέμου στις έδρες του κύβου αντιπροσωπεύουν την μέση ροή ανά διεύθυνση μεταξύ του πλεγματικού σημείου και των γειτονικών πλεγματικού κύβων. Αυτή η τεχνική αναπαράστασης των ατμοσφαιρικών μεταβλητών στο κέντρο και στις έδρες του κύβου ονομάζεται τεχνική του κλιμακωτού πλέγματος (staggered grid) και απεικονίζεται στα σχήματα 3.1 και 3.2. Στην συνέχεια, οι προγνωστικές εξισώσεις επιλύονται για κάθε πλεγματικό σημείο του χώρου και για την επίλυση τους χρησιμοποιείται η μέθοδος πεπερασμένων διαφορών.



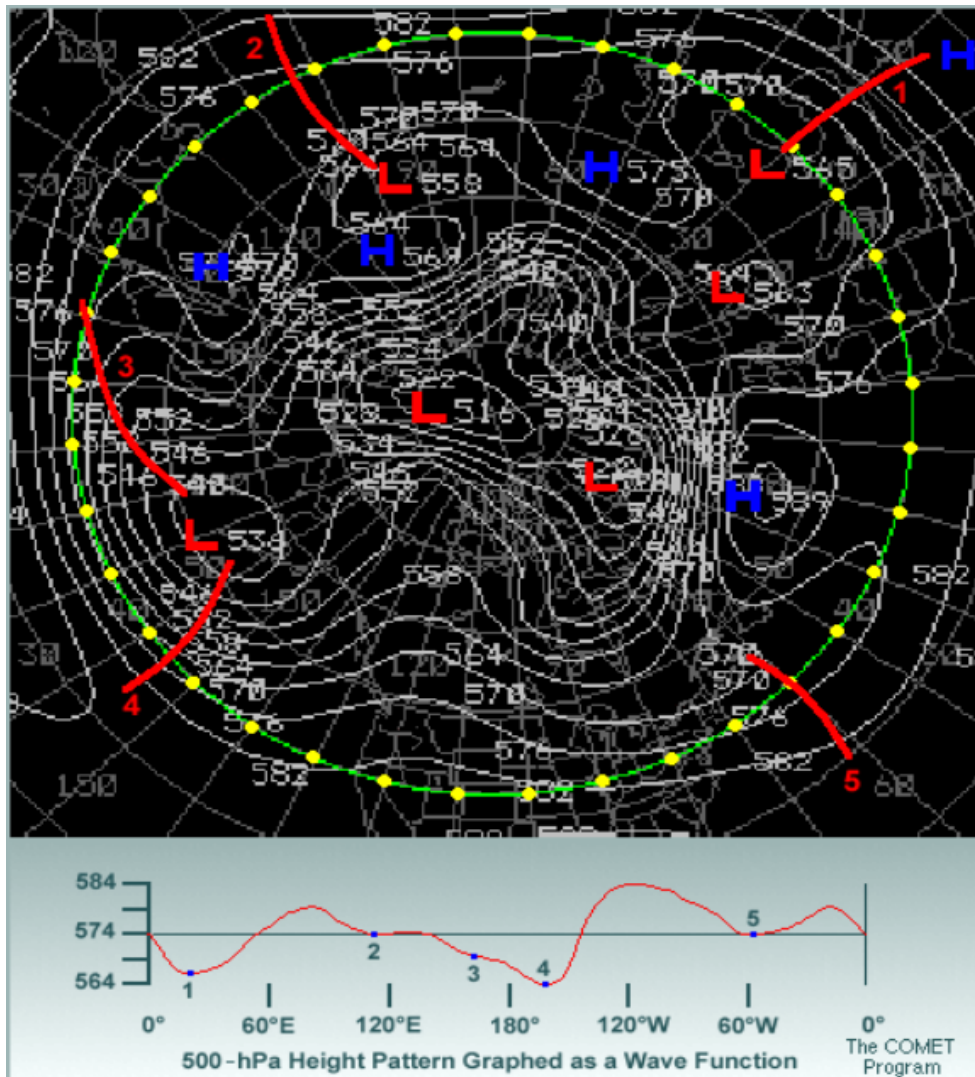
Σχήμα 3.1



Σχήμα 3.2

- Φασματική ανάλυση:

Η μέθοδος της φασματικής ανάλυσης βασίζεται στην αναπαράσταση των χωρικών διαφοροποιήσεων των ατμοσφαιρικών μεταβλητών, με ένα πεπερασμένο αριθμό κυμάτων διαφορετικών συχνοτήτων. Τα φασματικά μοντέλα συνδυάζουν την φασματική ανάλυση με τα πλεγματικά σημεία. Κάποιες προγνωστικές εξισώσεις χρησιμοποιούν δεδομένα, τα οποία προέρχονται αποκλειστικά από την φασματική αναπαράσταση αποφεύγοντας το σφάλματα που προκύπτουν από την μέθοδο πεπερασμένων διαφορών, ενώ για την επίλυση άλλων εξισώσεων χρησιμοποιούνται τα δεδομένα της πλεγματικής αναπαράστασης




Σχήμα 3.3

### 3.2.4.2: Ανάλυση Μοντέλων

Όπως είδαμε παραπάνω η ατμόσφαιρα μπορεί να παρασταθεί είτε με πλεγματικά σημεία είτε φασματικά. Η έννοια της οριζόντιας ανάλυσης (Horizontal Resolution) αναφέρεται στην απόσταση των πλεγματικών σημείων ή των αριθμό των κυμάτων που χρησιμοποιείται από τα φασματικά μοντέλα[15]. Μοντέλα με υψηλότερη ανάλυση (μικρότερες αποστάσεις πλεγματικών σημείων ή μεγαλύτερος αριθμός κυμάτων) προσφέρουν μεγαλύτερα ακρίβεια από μοντέλα με χαμηλότερη ανάλυση αλλά απαιτούν περισσότερους υπολογιστικούς πόρους. Η οριζόντια ανάλυση του εκάστοτε μοντέλου, επηρεάζει άμεσα την ορεογραφική

αναπαράσταση της υπό μελέτης περιοχής. Όπως φαίνεται και στο σχήμα 3.4 μοντέλα με μεγαλύτερη ανάλυση αναπαριστούν με μεγαλύτερη ακρίβεια την γεωμορφία του εδάφους και κατά συνέπεια ενσωματώνουν καλύτερα ατμοσφαιρικά φαινόμενα τα οποία συνδέονται με αυτήν.




Σχήμα 3.4

Αντίστοιχα με την οριζόντια ανάλυση, η έννοια της κάθετης ανάλυσης (Vertical Resolution) αναφέρεται στον κάθετο διαχωρισμό της ατμόσφαιρας σε ατμοσφαιρικά στρώματα. Στην πλειοψηφία των μοντέλων, ο διαχωρισμός γίνεται σε μη ισαπέχοντα στρώματα, χρησιμοποιώντας μεγαλύτερο αριθμό στρωμάτων στο κατώτερο μέρος της ατμόσφαιρας όπου τα ατμοσφαιρικά φαινόμενα παρουσιάζουν μεγαλύτερο ενδιαφέρον. Επίσης πολλά σύγχρονα μοντέλα, χρησιμοποιούν συστήματα κάθετων συντεταγμένων τα οποία ακολουθούν την γεωμορφία του εδάφους στα κατώτερα στρώματα της ατμόσφαιρας, όπως η σίγμα συντεταγμένη (sigma coordinate) και άλλες υβριδικές παραλλαγές της (σχήμα 3.5).

### 3.2.4.3: Τομέας Κάλυψης

Τα μοντέλα αριθμητικών προβλέψεων διαχωρίζονται σε δύο κατηγορίες, με βάση τον γεωγραφικό τομέα που καλύπτουν: τα παγκόσμια μοντέλα και τα μοντέλα περιορισμένης περιοχής (limited area models). Τα παγκόσμια μοντέλα λύνουν τις προγνωστικές εξισώσεις για



**Fig. 4.** Hybrid sigma–pressure vertical coordinate system.

Σχήμα 3.5

το σύνολο του πλανήτη, χρησιμοποιώντας μόνο κάθετες οριακές συνθήκες ενώ τα limited area models για περιορισμένες περιοχές απαιτώντας επιπρόσθετες πλευρικές οριακές συνθήκες. Εφόσον τομέας ενδιαφέροντος των παγκόσμιων μοντέλων αποτελεί το σύνολο της επιφάνειας του πλανήτη, η ανάλυση τους δεν μπορεί να είναι πολύ υψηλή λόγω της τεράστιας υπολογιστικής δύναμης που απαιτείται. Για τον λόγο αυτό, δημιουργήθηκε η ανάγκη των μοντέλων περιορισμένης περιοχής, στα οποία μειώνεται η περιοχή ενδιαφέροντος με αποτέλεσμα να υπάρχει η δυνατότητα αυξημένης ανάλυσης. Η αυξημένη ανάλυση δίνει την δυνατότητα στα μοντέλα περιορισμένης περιοχής να ενσωματώνουν ατμοσφαιρικά φαινόμενα μικρότερης κλίμακας, και κατά συνέπεια να παράγουν ακριβέστερες προβλέψεις. Εντούτοις, τα μοντέλα περιορισμένης περιοχής δεν μπορούν να λειτουργήσουν ανεξάρτητα, διότι απαιτούν δεδομένα από τα παγκόσμια μοντέλα για την θέσπιση των πλευρικών οριακών συνθηκών.

#### 3.2.4.4: Υδροστατική και Μη-υδροστατική προσέγγιση

Ένας σημαντικός διαχωρισμός των μοντέλων αριθμητικών προβλέψεων καιρού γίνεται σύμφωνα με το αν αυτά ακολουθούν την υδροστατική ή την μη υδροστατική προσέγγιση[16]. Τα υδροστατικά μοντέλα υποθέτουν πως υπάρχει ισορροπία μεταξύ των κάθετων συνιστωσών των δυνάμεων που ασκούνται στις αέριες μάζες. Πιο συγκεκριμένα, η βαρυτική δύναμη που ασκείται σε μια αέρια μάζα είναι ίση με την προς τα πάνω δύναμη που ασκείται λόγω της μείωσης της ατμοσφαιρικής πίεσης. Η προσέγγιση αυτή εξαλείφει την ανάγκη του άμεσου υπολογισμού της κατακόρυφης συνιστώσας του ανέμου και οι επιδράσεις της προσεγγίζονται μέσω της διαδικασίας της παραμετροποίησης την οποία θα περιγράψουμε παρακάτω. Η



υδροστατική προσέγγιση μειώνει την υπολογιστική πολυπλοκότητα του εκάστοτε μοντέλου και για τον λόγο αυτό εφαρμόζεται σε όλα τα μοντέλα παγκόσμιας κλίμακας και στα περισσότερα μοντέλα περιορισμένης περιοχής, δίνοντας ικανοποιητικά αποτελέσματα σε μοντέλα με χαμηλή οριζόντια ανάλυση. Αντίθετα σε μοντέλα με υψηλή ανάλυση (απόσταση πλεγμάτων σημείων μικρότερη των 10χλμ) τα οποία χρησιμοποιούνται για να εξετάσουμε κάποια φαινόμενα μέσης κλίμακας, όπως συστήματα καταιγιδοφόρων νεφών, η υδροστατική προσέγγιση δεν ισχύει. Στα μοντέλα αυτά χρησιμοποιείται η μη υδροστατική προσέγγιση κατά την οποία η εξίσωση της κάθετης συνιστώσας του ανέμου συμπεριλαμβάνεται στο σύνολο των προγνωστικών εξισώσεων.

### 3.2.5: Παραμετροποίηση

Οι προγνωστικές εξισώσεις, όπως προαναφέρθηκε, αποτελούνται από ένα σύστημα επτά διαφορικών εξισώσεων με επτά μεταβλητές. Όμως είναι αδύνατο να περιγραφούν οι ατμοσφαιρικές μεταβολές αποκλειστικά από τις μεταβλητές αυτές καθώς υπάρχουν πολλές ατμοσφαιρικές διεργασίες οι οποίες έχουν άμεσες επιπτώσεις στην ατμόσφαιρα αλλά, δεν μπορούν να αναλυθούν από τα μοντέλα λόγω χαμηλής οριζόντιας ανάλυσης των μοντέλων, έλλειψης δεδομένων ή του υψηλού υπολογιστικού κόστους που απαιτούν. Για τον λόγο αυτό τα μοντέλα αριθμητικών προβλέψεων καιρού χρησιμοποιούν σχήματα παραμετροποίησης τα οποία στοχεύουν στον υπολογισμό της επίδρασης των ατμοσφαιρικών αυτών διεργασιών αποφεύγοντας την μαθηματική τους μοντελοποίηση στο αριθμητικό μοντέλο[17].

Παραδείγματα τέτοιων φυσικών διεργασιών αποτελούν η ηλιακή ακτινοβολία, η επίδραση της ορογραφίας, η τυρβώδης ροή, η ροή ενέργειας μεταξύ ατμόσφαιρας και εδάφους και φαινόμενα συμπύκνωσης. Τα σχήματα παραμετροποίησης εξάγουν πληροφορίες για τις διεργασίες αυτές από τις μεταβλητές των προγνωστικών εξισώσεων κάνοντας κάποιες υποθέσεις. Ανάλογα με το είδος της ατμοσφαιρικής διεργασίας, οι υποθέσεις που γίνονται βασίζονται είτε σε στατιστικά στοιχεία είτε στους φυσικούς νόμους που την διέπουν.

Ο τρόπος με τον οποίο το εκάστοτε μοντέλο εφαρμόζει την διαδικασία της παραμετροποίησης επηρεάζει σε μεγάλο βαθμό την ακρίβεια του μοντέλου. Η προσπάθεια της πρόβλεψης ατμοσφαιρικών διεργασιών μικρής κλίμακας, χρησιμοποιώντας δεδομένα προερχόμενα από μοντέλα μεγάλης κλίμακας, αποτελεί το κύριο πρόβλημα κατά την διαδικασία της παραμετροποίησης. Επιπλέον προβλήματα που παρουσιάζονται, οφείλονται αρχικά στην αλληλεπίδραση μεταξύ των διαφόρων σχημάτων παραμετροποίησης, όπου το καθένα εμπεριέχει σφάλματα τα οποία μεταφέρονται από το ένα σχήμα στο άλλο, και στην συνέχεια

στην ολοένα αυξανόμενη πολυπλοκότητα και διασύνδεση των σχημάτων παραμετροποίησης δυσχεραίνοντας τον εντοπισμό της πηγής των σφαλμάτων πρόβλεψης.

### **3.3: Σύγχρονα Μοντέλα Αριθμητικών Προβλέψεων Καιρού**

#### **COSMO**

Το πρόγραμμα Consortium for Small-scale Modeling (COSMO) σχηματίστηκε τον Οκτώβριο του 1998 και λειτούργησε σε πρακτικό επίπεδο στα τέλη του 1999. Αρχικά, αποτελούσε μια συνεργασία των μετεωρολογικών υπηρεσιών της Γερμανίας, της Ελβετίας, της Ιταλίας και της Ελλάδας όμως με την πάροδο των χρόνων προστέθηκαν επίσης οι αντίστοιχες υπηρεσίες της Πολωνίας, της Ρουμανίας, της Ρωσίας και του Ισραήλ καθώς και άλλοι στρατιωτικοί και ακαδημαϊκοί οργανισμοί από τις προαναφερθείσες χώρες.


Το μοντέλο COSMO είναι ένα μοντέλο ατμοσφαιρικών προβλέψεων περιορισμένης περιοχής (Limited-Area Model) το οποίο δεν ακολουθεί την υδροστατική προσέγγιση. Η αρχική μορφή του μοντέλου βασίστηκε στο Lokal Modell το οποίο είχε αναπτυχθεί από την μετεωρολογική υπηρεσία της Γερμανίας (DWD). Στην συνέχεια, οι μεταγενέστερες τροποποιήσεις έγιναν στα πλαίσια του προγράμματος COSMO και είχαν ως σκοπό την κάλυψη της ανάγκης για ένα μοντέλο προβλέψεων υψηλής ανάλυσης περιορισμένης περιοχής για την παραγωγή ακριβέστερων προβλέψεων και για ερευνητικές εφαρμογές[19].

Οι αρχικές πρακτικές εφαρμογές του μοντέλου COSMO, το 2001, χρησιμοποιούσαν πλεγματική ανάλυση 7χλμ και αφορούσαν φαινόμενα που ανήκαν στην μέσο-β κλίμακα. Κύριο σημείο ενδιαφέροντος αποτελούσε η πρόβλεψη καιρικών φαινομένων κοντά στην επιφάνεια της γης. Από το 2007 κάποιες από τις υπηρεσίες που χρησιμοποιούσαν το COSMO άρχισαν να χρησιμοποιούν πλεγματική ανάλυση 2-3χλμ και την ανάλυση φαινομένων που ανήκουν στην μέσο-γ κλίμακα. Σήμερα το μοντέλο COSMO χρησιμοποιεί 1-3χλμ πλεγματική ανάλυση για την παραγωγή προβλέψεων. Η υψηλή αυτή ανάλυση δίνει την δυνατότητα στο μοντέλο να παρακάμψει τα σφάλματα τα οποία προκύπτουν από την παραμετροποίηση των φαινομένων μέσο-γ κλίμακας στα σύγχρονα υδροστατικά μοντέλα χαμηλής ανάλυσης.

Ως προς την συλλογή παρατηρήσεων το μοντέλο COSMO χρησιμοποιεί τετραδιάστατη παραμετρική αφομοίωση δεδομένων (4D-Var) σε συνδυασμό με μια τεχνική η οποία στην αγγλική βιβλιογραφία αναφέρεται ως “nudging” ή “Newtonian Relaxation”. Όπως αναφέρεται στο [20] η τεχνική του nudging αποτελεί μια συνεχή μέθοδο συλλογής παρατηρήσεων κατά την οποία η αρχική κατάσταση του μοντέλου μεταβάλλεται προς τις παρατηρήσεις με την

προσθήκη νέων όρων οι οποίοι είναι ανάλογοι της διαφοράς μεταξύ των παρατηρήσεων και της αρχικής κατάστασης στις προγνωστικές εξισώσεις.

Τα χαρακτηριστικά του μοντέλου COSMO διαφοροποιούνται ανάλογα με την μετεωρολογική υπηρεσία η οποία το χρησιμοποιεί. Στην Ελλάδα η Εθνική Μετεωρολογική Υπηρεσία (Ε.Μ.Υ.) χρησιμοποιεί το μοντέλο COSMO με πλεγματική ανάλυση περίπου 4 χιλιόμετρα και 80 κάθετα επίπεδα. Ο τομέας κάλυψης έχει εύρος γεωγραφικού μήκους 45° και εύρος γεωγραφικού πλάτους 24,5°. Η θέσπιση των οριακών συνθηκών γίνεται κάθε 3 ώρες με δεδομένα από το ECMWF και παράγει δύο προβλέψεις καθημερινά (00h και 12h) με χρονικό ορίζοντα πρόβλεψης 72 ώρες.




Σχήμα 3.6

### **HARMONIE-AROME**

Το μοντέλο HARMONIE-AROME αποτελεί αποτέλεσμα της συνεργασίας του διεθνούς του ερευνητικού προγράμματος HILRAM (High Resolution Limited Area Model) και του προγράμματος ALADIN (Aire Limitée Adaptation Dynamique Développement International). Στις 5 Δεκεμβρίου 2005 υπογράφηκε το σύμφωνο συνεργασίας μεταξύ των δύο κοινοπραξιών, στο οποίο αναφέρεται πως σκοπός της συνεργασίας αποτελεί η ανάπτυξη ενός state-of-the-art

μοντέλου για βραχυπρόθεσμη και πολύ-βραχυπρόθεσμη πρόβλεψη τόσο για ερευνητικούς σκοπούς όσο και για λειτουργική παραγωγή προβλέψεων.

Το μοντέλο HARMONIE-AROME αποτελεί ένα μη υδροστατικό φασματικό μοντέλο και ο δυναμικός πυρήνας που χρησιμοποιεί βασίζεται στο μοντέλο AROME-France το οποίο αναπτύχθηκε από την μετεωρολογική υπηρεσία της Γαλλίας (Météo-France) στα πλαίσια του προγράμματος ALADIN[21]. Για τον προσδιορισμό των οριακών συνθηκών τα δεδομένα λαμβάνονται από το ECMWF σε αντίθεση με το AROME-France το οποίο χρησιμοποιούσε το παγκόσμιο μοντέλο ARPEGE. Η οριζόντια ανάλυση του μοντέλου είναι 2.5 χιλιόμετρα και 65 κάθετα επίπεδα με το πρώτο να ξεκινάει στα 12 μέτρα. Για την συλλογή παρατηρήσεων χρησιμοποιεί βέλτιστη παρεμβολή (Optimal Interpolation-OI σε συνδυασμό με ) τρισδιάστατη παραμετρική τεχνική αφομοίωσης (3D-Var) και τα τελευταία χρόνια αναπτύσσεται ένα σχήμα τετραδιάστατης παραμετρικής αφομοίωσης δεδομένων (4D-Var).



Σχήμα 3.7

## **Κεφάλαιο 4: Πρόβλεψη Αιολικής Παραγωγής**

### **4.1: Εισαγωγή**

Αν και το ποσοστό της ενέργειας που προέρχεται από αιολικούς σταθμούς παραγωγής αυξάνεται με ραγδαίους ρυθμούς, η ένταξη τους στο δίκτυο παραγωγής και η αύξηση του ποσοστού αυτού δημιουργεί προβλήματα ευστάθειας δίκτυο[22]. Η αιολική παραγωγή ηλεκτρικής ενέργειας χρήζει διαφορετικής αντιμετώπισης από τους συμβατικούς σταθμούς παραγωγής διότι εξαρτάται αποκλειστικά από τις ατμοσφαιρικές συνθήκες. Η αδυναμία της ανθρώπινης παρέμβασης στην παραγωγή δεν μπορεί να διασφαλίσει πως η παραγωγή θα μπορεί να καλύψει την ζήτηση κάθε δεδομένη χρονική στιγμή. Για τον λόγο αυτό η αιολική παραγωγή αντιμετωπίζεται ως αρνητικό φορτίο από το δίκτυο και είναι απαραίτητη η συνύπαρξη του με της συμβατικές πηγές ώστε να διασφαλιστεί η ευστάθεια[23]. Η μεγιστοποίηση του ποσοστού της αιολικής παραγωγής εξαρτάται σε μεγάλο βαθμό από την ικανότητα πρόβλεψης της παραγωγής των αιολικών σταθμών και για τον λόγο αυτό η έρευνα για την ανάπτυξη και βελτιστοποίηση μοντέλων πρόβλεψης συνεχώς αυξάνεται. Η ανάγκη για την καλύτερη δυνατή πρόγνωση παραγωγής αιολικής ενέργειας έχει οδηγήσει στην ανάπτυξη πολλών μοντέλων πρόβλεψης τα οποία διαφέρουν σε μεγάλο βαθμό ως προς την υλοποίησή τους. Τα μοντέλα αυτά μπορούν να διαχωριστούν σε δύο βασικές κατηγορίες: τα φυσικά μοντέλα και τα στατιστικά μοντέλα. Ο διαχωρισμός αυτός έγκειται στον τρόπο με τον οποίο επεξεργάζονται τις μετεωρολογικές προβλέψεις με σκοπό την πρόβλεψη παραγωγής[23].

### **4.2: Φυσική και Στατιστική Προσέγγιση**


Όπως εξετάσαμε στο προηγούμενο κεφάλαιο τα δεδομένα της αριθμητικής πρόβλεψης καιρού αναφέρονται σε συγκεκριμένα γεωγραφικά σημεία τα οποία δεν ταυτίζονται με την τοποθεσία των αιολικών πάρκων. Κατά την φυσική προσέγγιση για την παραγωγή προβλέψεων επεξεργάζονται τα δεδομένα για την περιοχή στην οποία βρίσκεται το αιολικό πάρκο και παράγουν την πρόβλεψη ανέμου για την τοποθεσία του αιολικού λαμβάνοντας υπόψη την γεωμορφία της περιοχής και τα εμπόδια που επηρεάζουν την ταχύτητα και κατεύθυνση του ανέμου. Στην συνέχεια τα προσαρμοσμένα δεδομένα πρόβλεψης ανέμου εφαρμόζονται στην καμπύλη ισχύος μετατρέποντας την πρόβλεψη ανέμου σε πρόβλεψη αιολικής παραγωγής ενέργειας.

Εν αντιθέσει, η στατιστική προσέγγιση βασίζεται στην διαδικασία της “εκπαίδευσης” του μοντέλου. Πιο συγκεκριμένα, τα στατιστικά μοντέλα χρησιμοποιούν ιστορικά δεδομένα αριθμητικών προβλέψεων καιρού και τα αντίστοιχα δεδομένα παραγωγής ενέργειας τα οποία τροφοδοτούνται στο μοντέλο και το μεταβάλλουν με σκοπό την παραγωγή προβλέψεων[24]. Τα στατιστικά μοντέλα δεν απαιτούν θεωρητική γνώση των ατμοσφαιρικών διεργασιών για την κατασκευή τους παρόλα αυτά είναι σημαντική για την βέλτιστη επιλογή των δεδομένων που θα τροφοδοτηθούν στο μοντέλο και την βελτιστοποίηση του. Στην βάση αυτή τα στατιστικά μοντέλα διαχωρίζονται σε δυο περαιτέρω κατηγορίες, τα κατασκευαστικά (structural) τα οποία απαιτούν την τεχνογνωσία του αναλυτή και τα μαύρα κουτιά (black-boxes) στα οποία όλες οι απαραίτητες διεργασίες πραγματοποιούνται από το μοντέλο[27]. Στα μαύρα κουτιά συμπεριλαμβάνονται και τα μοντέλα που βασίζονται στα νευρωνικά δίκτυα όπως το μοντέλο που έχει αναπτυχθεί στα πλαίσια αυτής της διπλωματικής εργασίας.

### 4.3: Το Πρόβλημα της Φυσικής Προσέγγισης


Η διαδικασία παραγωγής ηλεκτρικής ενέργειας στα αιολικά πάρκα, στην βάση της αποτελεί την μετατροπή, μέσω της ανεμογεννήτριας, της κινητικής ενέργειας του ανέμου σε μηχανική ενέργεια η οποία περιστρέφει τον δρομέα της γεννήτριας για την παραγωγή ηλεκτρικής ενέργειας. Για κάθε ανεμογεννήτρια η διαδικασία αυτή περιγράφεται από την καμπύλη ισχύος[30]. Η μορφή της καμπύλης ισχύος μιας ανεμογεννήτριας παραμένει σχεδόν ίδια ανεξαρτήτως τύπου ή κατασκευαστή και είναι αυτή που απεικονίζεται στο σχήμα 1. Κάθε ανεμογεννήτρια χαρακτηρίζεται από την ταχύτητα έναυσης (cut-in speed), συνήθως 2 - 4 m/s, η οποία αποτελεί το κατώτερο όριο ταχύτητας για την παραγωγή ηλεκτρικής ενέργειας και την ταχύτητα αποκοπής (cut-out speed), 25 -30 m/s, κατά το οποίο η λειτουργία της ανεμογεννήτριας σταματάει για να προστατευθούν τα μηχανικά της μέλη. Ένα επιπλέον χαρακτηριστικό λειτουργίας αποτελεί η ονομαστική ταχύτητα ανέμου (rated speed) η οποία κυμαίνεται στα 12 -16 m/s[27]. Όταν η ταχύτητα ανέμου ξεπεράσει την ονομαστική η παραγωγή της γεννήτριας παραμένει σταθερή και αποτελεί την ονομαστική ισχύ της ανεμογεννήτριας.

Από την θεωρητική καμπύλη ισχύος μιας ανεμογεννήτριας βλέπουμε πως η σχέση ταχύτητας ανέμου – παραγόμενης ισχύος είναι μη γραμμική (σχήμα 4.1). Αυτό συνεπάγεται πως στις τιμές της ταχύτητας ανέμου όπου η καμπύλη παρουσιάζει μεγάλη κλίση μια μικρή διαφορά στην τιμή της ταχύτητας οδηγεί σε μεγάλη απόκλιση στην παραγόμενη ισχύ. Για τον λόγο αυτό, στην πρόβλεψη αιολικής παραγωγής, το μεγαλύτερο ποσοστό του σφάλματος μεταφέρεται και μεγεθύνεται από την πρόβλεψη των μετεωρολογικών μεταβλητών.



Σχήμα 4.1

Αν στην συνέχεια εξετάσουμε την θεωρητική κατανομή της ταχύτητας ανέμου, η επίδραση των αρχικών μετεωρολογικών προβλέψεων στην πρόβλεψη μεγαλώνει. Σύμφωνα με το [28] η πιο συχνά χρησιμοποιούμενη κατανομή για την περιγραφή της ταχύτητας ανέμου είναι η κατανομή Weibull. Στο σχήμα 4.2 παρουσιάζεται ένα διάγραμμα της συνάρτησης πυκνότητας πιθανότητας της ταχύτητας ανέμου. Από το σχήμα μπορούμε να διαπιστώσουμε πως οι χαμηλής εντάσεως άνεμοι είναι πολύ πιο συχνοί από του ισχυρούς και επομένως οι ανεμογεννήτριες δεν λειτουργούν στην ονομαστική ισχύ αλλά στο τμήμα της καμπύλης ισχύος το οποίο παρουσιάζει μεγάλη κλίση.




Σχήμα 4.2

Εφόσον η καμπύλη ισχύος παρέχεται από τον κατασκευαστή της εκάστοτε ανεμογεννήτριας θα μπορούσαμε να υποθέσουμε πως για την πρόβλεψη της παραγωγή ισχύος αρκεί να χρησιμοποιήσουμε κάποιο φυσικό μοντέλο βελτιστοποιώντας την πρόβλεψη των ατμοσφαιρικών μεταβλητών. Όμως η καμπύλη ισχύος που παρουσιάστηκε παραπάνω αποτελεί την θεωρητική μορφή της, η παραγωγή της οποίας γίνεται από τους κατασκευαστές σε πλήρως ελεγχόμενες σήραγγες ανέμου[24]. Στην πραγματικότητα, η πρακτική καμπύλη ισχύος μιας ανεμογεννήτριας είναι όπως παρουσιάζεται στο σχήμα 4.3.

Η διαφορά που παρουσιάζεται ανάμεσα στην θεωρητική και την πρακτική καμπύλη ισχύος οφείλεται σε μια πληθώρα παραγόντων. Στην καμπύλη ισχύος, για τον υπολογισμό της παραγόμενης ισχύος, λαμβάνουμε υπόψη μόνο την ταχύτητα του ανέμου. Στην πραγματικότητα όμως η παραγόμενη ισχύς εξαρτάται και από άλλα χαρακτηριστικά του ανέμου πέραν της ταχύτητας, όπως η κατεύθυνση του και η πυκνότητα του. Οι συνεχείς μεταβολές των μεταβλητών αυτών οδηγούν σε αυξομειώσεις της παραγωγής ακόμη και αν η ταχύτητα παραμένει σταθερή[23].

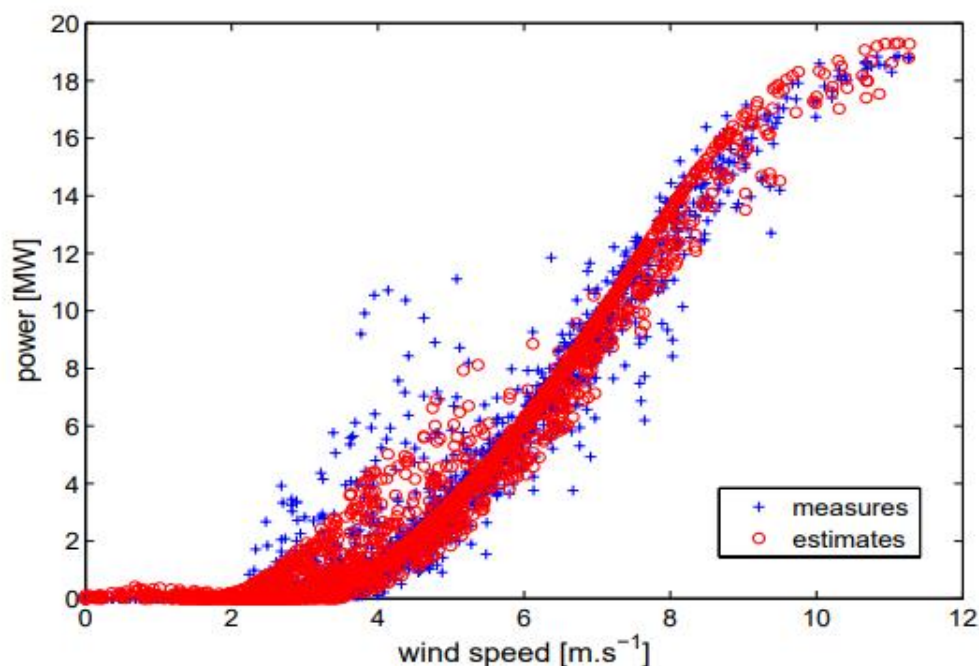
Ένας επιπλέον παράγοντας διαφοροποίησης της πραγματικής καμπύλης οφείλεται στον τρόπο με τον οποίο είναι δομημένοι οι αιολικοί σταθμοί παραγωγής. Κάθε αιολικό πάρκο αποτελείται από μια πληθώρα ανεμογεννητριών. Εφόσον η ανεμογεννήτρια χρησιμοποιεί την αιολική ενέργεια για την παραγωγή ηλεκτρικής ενέργειας ο αέρας πίσω από την ανεμογεννήτρια θα εξέρχεται με μικρότερη ταχύτητα της αρχικής. Το φαινόμενο αυτό ονομάζεται σκίαση (shadowing effect)[29]. Η επίδραση του φαινομένου σκίασης είναι τόσο έντονο ώστε για την ελαχιστοποίηση του διεξάγονται πολλαπλές μελέτες ως προς την τοποθεσία του αιολικού και την θέση κάθε ανεμογεννήτριας εντός του σταθμού.



Σχήμα 4.3



Υπάρχουν και άλλοι παράγοντες που επηρεάζουν την καμπύλη ισχύος σε μικρότερο βαθμό όπως η αλλαγή στο περιβάλλον του αιολικού σταθμού (εποχιακή βλάστηση), επέκταση του αιολικού πάρκου και η φθορά των εξαρτημάτων[24]. Επίσης εντός ενός αιολικού σταθμού δύναται να υπάρχουν πολλοί διαφορετικοί τύποι γεννητριών η κάθε μια από τις οποίες έχει την δικιά της καμπύλη ισχύος. Επομένως για την πρόβλεψη παραγωγής μέσω της καμπύλης ισχύος είναι απαραίτητος ο υπολογισμός μιας συγκεντρωτικής καμπύλης ισχύος για όλο τον σταθμό η οποία να συνυπολογίζει όλους αυτούς του παράγοντες.



Σχήμα 4.4

Ακόμα και στην περίπτωση αυτή όμως τα αποτελέσματα παρουσιάζουν αβεβαιότητα. Στο σχήμα 4.4 παρουσιάζεται μια εκτιμώμενη καμπύλη ισχύος και οι πραγματικές τιμές παραγόμενης ισχύος. Παρατηρώντας τα σχηματικά δεδομένα μπορούμε να εξάγουμε κάποια πολύ σημαντικά συμπεράσματα. Αρχικά, παρατηρούμε πως για ταχύτητες ανέμου 2-4m/s οι αναμενόμενες τιμές παραγωγής ισχύος παρουσιάζουν μεγάλη απόκλιση από την θεωρητική καμπύλη ισχύος και στην συνέχεια παρατηρούμε πως για τιμές ανέμου από 2-8m/s υπάρχουν πραγματικές τιμές ισχύος που παρουσιάζουν πολύ μεγάλη απόκλιση από τις αναμενόμενες τιμές τις οποίες το μοντέλο πρόβλεψης αποτυγχάνει να προβλέψει. Η αβεβαιότητα που παρουσιάζεται στις περιοχές αυτές αναμένεται να οδηγήσει και στο μεγαλύτερο σφάλμα πρόβλεψης του φυσικού μοντέλου. Δεδομένου πως οι τιμές ανέμου από 2-8m/s είναι οι πιο συχνά εμφανιζόμενες τιμές ταχύτητας ανέμου, όπως παρουσιάστηκε στην κατανομή της ταχύτητας ανέμου προηγουμένως, διαπιστώνουμε και το μεγαλύτερο πρόβλημα που αντιμετωπίζει το φυσικό μοντέλο πρόβλεψης.

Ένα επιπλέον πρόβλημα αποτελεί η μοναδικότητα της αθροιστικής καμπύλης ισχύος για κάθε αιολικό σταθμό παραγωγής ο υπολογισμός της οποίας απαιτεί οικονομικούς και υπολογιστικούς πόρους χωρίς να υπάρχει η δυνατότητα χρήσης τους σε πολλαπλούς σταθμούς.

Τα προβλήματα αυτά οδήγησαν στην ολοένα αυξανόμενη χρήση στατιστικών μοντέλων, και ιδίως νευρωνικών δικτύων, τόσο συνδυαστικά όσο και αυτοτελώς για την παραγωγή προβλέψεων καθώς έχει αποδειχθεί πως διαθέτουν εξαιρετικές δυνατότητες γενίκευσης και προσέγγισης της μαθηματικής σχέσης μεταξύ των δεδομένων εισόδου και εξόδου[7]. Επίσης τα μοντέλα, τα οποία βασίζονται στα νευρωνικά δίκτυα, παρουσιάζουν ικανοποιητικά αποτελέσματα ανεξαρτήτως των χαρακτηριστικών του εκάστοτε αιολικού πάρκου καθώς προσαρμόζονται σε αυτά κατά την διάρκεια της εκπαίδευσης.

# Κεφάλαιο 5: Εκτίμηση Σφάλματος

## 5.1: Εισαγωγή

Τις τελευταίες δεκαετίες παρουσιάζεται τεράστια βελτίωση στην ακρίβεια των προβλέψεων. Παρόλα αυτά η διαδικασία της πρόβλεψης πάντοτε θα εμπεριέχει κάποιο σφάλμα. Το ποσοστό του σφάλματος μεταβάλλεται ανάλογα με τον τομέα τον οποίο εφαρμόζεται η πρόβλεψη, την υπολογιστική πολυπλοκότητα καθώς και την ποσότητα και ποιότητα των δεδομένων στα οποία βασίζεται η πρόβλεψη καθώς και χρονικό ορίζοντα πρόβλεψης. Στον τομέα της αιολικής παραγωγής ηλεκτρικής ενέργειας η πρόβλεψη παραγωγής κατηγοριοποιείται σε τρεις κατηγορίες[32]:

- Άμεση βραχυπρόθεσμη πρόβλεψη με ορίζοντα πρόβλεψης 8 ωρών η οποία αποσκοπεί στον δυναμικό έλεγχο των ανεμογεννητριών με σκοπό την βέλτιστη αποδοτικότητα τους
- Βραχυπρόθεσμη πρόβλεψη με ορίζοντα πρόβλεψης 1-2 ημέρες η οποία χρησιμοποιείται στον προγραμματισμό για την ένταξη και απομόνωση ανεμογεννητριών στην παραγωγική διαδικασία του αιολικού πάρκου και την ανάπτυξη εμπορικών στρατηγικών
- Μεσοπρόθεσμη πρόβλεψη με χρονικό ορίζοντα 2-7 ημέρες η οποία είναι απαραίτητη στον προγραμματισμό των έργων συντήρησης των αιολικών πάρκων και την διαδικασία αποθήκευσης της ηλεκτρικής ενέργειας

Συνήθως ο μεγαλύτερος ορίζοντας πρόβλεψης συνεπάγεται και μεγαλύτερο σφάλμα. Ο επιθυμητός ορίζοντας πρόβλεψης επηρεάζει την μέθοδο την οποία θα χρησιμοποιηθεί για την πρόβλεψη παραγωγής.

Η επιλογή της κατάλληλης μεθόδου πρόβλεψης απαιτεί την σύγκριση των αποτελεσμάτων των διαθέσιμων μεθόδων. Για τον σκοπό υπάρχει μια πληθώρα κριτηρίων αξιολόγησης τα οποία μπορούν να εφαρμοστούν για να λάβουμε τα κατάλληλα συμπεράσματα[32].

## 5.2: Σφάλμα πρόβλεψης

Ο όρος σφάλμα πρόβλεψης περιγράφει την διαφορά της πραγματικής τιμής και της τιμής την οποία παρείχε η πρόβλεψη. Αν συμβολίσουμε το σφάλμα ως  $e(t + h|t)$  το σφάλμα πρόβλεψης μπορεί να περιγραφεί ως εξής:

$$e(t + h|t) = y(t) - \hat{y}(t + h|t)$$

Συχνά έναντι του σφάλματος πρόβλεψης χρησιμοποιείται το κανονικοποιημένο σφάλμα πρόβλεψης το οποίο περιγράφεται από την παρακάτω σχέση:

$$e(t + h|t) = \frac{1}{P_n} [y(t) - \hat{y}(t + h|t)]$$

όπου ο όρος  $P_n$  είναι η ονομαστική ισχύς του αιολικού πάρκου. Η κανονικοποίηση του σφάλματος επιτρέπει την σύγκριση των αποτελεσμάτων από διάφορα αιολικά πάρκα ανεξάρτητα από την ονομαστική ισχύ του εκάστοτε σταθμού.

Το σφάλμα  $e(t + h|t)$  μπορεί να διαχωριστεί σε συστηματικό σφάλμα  $\mu(t + h|t)$  και τυχαίο σφάλμα  $\xi(t + h|t)$  ως εξής:

$$e(t + h|t) = \mu(t + h|t) + \xi(t + h|t)$$

Το συστηματικό σφάλμα  $\mu(t + h|t)$  αποτελεί μια σταθερά και το τυχαίο σφάλμα  $\xi(t + h|t)$  αποτελεί μια τύχαια μεταβλητή η οποία ιδανικά ακολουθεί Γκαουσιανή κατανομή με μηδενική μέση τιμή.

## 5.3: Bias

Ο όρος bias αναφέρεται στην μεροληψία της μεθόδου πρόβλεψης[8]. Αποτελεί μια εκτίμηση του συστηματικού σφάλματος [33] και υπολογίζεται από τον αριθμητικό μέσο όρο των σφαλμάτων πρόβλεψης για μια συγκεκριμένη χρονική περίοδο

$$bias(h) = \frac{1}{N} \sum_{t=1}^N e(t + h|t)$$

Ο όρος N αναφέρεται στον αριθμό των προβλέψεων που χρησιμοποιούνται για την αξιολόγηση της μεθόδου πρόβλεψης.

Όσο πιο κοντά στο 0 είναι το bias τόσο καλύτερη είναι η μέθοδος πρόβλεψης. Στην πραγματικότητα το bias μια πρόβλεψης μας βοηθάει να κατανοήσουμε αν η μέθοδος μας

παράγει προβλέψεις με τιμές συστηματικά μεγαλύτερες ή μικρότερες από τις πραγματικές (αν είναι θετικό ή αρνητικό αντίστοιχα). Το bias αποτελεί ένα πολύ χρήσιμο στατιστικό στοιχείο το οποίο μπορεί να χρησιμοποιηθεί στην βελτίωση της εκάστοτε μεθόδου πρόβλεψης. Όμως δεν μπορεί να χρησιμοποιηθεί για την αξιολόγηση μια μεθόδου πρόβλεψης. Όπως αναφέραμε προηγουμένως αν το bias ισούται με 0 η πρόβλεψη είναι τέλεια αλλά αυτό δεν αληθεύει καθώς η απόλυτη τιμή του αθροίσματος των αρνητικών τιμών του σφάλματος μπορεί να ισούνται με το αντίστοιχο άθροισμα των θετικών κάνοντας το bias ίσο με το 0 χωρίς όμως να έχουμε μια τέλεια πρόβλεψη.

## 5.4: Μετρητικά Σφάλματος Σημειακής Πρόβλεψης

Για την εκτίμηση της ακρίβειας μιας σημειακής πρόβλεψης έχουν αναπτυχθεί πολλές μέθοδοι αξιολόγησης οι περισσότερες από τις οποίες βασίζονται στην μέτρηση του σφάλματος. Ένα συνηθισμένο μετρητικό σφάλματος αποτελεί το μέσο τετραγωνικό σφάλμα (Mean Square Error) το οποίο υπολογίζεται από τον τύπο:

$$MSE = \frac{1}{N} \sum_{t=1}^N e(t + h|t)^2$$

Από το MSE προκύπτει ένα επιπλέον μετρητικό σφάλματος, η ρίζα του μέσου τετραγωνικού σφάλματος (Root Mean Square Error) ως εξής:

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N e(t + h|t)^2}$$

Το MSE και το RMSE χρησιμοποιούν και τα δυο την τετραγωνική τιμή του σφάλματος για τον συνυπολογισμό των αρνητικών και των θετικών τιμών σφαλμάτων στην αξιολόγηση της ακρίβειας της πρόβλεψης. Μια εναλλακτική προσέγγιση αποτελεί η χρήση της μέσης τιμής του σφάλματος χρησιμοποιώντας το μέσο απόλυτο σφάλμα (Mean Absolute Error)

$$MAE = \frac{1}{N} \sum_{t=1}^n |e(t + h|t)|$$

Τα προαναφερθέντα μετρητικά σφάλματος βασίζονται στον απόλυτο υπολογισμό του σφάλματος. Αν και αποτελούν συχνά χρησιμοποιούμενες μεθόδους αξιολόγησης προβλέψεων έχουν κάποια μειονεκτήματα [32]:

- Το κυριότερο πρόβλημα έγκειται στο γεγονός πως οι παραπάνω μέθοδοι εξαρτώνται από την κλίμακα του προβλήματος. Το οποίο συνεπάγεται πως τα μετρητικά αυτά δεν μπορούν να εφαρμοστούν σε προβλήματα διαφορετικής κλίμακας.
- Οι μεμονωμένες ακραίες τιμές (outliers), οι οποίες είναι συνήθως στα πραγματικά προβλήματα, έχουν μεγάλη επίδραση στην αξιολόγηση της πρόβλεψης

Για την αντιμετώπιση του πρώτου προβλήματος έχει αναπτυχθεί μια κατηγορία μετρητικών σφάλματος τα οποία βασίζονται στο ποσοστιαίο σφάλμα:

$$p(t + h|t) = \frac{y(t) - \hat{y}(t + h|t)}{y(t)}$$

Τα πιο συνηθισμένα μετρητικά σφάλματος σε αυτήν την κατηγορία είναι το μέσο απόλυτο ποσοστιαίο σφάλμα (Mean Absolute Percentage Error) το οποίο υπολογίζεται από τον παρακάτω τύπο:

$$MAPE = \frac{1}{N} \sum_{t=1}^n 100 * |p(t + h|t)|$$

και η ρίζα του μέσου τετραγωνικού ποσοστιαίου σφάλματος (Root Mean Square Percentage Error):

$$RMSPE = \sqrt{\frac{1}{N} \sum_{t=1}^N p(t + h|t)^2}$$

Αν και το MAPE και το RMSPE λύνουν το πρόβλημα της διαφοράς κλίμακας των προβλημάτων δημιουργούν νέα προβλήματα όπως η διαίρεση με το μηδέν και η ασυμμετρία του προβλήματος κατά την οποία τα σφάλματα με μεγαλύτερη ή μικρότερη τιμή δεν συνεισφέρουν ισάξια.

Υπάρχουν πολλές ακόμη μέθοδοι αξιολόγησης σημειακών προβλέψεων οι οποίες επιλύουν διαφορετικά προβλήματα ανάλογα με τις ανάγκες του εκάστοτε προβλήματος (όπως για παράδειγμα η χρήση της μεθόδου MdAPE η οποία βασίζεται στον διάμεσο για την απαλοιφή των ακραίων τιμών) η ανάλυση των οποίων ξεφεύγει από το αντικείμενο μελέτης της παρούσας διπλωματικής.

## 5.5: Μετρητικά Σφάλματος Πιθανοτικής Πρόβλεψης

Για την αξιολόγηση των σφαλμάτων του μοντέλου πιθανοτικής πρόβλεψης δεν μπορούμε να χρησιμοποιήσουμε τα μετρητικά σφάλματος που παρουσιάσαμε στην σημειακή πρόβλεψη καθώς καλούμαστε να συγκρίνουμε τα πιθανοτικά αποτελέσματα που προέκυψαν από ένα σύνολο μοντέλων (ensemble models), όπως θα δούμε στο κεφάλαιο 7, με τις σημειακές παρατηρήσεις. Ένα συχνά χρησιμοποιούμενο μετρητικό σφάλματος για πιθανοτικές προβλέψεις είναι το Continuous Ranked Probability Score (CRPS)[34].

Αν με την μεταβλητή  $x$  συμβολίζουμε το μέγεθος για το οποίο διεξάγουμε την πρόβλεψη, με  $x_a$  την πραγματική τιμή του μεγέθους αυτού και με  $\rho(x)$  την συνάρτηση πυκνότητας πιθανότητας (probability density function (PDF)) για τις προβλέψεις που έχει παράγει το σύνολο (ensemble) των μοντέλων το CRPS ορίζεται με τον παρακάτω τύπο:

$$CRPS = CRPS(P, x_a) = \int_{-\infty}^{+\infty} [P(x) - P_a(x)]^2 dx$$

όπου τα  $P(x)$  και  $P_a(x)$  αντιστοιχούν στις αθροιστικές συναρτήσεις κατανομής πιθανότητας (cumulative distribution function (CDF)):

$$P(x) = \int_{-\infty}^x \rho(y) dy$$

και

$$P_a(x) = H(x - x_a)$$

με

$$H(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$$

την συνάρτηση Heaviside. Το CRPS μετράει την διαφορά μεταξύ των συναρτήσεων κατανομής της πραγματικής τιμής και των τιμών που προβλέψαμε. Η μικρότερη δυνατή τιμή που λαμβάνει είναι 0 όταν  $P=P_a$ , δηλαδή όταν έχουμε τέλεια πρόβλεψη.

# Κεφάλαιο 6: Τεχνητά Νευρωνικά Δίκτυα

## 6.1: Εισαγωγή


Με τον όρο τεχνητά νευρωνικά δίκτυα περιγράφουμε υπολογιστικά συστήματα τα οποία αποτελούν το πιο διαδεδομένο εργαλείο στην μηχανική μάθηση. Όπως φαίνεται και από τον όρο ‘νευρωνικά’ στο όνομα τους, ο τρόπος λειτουργίας τους βασίζεται στον τρόπο με τον οποίο λειτουργούν οι νευρώνες του ανθρώπινου εγκεφάλου. Αν και η λειτουργικότητα τους δεν μπορεί να συγκριθεί με αυτή ενός εγκεφάλου, λόγω της τεράστιας πολυπλοκότητας των βιολογικών νευρώνων, στις μέρες μας αποτελούν βασικό εργαλείο στην αναγνώριση μοτίβων σε δεδομένα τα οποία είναι πολύ ογκώδη ή πολύ πολύπλοκα για τον άνθρωπο[35].

## 6.2: Βασική Δομή Νευρωνικών Δικτύων


Στο Σχήμα 6.1 παρουσιάζεται η τυπική δομή ενός βασικού νευρωνικού δικτύου. Πιο συγκεκριμένα, αποτελείται από διασυνδεδεμένους κόμβους (νευρώνες) οι οποίοι είναι διατεταγμένοι σε τρία βασικά επίπεδα: το επίπεδο εισόδου, το κρυμμένο επίπεδο και το επίπεδο εξόδου. Το επίπεδο εισόδου, αποτελεί το επίπεδο το οποίο κατανέμει στο νευρωνικό δίκτυο τα προς επεξεργασία δεδομένα εισόδου και το επίπεδο εξόδου μας παρέχει τα τελικά αποτελέσματα μετά την επεξεργασία των δεδομένων. Στο κρυφό επίπεδο, το οποίο αποτελείται από ένα ή περισσότερα επίπεδα, γίνονται οι αριθμητικοί υπολογισμοί που αποτελούν μέρος της ‘εκπαίδευσης’ του νευρωνικού δικτύου[36].

Ο αριθμός των νευρώνων στα επίπεδα εισόδου και εξόδου εξαρτάται από τα χαρακτηριστικά του προβλήματος το οποίο καλείται να λύσει. Ενώ ο αριθμός των νευρώνων του κρυφού επιπέδου δεν είναι προκαθορισμένος και δεν μπορεί να γενικευθεί από κάποιον κανόνα. Αν ο αριθμός των νευρώνων είναι πολύ μικρός ή πολύ μεγάλος παρουσιάζονται προβλήματα στην αναγνώριση των μοτίβων των δεδομένων εισόδου (underfitting, overfitting) και κατά συνέπεια σφάλματα στα αποτελέσματα του νευρωνικού δικτύου[35]. Παρακάτω παρουσιάζεται σχηματικά ένας νευρώνας στο κρυφό επίπεδο (Σχήμα 6.2).





Σχήμα 6.1



Σχήμα 6.2

Κάθε νευρώνας  $j$  δέχεται μια σειρά από εισόδους  $u_1$  έως  $u_n$  σε κάθε μια από τις οποίες αντιστοιχίζεται ένα βάρος  $w_{1j}$  έως  $w_{nj}$  αντίστοιχα. Κάθε είσοδος πολλαπλασιάζεται με το αντίστοιχο βάρος και στην συνέχεια αθροίζεται με τα υπόλοιπα. Στην πραγματικότητα κάθε νευρώνας  $j$  είναι ένας αριθμός  $S(j)$  ο οποίος υπολογίζεται από την παρακάτω εξίσωση:


$$S_j = \sum_{n=1}^n w_{ij}u_j + w_{0j}$$

Στην παραπάνω εξίσωση παρατηρούμε έναν ακόμα όρο,  $w_{0j}$ , που ονομάζεται Bias. Ο όρος αυτός είναι αντίστοιχος της σταθεράς στις γραμμικές εξισώσεις και η ύπαρξη του συμβάλει στην ευελιξία του μοντέλου στο να προσαρμόζεται στο μοτίβο των δεδομένων της εισόδου. Για την καλύτερη κατανόηση του μπορούμε να υποθέσουμε έναν νευρώνα με μια μόνο είσοδο και αντίστοιχα ένα βάρος χωρίς Bias. Σε αυτήν την περίπτωση έχουμε μια γραμμική εξίσωση

$$S_j = w_j u_j$$

η οποία τέμνει την αρχή των αξόνων για οποιαδήποτε είσοδο. Με την προσθήκη του Bias η εξίσωση δεν περιορίζεται να περιστρέφεται γύρω από την αρχή των αξόνων αλλά κινείται σε όλο τον δισδιάστατο χώρο οπότε και το νευρωνικό δίκτυο αποκτά μεγαλύτερη ευελιξία.

Εφόσον υπολογιστεί ο αριθμός  $S_j$  που αποτελεί τον νευρώνα τον εισάγουμε σε μια συνάρτηση, την συνάρτηση ενεργοποίησης  $f(S_j)$ , και το αποτέλεσμα αυτό μεταφέρεται στο επίπεδο εξόδου. Παρατηρούμε πως στο δίκτυο το οποίο εξετάσαμε η ροή της πληροφορίας ακολουθεί μια κατεύθυνση, από το επίπεδο εισόδου στο κρυφό επίπεδο και από εκεί στο επίπεδο εξόδου. Τα δίκτυα αυτά ονομάζονται feedforward neural networks και ορίζονται ως κατευθυνόμενοι ακυκλικοί γράφοι. Υπάρχουν βέβαια και feedback ή recurrent δίκτυα στα οποία υπάρχει σύνδεση και μεταφορά δεδομένων σε προηγούμενα επίπεδα πριν την αναπροσαρμογή των βαρών (σχήμα 3). Παρόλα αυτά η πλειοψηφία των νευρωνικών δικτύων που χρησιμοποιείται σήμερα ακολουθούν την feedforward αρχιτεκτονική ενώ τα feedback δίκτυα αποτελούν κυρίως αντικείμενο ακαδημαϊκής έρευνας.



Σχήμα 6.3

### 6.3: Εκπαίδευση Νευρωνικών Δικτύων

Εφόσον σκιαγραφήσαμε τον τρόπο με τον οποίο δομείται ένα βασικό νευρωνικό δίκτυο μπορούμε να εξετάσουμε τον τρόπο με τον οποίο εκπαιδεύεται. Αρχικά όλα τα βάρη και τα biases αρχικοποιούνται σε μικρές τυχαίες τιμές και στην συνέχεια ξεκινάει η διαδικασία της εκπαίδευσης. Ένας εμπειρικός κανόνας είναι οι τιμές αυτές να ανήκουν στο διάστημα  $(-\frac{2}{N}, \frac{2}{N})$  για έναν νευρώνα με  $N$  εισόδους[36]. Υπάρχουν δύο προσεγγίσεις στην εκπαίδευση ενός

νευρωνικού δικτύου, η επιτηρούμενη μάθηση (supervised learning) και η μη – επιτηρούμενη μάθηση (unsupervised learning)[40].

### 6.3.1: Επιτηρούμενη Μάθηση

Η επιτηρούμενη μάθηση αποτελεί την επικρατούσα τεχνική εκπαίδευσης νευρωνικών δικτύων και βασίζεται στην σύγκριση των αποτελεσμάτων του εκάστοτε νευρωνικού δικτύου με τα επιθυμητά αποτελέσματα. Κατά την μέθοδο αυτή τα βάρη, τα οποία αρχικά λαμβάνουν τυχαίες τιμές, μεταβάλλονται με σκοπό την σύγκλιση των τιμών του νευρωνικού δικτύου και των επιθυμητών τιμών στην επόμενη επανάληψη. Πιο συγκεκριμένα η διαδικασία αυτή αποσκοπεί στην ελαχιστοποίηση του σφάλματος σε κάθε επανάληψη μεταβάλλοντας τα βάρη των νευρώνων έως ότου επιτευχθεί η απαιτούμενη ακρίβεια.

Τα νευρωνικά δίκτυα τα οποία βασίζονται στην επιτηρούμενη μάθηση πρέπει αρχικά να εκπαιδευτούν ώστε να έχουν την δυνατότητα παραγωγής χρήσιμων αποτελεσμάτων. Κατά την διαδικασία της εκπαίδευσης το δίκτυο τροφοδοτείται με τα δεδομένα εισόδου και εξόδου τα οποία αποτελούν τα πρότυπα εκπαίδευσης (training set) του νευρωνικού δικτύου. Δηλαδή για κάθε σύνολο δεδομένων εισόδου, παρέχεται και το αντίστοιχο σύνολο δεδομένων εξόδου τα οποία αποτελούν τα πραγματικά αποτελέσματα που αντιστοιχούν στα δεδομένα εισόδου. Η εκπαίδευση ενός νευρωνικού δικτύου αποτελεί συχνά μια χρονοβόρα διαδικασία η οποία μπορεί να διαρκέσει εβδομάδες ανάλογα με την πολυπλοκότητα της εκάστοτε εφαρμογής και τους υπολογιστικούς πόρους τους οποίους διαθέτουμε. Όταν το δίκτυο παράγει αποτελέσματα με σφάλμα το οποίο ικανοποιεί την ζητούμενη στατιστική ακρίβεια ολοκληρώνεται η διαδικασία της εκπαίδευσης. Στην συνέχεια τα βάρη οριστικοποιούνται στις παρούσες τιμές και το νευρωνικό δίκτυο είναι έτοιμο για την συγκεκριμένη εφαρμογή. Κάποιοι τύποι νευρωνικών δικτύων δίνουν την δυνατότητα της εκπαίδευσης ταυτόχρονα με την λειτουργία του δικτύου. Στις περιπτώσεις αυτές ο χρόνος ο οποίος απαιτείται για την εκπαίδευση του δικτύου αυξάνεται αλλά δίνει την δυνατότητα στο δίκτυο να προσαρμόζεται στις μεταβολές του συστήματος.

Για την επιτυχημένη εκπαίδευση ενός νευρωνικού δικτύου τα πρότυπα εκπαίδευσης απαιτείται να αποτελούνται από πολύ μεγάλο όγκο αριθμητικών δεδομένων και επίσης να περιέχουν ένα μεγάλο εύρος διαφορετικών δεδομένων ώστε το δίκτυο να είναι σε θέση να αναγνωρίσει τα μοτίβα και τις εξαρτήσεις που παρουσιάζονται σε αυτά. Επίσης, ως προς την αποδοτικότητα των νευρωνικών δικτύων, σημαντικό ρόλο διαδραματίζει και ο τρόπος αναπαράστασης των δεδομένων. Εφόσον το εκάστοτε δίκτυο επεξεργάζεται αποκλειστικά αριθμητικά δεδομένα,

στα διαθέσιμα φυσικά μοτίβα εκπαίδευσης (π.χ. φωτογραφίες, βίντεο) θα πρέπει οι υπό μελέτη παράμετροι να μοντελοποιηθούν μαθηματικά ώστε να τροφοδοτηθούν στο δίκτυο. Στην συνέχεια τα διαθέσιμα αριθμητικά δεδομένα κανονικοποιούνται στα πρότυπα του δικτύου. Στις σύγχρονες εφαρμογές νευρωνικών δικτύων η προεπεξεργασία των δεδομένων αποτελεί μια αυτοματοποιημένη διαδικασία.

### 6.3.2: Μη- Επιτηρούμενη Μάθηση

Η διαδικασία της μη-επιτηρούμενης μάθησης βασίζεται στην τροφοδότηση δεδομένων εισόδου στο δίκτυο χωρίς δεδομένα για την επιθυμητή έξοδο[42]. Η μελέτη και ανάπτυξη των περισσότερων μη-επιτηρούμενων δικτύων περιορίζεται στην ακαδημαϊκή κοινότητα διότι η λειτουργία του δεν είναι πλήρως κατανοητή και αποτελεί αντικείμενο έρευνας. Παρόλα αυτά όμως τα ικανοποιητικά αποτελέσματα των δικτύων αυτών σε ορισμένες εφαρμογές, στις οποίες τα μοτίβα εκπαίδευσης δεν είναι διαθέσιμα, αναδεικνύουν τις μελλοντικές δυνατότητες τους[35].

Εφόσον στα δίκτυα αυτά παρέχονται αποκλειστικά δεδομένα εισόδου η εκπαίδευση τους δεν επηρεάζεται από εξωτερικούς παράγοντες αλλά η εκτίμηση της αποτελεσματικότητάς αποτελεί μια ενσωματωμένη διαδικασία του δικτύου. Πιο συγκεκριμένα το δίκτυο δομείται κατάλληλα ώστε να αναζητάει μοτίβα στα δεδομένα εισόδου και να προσαρμόζεται σε αυτά ανάλογα με τις απαιτήσεις του προβλήματος. Αν και δεν παρέχουμε πληροφορίες αναφορικά με την ορθότητα των αποτελεσμάτων, παρέχουμε στο δίκτυο κάποιες πληροφορίες για τον τρόπο διαχείρισης των δεδομένων εισόδου και επίσης ορίζουμε σε αυτό κανόνες μάθησης.

## 6.4: Backpropagation

Με τον όρο backpropagation αναφερόμαστε στον πιο διαδεδομένο αλγόριθμο εκπαίδευσης feedforward νευρωνικών δικτύων επιτηρούμενης μάθησης ο οποίος βασίζεται στη μέθοδο μείωσης της κλίσης gradient descent[41]. Ο αλγόριθμος backpropagation επινοήθηκε το 1970 όμως η χρησιμότητα στον χώρο της μηχανικής μάθησης διαφάνηκε το 1986 με την δημοσίευση του paper "Learning Representations by Back-Propagating Errors" από τους Rumelhart, Hinton και Williams[49]. Η μέθοδος αυτή βασίζεται στην συνάρτηση σφάλματος ενός δεδομένου νευρωνικού δικτύου. Πιο συγκεκριμένα βασίζεται στον υπολογισμό της μερικής παραγώγου της συνάρτησης κόστους ως προς τα βάρη και τα biases του δικτύου.

Ο υπολογισμός των μερικών παραγώγων γίνεται από πίσω προς τα εμπρός με τον υπολογισμό αρχικά του τελευταίου επιπέδου και στο τέλος του πρώτου επιπέδου. Ο υπολογισμός των μερικών παραγώγων του παρόντος επιπέδου χρησιμοποιείται στον υπολογισμό του προηγούμενου επιπέδου μεταφέροντας το σφάλμα στο αρχικό επίπεδο μεταβάλλοντας τα βάρη και τα biases σύμφωνα με τον συντελεστή εκμάθησης που προκύπτει από τους υπολογισμούς.

## 6.5: Extreme Learning Machines

Τα αποτελέσματα που παρουσιάζουν τα τεχνητά νευρωνικά δίκτυα στον τομέα των προβλέψεων τα τελευταία χρόνια έχουν οδηγήσει στην ραγδαία αύξηση του μεριδίου της αγοράς που καταλαμβάνουν, σε μια πληθώρα εφαρμογών. Η αύξηση αυτή παρατηρείται και στον τομέα της αιολικής παραγωγής ενέργειας καθώς αναπτύσσονται συνεχώς νέα μοντέλα πρόβλεψης τα οποία βασίζονται σε διαφορετικούς τύπους νευρωνικών δικτύων. Στα πλαίσια της παρούσας διπλωματικής εργασίας αναπτύχθηκε ένα μοντέλο πιθανοτικής πρόβλεψης αιολικής παραγωγής βασισμένο στα Extreme Learning Machines(ELM)[39].

Τα ELM είναι feedforward νευρωνικά δίκτυα ενός κρυφού επιπέδου (single hidden-layer feedforward neural network). Δεδομένων  $N$  τυχαίων διακριτών παρατηρήσεων  $\{(x_i, t_i)\}$  για  $i=1$  ως  $N$  όπου  $x_i \in \mathbf{R}^n$  με  $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T$  και  $t_i \in \mathbf{R}^m$  με  $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T$ , ένα ELM με  $K$  κόμβους (νευρώνες) κρυφού επιπέδου και συνάρτηση ενεργοποίησης  $g(x)$  μοντελοποιείται μαθηματικά με τον παρακάτω τύπο:

$$f(x_j; w, b, \beta) = \sum_{i=1}^K \beta_i * g(w_i * x_j + b_i) = o_j, \quad j = 1, 2, \dots, N$$

Όπου η μεταβλητή  $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$  αποτελεί το διάνυσμα των βαρών που συνδέει τον κόμβο  $i$  του κρυφού επιπέδου με τους κόμβους του επιπέδου εισόδου,  $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$  το διάνυσμα βαρών που συνδέει τον κόμβο  $i$  του κρυφού επιπέδου με τους κόμβους του επιπέδου εξόδου και  $b_i$  το κατάφλι του κρυφού κόμβου  $i$ .

Ένα τυπικό SLFN (single hidden-layer feedforward neural network) με  $K$  κόμβους κρυφού επιπέδου και συνάρτηση ενεργοποίησης  $g(x)$  μπορεί να προσεγγίσει τις  $N$  τυχαίες παρατηρήσεις με μηδενική τιμή μέσου όρου σφάλματος, δηλαδή  $\sum_{j=1}^K \|o_j - t_j\| = 0$ . Επομένως υπάρχουν  $\beta_i, b_i$  και  $w_i$  τέτοια ώστε

$$f(x_j; w, b, \beta) = \sum_{i=1}^K \beta_i * g(w_i * x_j + b_i) = t_j, \quad j = 1, 2, \dots, N$$

Για ένα δεδομένο SLFN υπάρχουν  $N$  τέτοιες εξισώσεις (όσες και οι κόμβοι του κρυφού επιπέδου) οι οποίες μπορούν να γραφούν:

$$\mathbf{H}\beta = \mathbf{T}$$

Όπου ο πίνακας  $\mathbf{H}$  είναι ο πίνακας εξόδου του κρυφού επιπέδου:

$$\mathbf{H}_{N \times K} = \begin{bmatrix} g(w_1 * x_1 + b_1) & \cdots & g(w_K * x_1 + b_K) \\ \vdots & \ddots & \vdots \\ g(w_1 * x_N + b_1) & \cdots & g(w_K * x_N + b_K) \end{bmatrix}$$

Ο πίνακας  $\beta$  συμβολίζει τον πίνακα των βαρών εξόδου:

$$\beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \dots \\ \beta_K \end{bmatrix}$$

Και ο πίνακας  $\mathbf{T}$  αποτελεί τον πίνακα των επιθυμητών τιμών εξόδου:

$$\mathbf{T} = \begin{bmatrix} t_1 \\ t_2 \\ \dots \\ t_m \end{bmatrix}$$

Ως τώρα το νευρωνικό δίκτυο δεν διαφοροποιείται από τα συμβατικά SLFN. Η διαφορά τους έγκειται στον αλγόριθμο εκπαίδευσης. Η εκπαίδευση ενός SLFN βασίζεται στον αλγόριθμο backpropagation. Πιο συγκεκριμένα, η διαδικασία της εκπαίδευσης αποσκοπεί στην εύρεση τιμών για τις μεταβλητές  $w_i, b_i, \beta_i$  για  $i = 1, 2, \dots, K$  για τις οποίες ισχύει:

$$\|\mathbf{H} * \hat{\beta} - \mathbf{T}\| = \min_{w_i, b_i, \beta_i} \|\mathbf{H} * \beta - \mathbf{T}\|$$

Το οποίο αντιστοιχεί στην ελαχιστοποίηση της συνάρτησης κόστους:

$$E = \sum_{j=1}^N \left( \sum_{i=1}^K \beta_i * g(w_i * x_j + b_i) - t_j \right)^2$$

Σύμφωνα με τον αλγόριθμο backpropagation ένας αλγόριθμος βασισμένος στο gradient descent χρησιμοποιείται για την εύρεση του  $\min_{w_i, b_i, \beta_i} \|\mathbf{H} * \beta - \mathbf{T}\|$ . Στην διαδικασία της ελαχιστοποίησης το διάνυσμα  $\mathbf{W}$ , το οποίο αποτελεί το σύνολο των βαρών ( $w_i, b_i$ ) και των biases ( $\beta_i$ ), προσαρμόζεται επαναληπτικά σύμφωνα με την παρακάτω σχέση:

$$W_k = W_{k-1} - n \frac{\partial E(W)}{\partial W}$$

Όπου  $n$  είναι ο ρυθμός εκμάθησης (learning rate) του νευρωνικού δικτύου.

Η διαδικασία όμως της εκπαίδευσης ενός νευρωνικού δικτύου μέσω του αλγόριθμου backpropagation παρουσιάζει κάποια προβλήματα τα οποία είναι τα εξής:

- Εφόσον η αποτελεσματικότητα του αλγόριθμου εξαρτάται από τον ρυθμό εκμάθησης  $n$ . Αν το  $n$  είναι μικρό ο αλγόριθμος εκμάθησης συγκλίνει πολύ αργά ενώ αν είναι πολύ μεγάλο παρουσιάζονται προβλήματα σταθερότητας διότι μπορεί να αποκλίνει
- Ένα επιπλέον πρόβλημα του αλγόριθμου αυτού αποτελεί η ύπαρξη τοπικών ελαχίστων στα οποία μπορεί να σταματήσει. Ιδανικά ο αλγόριθμος δεν θα πρέπει να σταματάει σε αυτά όταν βρίσκονται πολύ πιο ψηλά από το ολικό ελάχιστο.
- Στα νευρωνικά δίκτυα που χρησιμοποιούν το backpropagation μπορεί να παρουσιαστεί overfitting κατά το οποίο όταν καλείται να παράγει αποτελέσματα για κάποιο άλλο σύνολο εκτός του training set η αποδοτικότητα του μειώνεται.
- Τέλος ένα από τα σημαντικότερα προβλήματα των SLNF που χρησιμοποιούν backpropagation αποτελεί ο χρόνος που απαιτείται για την εκπαίδευση τους στην πλειοψηφία των εφαρμογών.

Κάποια από αυτά τα προβλήματα επιλύονται με την χρήση ενός νέου αλγόριθμου εκμάθησης ο οποίος χρησιμοποιείται στα Extreme Learning Machines (ELM). Τα βάρη του επιπέδου εισόδου  $w_i$  και τα biases  $b_i$  αρχικοποιούνται σε τυχαίες τιμές και σε αντίθεση με τον αλγόριθμο backpropagation δεν μεταβάλλονται και ο πίνακας  $\mathbf{H}$  παραμένει αμετάβλητος κατά την διαδικασία της εκπαίδευσης.

Εφόσον τα  $w_i$  και  $b_i$  δεν μεταβάλλονται η εκπαίδευση ενός ELM αντιστοιχεί στην εύρεση μια λύσης ελαχίστων τετραγώνων για το παρακάτω γραμμικό σύστημα:

$$\hat{\beta} = \mathbf{H}^+ \mathbf{T}$$

Όπου  $\mathbf{H}^+$  είναι ο Moore-Penrose γενικευμένος αντίστροφος πίνακας του πίνακα  $\mathbf{H}$ .

Η χρήση των Extreme Learning Machines παρουσιάζει ορισμένα πλεονεκτήματα έναντι της χρήσης άλλων τύπων νευρωνικών δικτύων. Το κυριότερο πλεονέκτημα τους, και ο λόγος που τα καθιστά ιδανικά για παραγωγή βραχυπρόθεσμων προβλέψεων αιολικής παραγωγής, αποτελεί η αποφυγή της χρήσης του χρονοβόρου επαναληπτικού αλγόριθμου backpropagation. Η εκπαίδευση των ELM περιορίζεται σε έναν πολλαπλασιασμό πινάκων γεγονός το οποίο ελαχιστοποιεί σημαντικά τον χρόνο που απαιτείται για την εκπαίδευση τους. Όπως παρουσιάζεται και στο [39] για την επίλυση ενός προβλήματος με χρήση ELM έναντι ενός

συμβατικού νευρωνικού δικτύου backpropagation ο χρόνος εκπαίδευσης μειώνεται από 21.26s σε 0.125s παρουσιάζοντας ταυτόχρονα καλύτερη ακρίβεια αποτελεσμάτων. Ένα επιπλέον πλεονέκτημα από την αποφυγή της χρήσης του backpropagation αποτελεί η μη εμφάνιση τοπικών ελαχίστων κατά την εκπαίδευση του μοντέλου τα οποία επηρεάζουν την ακρίβεια του μοντέλου.



# Κεφάλαιο 7: Μοντέλο Πιθανοτικής Πρόβλεψης

## 7.1: Εισαγωγή

Όπως αναφέρθηκε και στα προηγούμενα κεφάλαια η ακρίβεια με την οποία μπορούμε να προβλέψουμε την αιολική παραγωγή ενέργειας υπόκειται σε κάποιους φυσικούς περιορισμούς οι οποίοι οφείλονται στην πολυπλοκότητα των εξισώσεων που διέπουν την συμπεριφορά της ατμόσφαιρας και πιο συγκεκριμένα στην χαοτική φύση του ανέμου. Αν και η ακρίβεια της ντετερμινιστικής πρόβλεψης έχει βελτιωθεί αρκετά τα τελευταία χρόνια, ποτέ δεν θα μπορέσει να είναι τέλεια. Ο περιορισμός αυτός έχει οδηγήσει στην ανάπτυξη πιθανοτικών μοντέλων πρόβλεψης τα οποία παρέχουν πληροφορίες αναφορικά με την αξιοπιστία της πρόβλεψης.

Για την παραγωγή πιθανοτικής πρόβλεψης αιολικής παραγωγής χρησιμοποιούμε ένα σύνολο μοντέλων πρόβλεψης (ensemble models forecasting) τα οποία παράγουν ένα μεγάλο δείγμα πιθανών μελλοντικών αποτελεσμάτων για την υπό μελέτη μεταβλητή και στην συνέχεια από το διαθέσιμο δείγμα εξετάζουμε την κατανομή της μεταβλητής με σκοπό να εξάγουμε τα δεδομένα για την αξιοπιστία της πρόβλεψης. Για την παραγωγή του δείγματος προβλέψεων μπορούν να χρησιμοποιούνται είτε πολλαπλές προβλέψεις ενός μοντέλου με διαφοροποιημένα δεδομένα εισόδου, είτε διαφορετικά μοντέλα τα οποία καλούνται να προβλέψουν στα ίδια δεδομένα εισόδου. Η βασική ιδέα της πιθανοτικής πρόβλεψης έγκειται στο γεγονός πως για τα δεδομένα εισόδου στα οποία τα αποτελέσματα παρουσιάζουν μεγάλη απόκλιση τιμών η αξιοπιστία της πρόβλεψης θα είναι μικρή ενώ για εκείνα που συγκλίνουν στην ίδια τιμή η αξιοπιστία θα αυξάνεται.

## 7.2: Bootstrapping

Το πιθανοτικό μοντέλο που αναπτύχθηκε στα πλαίσια της εργασίας ανήκει στην πρώτη κατηγορία καθώς για την παραγωγή των διαστημάτων εμπιστοσύνης χρησιμοποιήθηκε το ντετερμινιστικό μοντέλο ELM, που περιγράψαμε στο προηγούμενο κεφάλαιο, για ένα διαφοροποιημένο σύνολο δεδομένων εισόδου και αποτελεσμάτων το οποίο παραγάγαμε με την μέθοδο του bootstrapping[43].

Πιο συγκεκριμένα, χρησιμοποιήσαμε την μέθοδο pairs bootstrapping, η οποία βασίζεται στην δημιουργία ενός νέου συνόλου δεδομένων εισόδου- εξόδου κάνοντας δειγματοληψία με

επανατοποθέτηση στα αρχικά δεδομένα χρησιμοποιώντας ομοιόμορφη κατανομή. Αρχικά το σύνολο των δεδομένων που διαθέτουμε διαχωρίζεται σε δύο υποσύνολα, το ένα για την εκπαίδευση και το άλλο για την αξιολόγηση του μοντέλου. Δεδομένου ενός συνόλου  $N$  δεδομένων εκπαίδευσης  $\{[x_i, t_i]\}$  για  $i = 1, 2, \dots, N$ , ο αλγόριθμος [8] που συνοψίζεται στα παρακάτω βήματα περιγράφει την διαδικασία της παραγωγής  $B$  διαφοροποιημένων συνόλων δεδομένων εκπαίδευσης εκ του αρχικού και κατά συνέπεια  $B$  συνόλων προβλέψεων επί των δεδομένων αξιολόγησης:

- Παραγωγή  $N$  νέων ζευγών παρατηρήσεων  $\{[x_i^*, t_i^*]\}$  για  $i = 1, 2, \dots, N$  δειγματοληπτώντας ομοιόμορφα και με επανατοποθέτηση από το αρχικό σύνολο παρατηρήσεων που προορίζονταν για την εκπαίδευση του μοντέλου.
- Παραγωγή των προβλέψεων  $\hat{y}_j(x_i^*)$  από το ντετερμινιστικό μοντέλο ELM χρησιμοποιώντας ως δεδομένα εκπαίδευσης τις νέες παρατηρήσεις που δημιουργήσαμε στο πρώτο βήμα.
- Επανάληψη των προηγούμενων βημάτων έως ότου αποκτήσουμε  $B$  σύνολα προβλέψεων  $\hat{y}_j(x_i^*)$  για  $i = 1, 2, \dots, N$  και  $j = 1, 2, \dots, B$

### 7.3: Παραγωγή Διαστημάτων Εμπιστοσύνης

Για να μπορέσουμε να μπορέσουμε να ποσοτικοποιήσουμε την αξιοπιστία των παραγόμενων σημειακών προβλέψεων  $\hat{y}(x_i)$  (εκτιμήτρια) αναφορικά με τις πραγματικές τιμές των παρατηρήσεων  $y(x_i)$  θα πρέπει αρχικά να κατασκευάσουμε τα διαστήματα εμπιστοσύνης. Για να υπολογίσουμε το  $\hat{y}(x_i)$  θα χρησιμοποιήσου την μέθοδο bootstrap. Αν παράγουμε  $B$  νέα σύνολα εκπαίδευσης, κάνοντας κάθε φορά bootstrapping στα αρχικά δεδομένα, το  $\hat{y}(x_i)$  μπορεί να περιγραφεί από τη εξίσωση:

$$\hat{y}(x_i) = \frac{1}{B} \sum_{j=1}^B \hat{y}_j(x_i)$$

και αποτελεί την μέση τιμή των προβλέψεων που παρήγαγαν  $B$  bootstrapped ELM(BELM), με τον όρο  $\hat{y}_j(x_i)$ ,  $i = 1, 2, \dots, N_{test}$  να αποτελεί τις σημειακές προβλέψεις που παρήγαγε το εκάστοτε BELM. Με τον τρόπο αυτό λαμβάνουμε μια λιγότερο μεροληπτική, ως προς το σφάλμα, εκτίμηση των σημειακών προβλέψεων απ' ότι αν χρησιμοποιούσαμε τα αποτελέσματα του ντετερμινιστικού μοντέλου.

Η διακύμανση (variance) της αβεβαιότητας της εκτίμησης του σφάλματος από το μοντέλο μπορεί να εκτιμηθεί από τις προβλέψεις που έχουμε λάβει από τα K BELM με τον παρακάτω τύπο[44]:

$$\sigma_{\hat{y}}^2(x_i) = \frac{1}{B-1} \sum_{j=1}^B (\hat{y}_j(x_i) - \hat{y}(x_i))^2$$

Στην συνέχεια για να κατασκευάσουμε τα διαστήματα εμπιστοσύνης του πιθανοτικού μοντέλου πρόβλεψης  $I_K^a(x_i) = [L_K^a(x_i), U_K^a(x_i)]$ , για επίπεδο εμπιστοσύνης  $P(x_i \in I_K^a) = 100(1-a)\%$ , θα χρησιμοποιήσουμε τους τύπους[8]:

$$L_K^a(x_i) = \hat{y}(x_i) - z_{1-a/2} \sqrt{\sigma_{\hat{y}}^2(x_i)}$$

$$U_K^a(x_i) = \hat{y}(x_i) + z_{1-a/2} \sqrt{\sigma_{\hat{y}}^2(x_i)}$$

όπου  $L_K^a(x_i)$  είναι το κάτω όριο,  $U_K^a(x_i)$  το άνω όριο και  $z_{1-a/2}$  η αθροιστική πιθανότητα της κατανομής της μεταβλητής  $z = \frac{x_i - \mu}{\sigma}$  η οποία ακολουθεί την τυποποιημένη κανονική κατανομή  $N(0,1)$ .

## 7.4: Αξιολόγηση Αξιοπιστίας

Χρησιμοποιώντας τις παραπάνω σχέσεις για την παραγωγή των διαστημάτων εμπιστοσύνης  $[L_K^a(x_i), U_K^a(x_i)]$ , εξ ορισμού θα πρέπει η πιθανότητα να βρίσκονται οι πραγματικές τιμές  $y(x_i)$  εντός των ορίων αυτών να είναι ίση με το επίπεδο εμπιστοσύνης  $PINC = P(x_i \in I_K^a) = 100(1-a)\%$  (Prediction Interval Nominal Confidence). Για να αξιολογήσουμε την αξιοπιστία των διαστημάτων εμπιστοσύνης θα χρησιμοποιήσουμε την πιθανότητα κάλυψης (Prediction Interval Coverage Probability (PICP))[45] η οποία ορίζεται ως:

$$PICP = \frac{1}{N} \sum_{i=1}^N c_i$$

Όπου N ο αριθμός των ζευγών των δεδομένων αξιολόγησης (test data) και  $c_i = \begin{cases} 1, & y(x_i) \in I_K^a \\ 0, & \text{αλλιώς} \end{cases}$ .

Για να έχουμε αξιόπιστα διαστήματα εμπιστοσύνης θα πρέπει το  $PICP$ , το οποίο λαμβάνουμε από της πραγματικές τιμές και τα διαστήματα εμπιστοσύνης που υπολογίσαμε, να έχει όσο το

δυνατόν πλησιέστερη τιμή στο επιθυμητό  $PINC$ . Ένα επιπλέον δείκτης αξιολόγησης είναι ο average coverage error (ACE) και ορίζεται ως:

$$ACE = PICP - PINC$$

Επομένως όσο πιο κοντά βρίσκεται η τιμή του ACE στο 0 τόσο αυξάνεται η αξιοπιστία του πιθανοτικού μοντέλου που έχουμε κατασκευάσει.

## 7.5: Αξιολόγηση Εύρους Διαστημάτων Εμπιστοσύνης

Η διασφάλιση της αξιοπιστίας όμως, δεν αρκεί για να αξιολογήσουμε πλήρως την αποτελεσματικότητα του πιθανοτικού μοντέλου. Έχοντας μεγάλο εύρος διαστημάτων εμπιστοσύνης διασφαλίζουμε πολύ μεγάλη πιθανότητα κάλυψης (PICP) χωρίς όμως να παρέχουμε κάποια χρήσιμη πληροφορία. Για να μπορέσουμε να αξιολογήσουμε το εύρος των διαστημάτων εμπιστοσύνης θα χρησιμοποιήσουμε τον δείκτη  $Sc_y^a$  (Score)[8].

Αν ορίσουμε το εύρος του διαστήματος εμπιστοσύνης για την  $i$ -οστή παρατήρηση ως:

$$\delta_y^a(x_i) = U_y^a(x_i) - L_y^a(x_i)$$

Μπορούμε στην συνέχεια να ορίσουμε τον δείκτη  $Sc_y^a$  για το σύνολο των παρατηρήσεων των δεδομένων αξιολόγησης ως εξής:

$$Sc_y^a(x_i) = \begin{cases} -2 * \alpha * \delta_y^a(x_i) - 4[L_y^a(x_i) - y_i], & y_i < L_y^a(x_i) \\ -2 * \alpha * \delta_y^a(x_i), & y_i \in I_y^a(x_i) \\ -2 * \alpha * \delta_y^a(x_i) - 4[y_i - U_y^a(x_i)], & y_i > U_y^a(x_i) \end{cases}$$

όπου το  $\alpha$  αντιστοιχεί στο επίπεδο εμπιστοσύνης  $PINC = P(x_i \in I_K^a) = 100(1 - \alpha)\%$  και το  $y_i$  την πραγματική τιμή της μεταβλητής που καλούμαστε να προβλέψουμε. Επομένως έχουμε λάβει τόσες τιμές για τον δείκτη όσο και το πλήθος των σετ δεδομένων αξιολόγησης για το οποίο κληθήκαμε να προβλέψουμε.

Τελικά παίρνοντας τον μέσο όρων των δεικτών αυτών σύμφωνα με τον παρακάτω τύπο

$$Sc_y^a = \frac{1}{N_{test}} \sum_{i=1}^N Sc_y^a(x_i)$$

λαμβάνουμε μια τιμή η οποία χρησιμοποιείται για την αξιολόγηση των διαστημάτων εμπιστοσύνης.

Παρατηρώντας τον τύπο για το  $Sc_y^a(x_i)$  διαπιστώνουμε πως όσο πιο κοντά στο μηδέν βρίσκεται η τιμή του, τόσο μικρότερο το μέσο εύρος των διαστημάτων εμπιστοσύνης και επομένως τόσο καλύτερη κρίνεται και η απόδοση του πιθανοτικού μοντέλου. Επίσης παρατηρούμε πως όταν η πραγματική τιμή της μεταβλητής που καλούμαστε να προβλέψουμε βρίσκεται εκτός του διαστήματος εμπιστοσύνης η απόλυτη τιμή του δείκτη αυξάνεται περισσότερο συγκριτικά με την περίπτωση του να βρίσκεται εντός του διαστήματος. Επομένως, ο δείκτης  $Sc_y^a$  δεν εξαρτάται αποκλειστικά από το εύρος του διαστήματος εμπιστοσύνης αλλά επηρεάζεται και από το πλήθος των τιμών που περιέχονται σε αυτό, εμπεριέχοντας ταυτόχρονα πληροφορίες και για το εύρος τιμών των διαστημάτων εμπιστοσύνης και για την αξιοπιστία της πρόβλεψης. Καθώς όμως δεν είναι σαφές πόσο συνεισφέρει ο κάθε αρνητικός όρος στην διαμόρφωση του δείκτη, για την αξιολόγηση της αξιοπιστία της πρόβλεψης θα χρησιμοποιηθεί ο δείκτης  $ACE$  που παρουσιάστηκε.

# Κεφάλαιο 8: Περιγραφή Πιθανοτικού Μοντέλου Πρόβλεψης Αιολικής Ισχύος

## 8.1: Ανάλυση Δεδομένων

Όπως επιγραμματικά αναφέραμε και στην εισαγωγή τα δεδομένα που χρησιμοποιήθηκαν για την ανάπτυξη και αξιολόγηση του πιθανοτικού μοντέλου πρόβλεψης αιολικής ισχύος αποτελούν μέρος των δεδομένων που δόθηκαν στους διαγωνιζομένους του διεθνούς διαγωνισμού Global Energy Forecasting Competition 2014. Τα δεδομένα αποτελούνται από τις προβλέψεις ανέμου σε δύο υψόμετρα, στα 10μ και στα 100μ από την επιφάνεια του εδάφους, τα οποία έχουν παραχθεί από το μοντέλο αριθμητικών προβλέψεων καιρού του European Centre for Medium-range Weather Forecasts (ECMWF) για της γεωγραφικές περιοχές που αντιστοιχούν σε 10 σταθμούς αιολικής παραγωγής στην Αυστραλία. Οι προβλέψεις ανέμου έχουν παραχθεί με χρονικό ορίζοντα πρόβλεψης μια ημέρα και χρονική ανάλυση μίας ώρας, λαμβάνοντας έτσι 24 ωριαίες προβλέψεις για κάθε ημέρα. Επίσης παράλληλα με τις προβλέψεις ανέμου στα δεδομένα περιέχονται και οι αντίστοιχες πραγματικές τιμές της παραγόμενης ισχύος σε ωριαία βάση.


Τα δεδομένα που αφορούν την παραγόμενη ισχύ είναι κανονικοποιημένα σύμφωνα με την ονομαστική εγκατεστημένη ισχύ του αιολικού σταθμού στον οποίο αντιστοιχούν, ενώ οι προβλέψεις ανέμου έχουν παραμείνει αμετάβλητες. Οι προβλέψεις ανέμου δίνονται σε καρτεσιανές συντεταγμένες και αποτελούνται από τις μεταβλητές  $U$  (άξονας Δύση-Ανατολή) και  $V$  (άξονας Νότος-Βορράς) οι οποίες αποτελούν τις οριζόντιες συνιστώσες της ταχύτητας του ανέμου στις προγνωστικές εξισώσεις του μοντέλου αριθμητικών προβλέψεων καιρού. Για την αξιολόγηση του μοντέλου προβλέψεων χρησιμοποιήθηκαν δεδομένα ενός έτους (από 01/01/2012 01:00 έως 01/01/2013 00:00). Επομένως, είχαμε στην διάθεση μας 8785 σετ 5 δεδομένων ( $U_{10m}, V_{10m}, U_{100m}, V_{100m}$  και  $P_{norm}$ ) ωριαίας ανάλυσης.

Απαραίτητο βήμα της διαδικασίας πριν την ανάπτυξη του μοντέλου αποτέλεσε ο διαχωρισμός των δεδομένων σε δεδομένα εισόδου και δεδομένα εξόδου. Ως δεδομένα εισόδου είχαμε έναν πίνακα  $X_{8785 \times 4}$  ο οποίος περιείχε τις μεταβλητές  $U_{10m}, V_{10m}, U_{100m}, V_{100m}$  και ως δεδομένα εξόδου έναν πίνακα  $Y_{8785 \times 1}$  με την μεταβλητή  $P_{norm}$ . Στην συνέχεια τα δεδομένα διαχωρίστηκαν περαιτέρω σε δεδομένα εκπαίδευσης (training data) και δεδομένα αξιολόγησης (test data). Τα δεδομένα εκπαίδευσης αποτελούνταν από τους πίνακες  $X_{train_{8485 \times 4}}$  και

$Y_{train}_{8485 \times 1}$  και ως δεδομένα αξιολόγησης κρατήθηκαν οι τελευταίες 300 παρατηρήσεις οι οποίες αποτελούσαν τους πίνακες  $X_{test}_{300 \times 4}$  και  $Y_{test}_{300 \times 1}$  αντίστοιχα.

## 8.2: Ανάπτυξη μοντέλου ELM για την Παραγωγή Σημειακής Πρόβλεψης

Το ντετερμινιστικό μοντέλο πρόβλεψης αναπτύχθηκε σε προγραμματιστικό περιβάλλον Python σύμφωνα με τα στοιχεία θεωρίας που διέπουν την λειτουργία των Extreme Learning Machines (αναπτύχθηκαν στο κεφάλαιο 6) και παρουσιάζεται σχηματικά στο σχήμα 8.1. Σκοπός του μοντέλου αποτελεί η παραγωγή σημειακής πρόβλεψης παραγωγής αιολικής ενέργειας με ημερήσιο ορίζοντα πρόβλεψης. Ως πιθανές συναρτήσεις ενεργοποίησης για την εκπαίδευση του μοντέλου επιλέχθηκαν τρεις από τις πιο ευρέα χρησιμοποιούμενες συναρτήσεις: η  $ReLU(x)$  (rectified linear unit), η  $\tanh(x)$  (υπερβολική εφαπτομένη) καθώς και η  $\text{sigmoid}(x)$  (σιγμοειδής).



Σχήμα 8.1

Προτού το μοντέλο αποκτήσει την δυνατότητα παραγωγής σημειακών προβλέψεων έπρεπε να καθοριστούν οι υπερπαραμέτροι (hyperparameters) του μοντέλου. Ο όρος υπερπαραμέτροι αναφέρεται σε κάποιες παραμέτρους του προβλήματος οι οποίες χρησιμοποιούνται για την προσαρμογή του μοντέλου στο εκάστοτε πρόβλημα που καλείται να αντιμετωπίσει. Εφόσον καθοριστούν, οι υπερπαραμέτροι του μοντέλου δεν μεταβάλλονται κατά την διαδικασία της εκπαίδευσης του. Στα πλαίσια του παρόντος σημειακού μοντέλου οι υπερπαραμέτροι που έπρεπε να καθοριστούν ήταν, η συνάρτηση ενεργοποίησης και ο αριθμός των κόμβων κρυφού επιπέδου που θα χρησιμοποιηθούν στην εκπαίδευση, ώστε να ελαχιστοποιηθεί το σφάλμα πρόβλεψης.

Για τον σκοπό αυτό κατασκευάστηκαν τρία μοντέλα, το κάθε ένα από τα οποία χρησιμοποιεί διαφορετική συνάρτηση ενεργοποίησης. Στην συνέχεια τα μοντέλα αυτά κλήθηκαν να παράγουν προβλέψεις, το καθένα ξεχωριστά, για ένα εύρος αριθμού κόμβων το οποίο ανήκε στο διάστημα [1,400]. Η διαδικασία αυτή είναι γνωστή ως Grid Search, και στην ουσία πρόκειται για την καταγραφή όλων των δυνατών συνδυασμών παραμέτρων ώστε να εξετάσουμε ποιος συνδυασμός παράγει τις ακριβέστερες προβλέψεις. Για την εκπαίδευση των μοντέλων έγινε χρήση των πινάκων  $\mathbf{X}_{train}_{8485 \times 4}$  και  $\mathbf{Y}_{train}_{8485 \times 1}$  ενώ για την αξιολόγησή τους, των πινάκων  $\mathbf{X}_{test}_{300 \times 4}$  και  $\mathbf{Y}_{test}_{300 \times 1}$ . Επίσης για την αξιολόγηση της ακρίβεια πρόβλεψης του κάθε μοντέλου χρησιμοποιήσαμε τα μετρητικά σφάλματος MAE και RMSE τα οποία αναλύθηκαν στην ενότητα 5.4. Παρακάτω παρουσιάζονται αναλυτικά οι συναρτήσεις ενεργοποίησης που χρησιμοποιήθηκαν και τα αποτελέσματα του Grid Search.

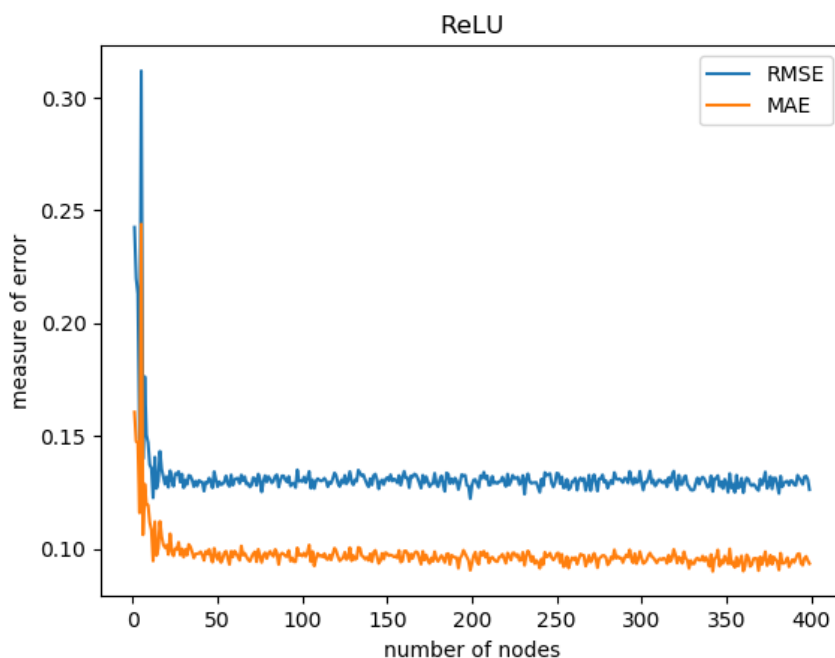
### **ReLU(x):**

Η ReLU (rectified linear unit) αποτελεί μια από τις πιο διαδεδομένες συναρτήσεις σε αρκετούς τύπους νευρωνικών δικτύων. Μαθηματικά περιγράφεται από την σχέση:

$$g(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases}$$



και η γραφική της παράσταση αποτελείται από δύο γραμμικές συναρτήσεις. Παρατηρούμε πως η  $\text{ReLU}(x)$  έχει ως έξοδο την τιμή της εισόδου για τιμές μεγαλύτερες του μηδενός και μηδενική έξοδο για τιμές εισόδου μικρότερες του μηδενός. Στο σχήμα 8.2 παρουσιάζονται οι τιμές των MAE και RMSE που προέκυψαν αναλογικά με το αριθμό των νευρώνων.



Σχήμα 8.2

Παρατηρώντας τα σχηματικά δεδομένα βλέπουμε πως η περιοχή στην οποία το μοντέλο έχει πάνω από περίπου 40 κόμβους κρυφού επιπέδου (νευρώνες) παρουσιάζει ιδιαίτερο ενδιαφέρον καθώς οι τιμές των MAE και RMSE παρουσιάζουν ελάχιστες αυξομειώσεις και η αύξηση του αριθμού των κόμβων δεν οδηγεί σε περαιτέρω σημαντική μείωση τους. Ενδεικτικά στους πίνακες 8.1 και 8.2 παρουσιάζονται τα στιγμιότυπα των δεδομένων για τιμές κόμβων από 41 ως 70 τα οποία αποτελούν μέρος του συνόλου των δεδομένων που χρησιμοποιήθηκαν για την σχεδίαση του σχήματος 8.2.

Αριθμός Νευρώνων	MAE	Αριθμός Νευρώνων	MAE	Αριθμός Νευρώνων	MAE
41	0.097292	51	0.098293	61	0.097936
42	0.094833	52	0.093925	62	0.096328
43	0.09881	53	0.095569	63	0.094878
44	0.097742	54	0.098161	64	0.101192
45	0.099699	55	0.098879	65	0.097147
46	0.096587	56	0.096079	66	0.098015
47	0.094052	57	0.093022	67	0.09648
48	0.100209	58	0.098887	68	0.095159
49	0.096983	59	0.096352	69	0.094408
50	0.095214	60	0.098961	70	0.096275

*Πίνακας 8.1*

Αριθμός Νευρώνων	RMSE	Αριθμός Νευρώνων	RMSE	Αριθμός Νευρώνων	RMSE
41	0.129453	51	0.129753	61	0.13116
42	0.125548	52	0.128409	62	0.13121
43	0.129528	53	0.12871	63	0.128967
44	0.129076	54	0.129832	64	0.132716
45	0.131333	55	0.132332	65	0.130157
46	0.129708	56	0.128817	66	0.131971
47	0.126964	57	0.127656	67	0.128617
48	0.134177	58	0.132728	68	0.129141
49	0.130606	59	0.128148	69	0.127426
50	0.127505	60	0.130568	70	0.12813

*Πίνακας 8.2*


Τα αριθμητικά δεδομένα βοηθούν στην καλύτερη κατανόηση του σχήματος 8.1. Μελετώντας τα παρατηρούμε πως το μοντέλο με την  $\text{ReLU}(x)$  ως συνάρτηση ενεργοποίησης παρουσιάζει ελάχιστο MAE για 57 κόμβους με τιμή  $\text{MAE}=0.093022$  και ελάχιστο RMSE για 42 κόμβους με τιμή  $\text{RMSE}=0.125548$ . Επίσης παρατηρούμε, πως στα παραπάνω δεδομένα οι τιμές για το MAE ανήκουν στο διάστημα  $[0.093022, 0.101192]$  και του RMSE στο  $[0.125548, 0.134177]$ . Επομένως, ο βέλτιστος αριθμός κόμβων είναι 57 καθώς το MAE ελαχιστοποιείται και το RMSE λαμβάνει τιμή η οποία είναι κοντά στο κάτω όριο του διαστήματος.

Στο σημείο αυτό θα πρέπει να σημειώσουμε πως κατά την επανάληψη της διαδικασίας της πρόβλεψης με ακριβώς τα ίδια δεδομένα εκπαίδευσης και αξιολόγησης παρουσιάστηκαν ελαφρώς διαφορετικά αποτελέσματα για το MAE και το RMSE αναλογικά με τους κόμβους. Παρόλα αυτά όμως το MAE και το RMSE ανήκαν προσεγγιστικά στα ίδια διαστήματα. Επομένως, ο βέλτιστος αριθμός κόμβων καθορίστηκε σε διαφορετική τιμή. Η τυχαιότητα αυτή είναι αναμενόμενη και έγκειται στην αρχιτεκτονική των ELM και ο πιο συγκεκριμένα στην τυχαία ανάθεση τιμών στα βάρη εισόδου  $w_i$  και biases  $b_i$  κατά την διαδικασία της εκπαίδευσης. Ορισμένες τεχνικές για την ελαχιστοποίηση της επίδρασης της τυχαιότητας στην επιλογή των υπέρπαραμέτρων του μοντέλου αναπτύσσονται στην επόμενη ενότητα του κεφαλαίου.

### Sigmoid(x)

Η συνάρτηση  $\text{sigmoid}(x)$  (σιγμοειδής) ήταν μια από τις πρώτες συναρτήσεις που χρησιμοποιήθηκαν στην εκπαίδευση των νευρωνικών δικτύων. Μαθηματικά περιγράφεται από την παρακάτω σχέση και η γραφική της παράσταση παρουσιάζεται στο σχήμα 8.3.

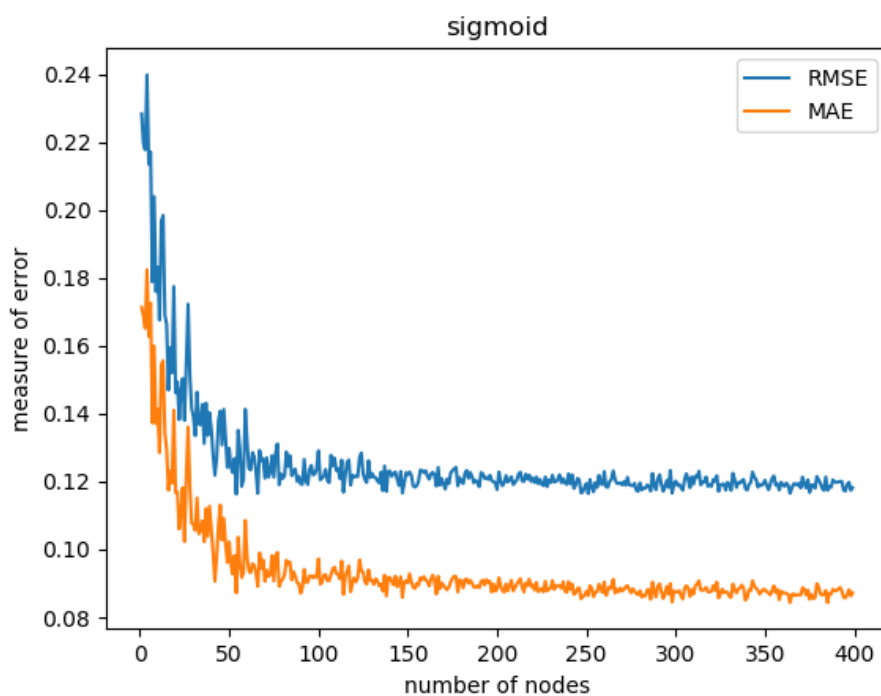
$$g(x) = \frac{1}{1 + e^{-x}}$$



Σχήμα 8.3

Επαναλαμβάνοντας την ίδια διαδικασία με προηγουμένως λαμβάνουμε τις τιμές των MAE και RMSE για τους διαφορετικούς αριθμούς νευρώνων οι οποίοι παρουσιάζονται στο σχήμα 8.4.

Σύμφωνα με το σχήμα, μετά τους περίπου 130 κόμβους οι τιμές των μετρητικών αρχίζουν να σταθεροποιούνται και πάλι σε ένα συγκεκριμένο εύρος τιμών και η αύξηση του αριθμού των κόμβων πέραν του αριθμού αυτού δεν βελτιώνει αισθητά την ακρίβεια των προβλέψεων. Παρατηρούμε πως απαιτείται αρκετά μεγαλύτερος αριθμός κόμβων από ότι στην προηγούμενη περίπτωση. Για την καλύτερη κατανόηση των αποτελεσμάτων παραθέτουμε και εδώ 30 στιγμιότυπα των δεδομένων, στους πίνακες 8.3 και 8.4, από τα οποία προέκυψε το σχήμα 8.3. Τα δεδομένα αυτά αφορούν τις τιμές των MAE και RMSE που λάβαμε χρησιμοποιώντας από 131 ως 160 κόμβους ώστε να εξετάσουμε την περιοχή ενδιαφέροντος του σχήματος στη οποία οι δείκτες σταθεροποιούνται.



Σχήμα 8.4

Αριθμός Νευρώνων	MAE	Αριθμός Νευρώνων	MAE	Αριθμός Νευρώνων	MAE
131	0.089716	141	0.090525	151	0.092877
132	0.091372	142	0.089598	152	0.090502
133	0.090795	143	0.09216	153	0.08889
134	0.08928	144	0.089039	154	0.08852
135	0.089796	145	0.090226	155	0.090013
136	0.087755	146	0.091983	156	0.089506
137	0.09245	147	0.085963	157	0.091741
138	0.086291	148	0.090404	158	0.09108
139	0.091697	149	0.090828	159	0.091999
140	0.09182	150	0.090135	160	0.09118

Πίνακας 8.3

Αριθμός Νευρώνων	RMSE	Αριθμός Νευρώνων	RMSE	Αριθμός Νευρώνων	RMSE
131	0.121357	141	0.121544	151	0.122823
132	0.121159	142	0.122396	152	0.121877
133	0.120232	143	0.122811	153	0.118741
134	0.119566	144	0.120926	154	0.118386
135	0.122777	145	0.118863	155	0.118766
136	0.117359	146	0.122976	156	0.120099
137	0.124594	147	0.116659	157	0.123418
138	0.117098	148	0.119475	158	0.123278
139	0.123015	149	0.122612	159	0.122616
140	0.123075	150	0.122006	160	0.123185

Πίνακας 8.4


Εξετάζοντας τα αποτελέσματα παρατηρούμε πως το μοντέλο το οποίο χρησιμοποιεί την sigmoid ως συνάρτηση ενεργοποίησης με 147 κόμβους παρουσιάζει MAE=0.085963 και RMSE=0.116659. Τα αποτελέσματα αυτά είναι σημαντικά καλύτερα από τα αποτελέσματα που παρήγαγε το αντίστοιχο μοντέλο με ReLU(x). Επίσης όμως θα πρέπει να σημειώσουμε πως και πάλι οι τιμές παρουσιάζουν τυχαιότητα λόγω της τυχάιας ανάθεσης βαρών. Επομένως και σε αυτή την περίπτωση το 147 αποτελεί προσεγγιστικό αριθμό κόμβων καθώς μεταβάλλεται λόγω της τυχαιότητας το μοντέλου.

### **tanh(x)**

Η τελευταία συνάρτηση ενεργοποίησης που χρησιμοποιήθηκε για την παραγωγή ενός μοντέλου ντετερμινιστικής πρόβλεψη είναι η  $\tanh(x)$  (υπερβολική εφραπτομένη) η οποία περιγράφεται από τον μαθηματικό τύπο:


$$\tanh(x) = g(x) = \frac{e^{2x} - 1}{e^{2x} + 1}$$

και η γραφική της παράσταση παρουσιάζεται στο σχήμα 8.5. Συγκρίνοντας τις γραφικές παραστάσεις των συναρτήσεων  $\tanh(x)$  και  $\text{sigmoid}(x)$  παρατηρούμε πως έχουν σχεδόν την ίδια μορφή. Η κύρια διαφοροποίηση τους έγκειται στην δυνατότητα της  $\tanh(x)$  αν παράγει αρνητικές τιμές εν αντιθέσει με την  $\text{sigmoid}(x)$ , τα αποτελέσματα της οποίας ανήκουν στο διάστημα (0,1).



Σχήμα 8.5

Στο σχήμα 8.6 παρουσιάζονται τα αποτελέσματα του μοντέλου το οποίο χρησιμοποιεί την  $\tanh(x)$  ως συνάρτηση ενεργοποίησης.



Σχήμα 8.6

Παρατηρούμε πως το μοντέλο παρουσιάζει χειρότερη επίδοση από τα προηγούμενα με πολύ μεγάλες αυξομειώσεις στις τιμές των MAE και RMSE για τις διαφορετικές τιμές του αριθμού των κόμβων. Αν και παρατηρείται πτωτική τάση των δεικτών, το μοντέλο με συνάρτηση ενεργοποίησης  $\tanh(x)$  έχει σημαντικά χειρότερες προβλέψεις από τα δυο προηγούμενα μοντέλα.

Συνοψίζοντας, τα αποτελέσματα που λάβαμε μας οδήγησαν στην απόρριψη της  $\tanh(x)$  ως συνάρτηση ενεργοποίησης και κληθήκαμε να επιλέξουμε ανάμεσα σε δυο ζεύγη υπερπαραμέτρων για το μοντέλο. Το πρώτο θα αποτελείται από την συνάρτηση ενεργοποίησης  $\text{ReLU}(x)$  και αριθμό κόμβων κοντά στους 50 ενώ το δεύτερο από την συνάρτηση ενεργοποίησης  $\text{sigmoid}(x)$  και αριθμό κόμβων κοντά στο 150. Το πρώτο μοντέλο έχει ικανοποιητική ικανότητα πρόβλεψης με μικρό αριθμό κόμβων ενώ το δεύτερο παρουσιάζει καλύτερη ακρίβεια προβλέψεων από το πρώτο, με σημαντικά μεγαλύτερο αριθμό κόμβων. Διαισθητικά θα επιλέγαμε το δεύτερο μοντέλο με την συνάρτηση  $\text{sigmoid}(x)$  και αριθμό κόμβων προσεγγιστικά στο 150. Θα πρέπει εδώ να σημειώσουμε πως ο τριπλασιασμός των κόμβων αυξάνει τον απαιτούμενο χρόνο εκπαίδευσης για το μοντέλο. Δεδομένης της ύπαρξης ενός μικρού βαθμού τυχαιότητας στα αποτελέσματα, δεν μπορούμε να αποφανθούμε αν το δεύτερο μοντέλο παράγει συστηματικά καλύτερα αποτελέσματα ώστε να θυσιάσουμε την ταχύτητα εκπαίδευσης. Για την καλύτερη αξιολόγηση των προβλέψεων και την


ελαχιστοποίηση της τυχαιότητας λόγω της τυχαίας ανάθεσης βαρών και biases κατά την εκπαίδευση των αποτελεσμάτων χρησιμοποιήσαμε την μέθοδο Cross-Validation για την υπερπαραμετροποίηση του μοντέλου.

### 8.3: Cross-Validation Ντετερμινιστικών Μοντέλων ELM

Το Cross-Validation (CV) αποτελεί μια στατιστική μέθοδο η οποία χρησιμοποιείται ευρέως στον τομέα των νευρωνικών δικτύων για την επιλογή των υπερπαραμέτρων των μοντέλων. Η βασική ιδέα του Cross-Validation βασίζεται στον περαιτέρω διαχωρισμό των δεδομένων εκπαίδευσης σε υποσύνολα δεδομένων εκπαίδευσης και αξιολόγησης με σκοπό την καλύτερη εκτίμηση της ικανότητας πρόβλεψης.

#### 8.3.1: K-Fold Cross-Validation

Για την επιλογή των υπερπαραμέτρων του μοντέλου ELM που αναπτύχθηκε στα πλαίσια της παρούσας διπλωματικής εργασίας χρησιμοποιήσαμε K-Fold Cross-Validation. Σύμφωνα με αυτήν την μέθοδο το σύνολο των διαθέσιμων δεδομένων διαχωρίζεται σε K υποσύνολα από τα οποία K-1 υποσύνολα χρησιμοποιούνται για την εκπαίδευση του μοντέλου και το εναπομείναν σύνολο για την αξιολόγηση του. Η διαδικασία επαναλαμβάνεται K φορές, έτσι ώστε κάθε ένα από τα K υποσύνολα να χρησιμοποιηθεί ακριβώς μια φορά για την αξιολόγηση του μοντέλου (σχήμα 8.7). Στην συνέχεια εξάγουμε τον μέσο όρο των δεικτών αξιολόγησης που προέκυψαν σε κάθε βήμα για την τελική επιλογή των υπερπαραμέτρων.



Σχήμα 8.7

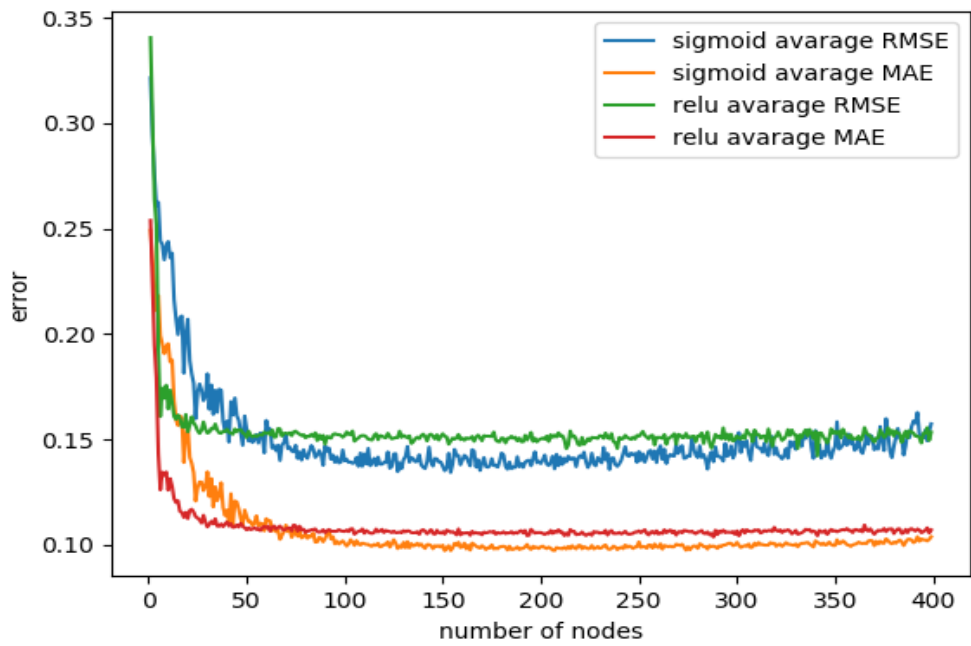


### 8.3.2: Καθορισμός Υπερπαραμέτρων με 4-Fold Cross-Validation

Για την επιλογή των υπερπαραμέτρων των μοντέλων επιλέχθηκε 4-Fold Cross-Validation και αφού έγινε ο διαχωρισμός των δεδομένων σε 4 υποσύνολα λάβαμε τα παρακάτω αποτελέσματα για τις μέσες τιμές των MAE και RMSE ως προς τον αριθμό των κόμβων τα οποία έχουν αναπαρασταθεί σε ένα κοινό διάγραμμα (σχήμα 8.8).

Παρατηρώντας τα δεδομένα βλέπουμε πως όταν ο αριθμός των κόμβων ξεπεράσει τους περίπου 70 κόμβους το μοντέλο που χρησιμοποιεί την  $\text{sigmoid}(x)$  παράγει σταθερά ακριβέστερες προβλέψεις καθώς τα αντίστοιχα MAE και RMSE είναι μικρότερα από αυτά του μοντέλου που χρησιμοποιεί την  $\text{ReLU}(x)$ . Επίσης διαφαίνεται πως η χρήση 4-Fold Cross-Validation όντως μείωσε την τυχαιότητα του μοντέλου καθώς παρατηρούνται μικρότερες αυξομειώσεις των δεικτών και για τα δυο μοντέλα.

Για να αποφανθούμε για το αν η μείωση του συνολικού σφάλματος, χρησιμοποιώντας την  $\text{sigmoid}(x)$  με μεγαλύτερο αριθμό κόμβων, είναι αρκετά σημαντική ώστε να αυξήσουμε την ταχύτητα εκπαίδευσης, παρουσιάζονται στους παρακάτω πίνακες οι τιμές των  $\overline{MAE}$  και  $\overline{RMSE}$  για τα 2 μοντέλα, από τις οποίες προέκυψε το παραπάνω διάγραμμα. Ενδεικτικά, συμπεριλαμβάνουμε τα αποτελέσματα για την  $\text{sigmoid}(x)$  για πλήθος κόμβων εντός του διαστήματος [131, 180](πίνακες 8.5 και 8.6) και τα αποτελέσματα για την  $\text{ReLU}(x)$  για πλήθος κόμβων εντός του διαστήματος [41,80](πίνακες 8.7 και 8.8). Οι περιοχές αυτές αποτελούν και τις αντίστοιχες περιοχές ενδιαφέροντος, για τα δυο μοντέλα, στις οποίες τα  $\overline{MAE}$  και  $\overline{RMSE}$  σταθεροποιούνται κοντά στις μικρότερες τιμές τους.



Σχήμα 8.8

Αποτελέσματα sigmoid(x):

Αριθμός κόμβων	$\overline{MAE}$	Αριθμός κόμβων	$\overline{MAE}$	Αριθμός κόμβων	$\overline{MAE}$	Αριθμός κόμβων	$\overline{MAE}$
131	0.10335	141	0.103734	151	0.103516	161	0.102795
132	0.10468	142	0.104035	152	0.102559	162	0.103713
133	0.103125	143	0.104023	153	0.103	163	0.102234
134	0.104733	144	0.103004	154	0.101525	164	0.102869
135	0.103391	145	0.103041	155	0.103612	165	0.103612
136	0.104067	146	0.103576	156	0.102896	166	0.101985
137	0.103094	147	0.103205	157	0.103213	167	0.102259
138	0.10407	148	0.10247	158	0.103225	168	0.102594
139	0.104743	149	0.101608	159	0.103784	169	0.102918
140	0.103163	150	0.103203	160	0.103933	170	0.103114

Πίνακας 8.5

Αριθμός κόμβων	$\overline{RMSE}$	Αριθμός κόμβων	$\overline{RMSE}$	Αριθμός κόμβων	$RMSE$	Αριθμός κόμβων	$\overline{RMSE}$
131	0.144158	141	0.148523	151	0.144416	161	0.143336
132	0.146342	142	0.145248	152	0.143957	162	0.142991
133	0.14328	143	0.147698	153	0.145031	163	0.1436
134	0.14714	144	0.145888	154	0.14118	164	0.147952
135	0.145824	145	0.148632	155	0.144057	165	0.148922
136	0.145437	146	0.147534	156	0.143483	166	0.142385
137	0.143473	147	0.145721	157	0.1444	167	0.145071
138	0.14661	148	0.145598	158	0.145359	168	0.14597
139	0.147028	149	0.140517	159	0.151169	169	0.144346
140	0.142673	150	0.147864	160	0.14756	170	0.147196

Πίνακας 8.6

Αποτελέσματα  $ReLU(x)$ :

Αριθμός κόμβων	$\overline{MAE}$	Αριθμός κόμβων	$\overline{MAE}$	Αριθμός κόμβων	$\overline{MAE}$	Αριθμός κόμβων	$\overline{MAE}$
41	0.110933	51	0.110869	61	0.110996	71	0.109232
42	0.110514	52	0.109928	62	0.110122	72	0.10912
43	0.110747	53	0.109922	63	0.110397	73	0.109395
44	0.110322	54	0.110257	64	0.110445	74	0.108878
45	0.110098	55	0.108811	65	0.110781	75	0.109686
46	0.109488	56	0.110549	66	0.108992	76	0.110933
47	0.110849	57	0.110169	67	0.108875	77	0.11033
48	0.109284	58	0.110977	68	0.109776	78	0.109738
49	0.111008	59	0.110667	69	0.109679	79	0.10857
50	0.109045	60	0.109479	70	0.109873	80	0.109511


Πίνακας 8.7

Αριθμός κόμβων	$\overline{RMSE}$	Αριθμός κόμβων	$\overline{RMSE}$	Αριθμός κόμβων	$\overline{RMSE}$	Αριθμός κόμβων	$\overline{RMSE}$
41	0.153873	51	0.155381	61	0.155184	71	0.151617
42	0.152715	52	0.153561	62	0.153606	72	0.150564
43	0.154795	53	0.154196	63	0.154383	73	0.152502
44	0.155034	54	0.154423	64	0.153358	74	0.153216
45	0.153184	55	0.15299	65	0.155273	75	0.153607
46	0.153673	56	0.154141	66	0.152413	76	0.153513
47	0.154627	57	0.154082	67	0.152553	77	0.153472
48	0.151664	58	0.154668	68	0.153658	78	0.15365
49	0.155305	59	0.154136	69	0.152604	79	0.152125
50	0.153732	60	0.15299	70	0.153596	80	0.151899

Πίνακας 8.8

Για το μοντέλο με την  $\text{sigmoid}(x)$ , ο βέλτιστος αριθμός κόμβων κρίθηκε στους 149 καθώς οι δείκτες σφάλματος λάβανε τις τιμές  $\overline{MAE} = 0.101608$  και  $\overline{RMSE} = 0.140517$ . Οι τιμές αυτές δεν αποτελούν τις ελάχιστες που παρουσιάζονται συνολικά στα αποτελέσματα, καθώς η αύξηση του αριθμού των κόμβων παρουσιάζει μείωση των τιμών. Η μείωση όμως αυτή είναι αρκετά μικρή ώστε η βελτίωση της ακρίβειας των προβλέψεων να θεωρείται αμελητέα. Επομένως η αύξηση των κόμβων θα αύξανε σε αισθητό βαθμό την πολυπλοκότητα των υπολογισμών και κατά συνέπεια τον χρόνο εκπαίδευσης χωρίς ουσιαστικό αντίκτυπο στην ακρίβεια των προβλέψεων. Για τον λόγο αυτό, καταλήξαμε στην επιλογή 149 κόμβων κρυφού επιπέδου.

Συγκρίνοντας τις τιμές  $\overline{MAE} = 0.101608$  και  $\overline{RMSE} = 0.140517$  με τα αντίστοιχα αποτελέσματα της  $\text{ReLU}(x)$  βλέπουμε πως υπάρχει σημαντική διαφορά στην ακρίβεια της πρόβλεψης ανεξαρτήτως του αριθμού των κόμβων που θα επιλέξουμε για αυτή. Για τον λόγο αυτό, καθορίσαμε πως το βέλτιστο μοντέλο ELM (συνυπολογίζοντας την ακρίβεια και τον χρόνο εκπαίδευσης) για την παραγωγή σημειακών προβλέψεων αποτελείται από 149 κόμβους και χρησιμοποιεί την  $\text{sigmoid}(x)$  ως συνάρτηση ενεργοποίησης. Το μοντέλο υλοποιήθηκε και εκπαιδεύτηκε με τα αρχικά δεδομένα εκπαίδευσης ( $\mathbf{X}_{train_{8485 \times 4}}$  και  $\mathbf{Y}_{train_{8485 \times 1}}$ ). Στην συνέχεια κλήθηκε να προβλέψει την αναμενόμενη παραγόμενη ισχύ για τις τελευταίες 300 προβλέψεις ανέμου ( $\mathbf{X}_{test_{300 \times 4}}$ ). Η χρονοσειρά των προβλέψεων που παρήγαγε το μοντέλο και των πραγματικών τιμών ( $\mathbf{Y}_{test_{300 \times 1}}$ ) παρουσιάζεται το σχήμα 8.9. Τα μετρητικά σφάλματος λάβανε τις τιμές  $MAE = 0.086164$  και  $RMSE = 0.118427$ .



Σχήμα 8.9

Στο σημείο αυτό αξίζει να αναφέρουμε πως, για το παρόν μοντέλο (Sigmoid(x) και 149 κόμβους), χρησιμοποιώντας την μέθοδο 4-Way Cross-Validation λάβαμε  $\overline{MAE} = 0.101608$  και  $\overline{RMSE} = 0.140517$  ενώ χωρίς αυτή προβλέποντας για τις τελευταίες 300 τιμές αιολικής ισχύος, λάβαμε  $MAE = 0.086164$  και  $RMSE = 0.118427$ . Παρατηρούμε λοιπόν, μια φαινομενική αύξηση του σφάλματος. Στην πραγματικότητα, η τιμές που λάβαμε από το Cross-Validation είναι πιο αντιπροσωπευτικές για την ικανότητα πρόβλεψης του μοντέλου. Αυτό συμβαίνει διότι με τον επαναλαμβανόμενο διαχωρισμό των δεδομένων, προβλέπουμε 4 φορές και κάθε φορά έχουμε διαφορετικά δεδομένα αξιολόγησης και εκπαίδευσης. Παίρνοντας τον μέσο όρο των τεσσάρων  $MAE$  και  $RMSE$  (ένα για κάθε διαφορετικό διαχωρισμό) το μοντέλο αξιολογείται σε μεγαλύτερο εύρος δεδομένων. Με τον τρόπο αυτό οι δείκτες σφάλματος απαλλάσσονται από τυχόν μεροληψία του μοντέλου προς ένα συγκεκριμένο σύνολο δεδομένων αξιολόγησης. Ένα χαρακτηριστικό παράδειγμα αποτελεί η εποχικότητα. Αν το μοντέλο έχει καλύτερη ακρίβεια πρόβλεψης το φθινόπωρο έναντι των άλλων εποχών και αξιολογηθεί με δεδομένα που ανήκουν σε αυτό, η επίδοση αυτή δεν είναι αντιπροσωπευτική της πραγματικής επίδοσης του.

Η μεροληψία ενός μοντέλου πρόβλεψης μπορεί να οφείλεται σε μια πληθώρα παραγόντων. Αρχικά σημαντικό παράγοντα αποτελεί το σφάλμα πρόβλεψης στα δεδομένα αριθμητικών προβλέψεων καιρού. Πιο συγκεκριμένα, όσο ακριβέστερες είναι οι προβλέψεις ανέμου τόσο καλύτερη δυνατότητα εκτίμησης της παραγόμενης αιολικής ισχύος έχει το μοντέλο. Επομένως

αν στο διάστημα των τελευταίων 300 ωρών τα σφάλματα αιολικής πρόβλεψης ήταν μικρότερα, σε σχέση τα υπόλοιπα δεδομένα, θα παρείχε και ακριβέστερες προβλέψεις.

Στην συνέχεια, επίσης σημαντικό παράγοντα αποτελεί και η ποιότητα των διαθέσιμων δεδομένων. Αν ένα μοντέλο κληθεί να προβλέψει, για τιμές ταχύτητας ανέμου οι οποίες είναι κυρίαρχες στα δεδομένα εκπαίδευσης, θα παράγει και καλύτερα αποτελέσματα. Επομένως αν στο διάστημα των τελευταίων 300 ωρών είχαμε πιο “συνηθισμένα” σετ δεδομένων χωρίς πολλές ακραίες τιμές το μοντέλο θα είχε και καλύτερη δυνατότητα πρόβλεψης.

Οι παραπάνω παρατηρήσεις καταδεικνύουν ακόμα ένα πλεονέκτημα της αξιολόγησης των αποτελεσμάτων μέσω Cross-Validation. Εκτός από την ελαχιστοποίηση της τυχαιότητας του μοντέλου, το μοντέλο αξιολογήθηκε σε όλα τα ακραία σετ τιμών (προβλέψεις ανέμου- παραγόμενη ισχύς) και όλο το εύρος σφαλμάτων αριθμητικών προβλέψεων καιρού που είχαμε διαθέσιμα στα δεδομένα που χρησιμοποιήθηκαν, αποκτώντας έτσι μια καλύτερη εκτίμηση των πραγματικών δυνατοτήτων του μοντέλου.

## **8.4: Επεξεργασία δεδομένων**

Εφόσον αναπτύχθηκε το μοντέλο ELM σημειακής πρόβλεψης έγινε μια προσπάθεια επεξεργασίας των δεδομένων με σκοπό την βελτίωση της ακρίβειας των προβλέψεων. Οι δυο επιλογές που εξετάστηκαν αφορούν τις προβλέψεις αέρα και είναι αρχικά η μετατροπή τους από καρτεσιανό σύστημα συντεταγμένων σε πολικό και στην συνέχεια η κανονικοποίηση τους (τα δεδομένα εξόδου δόθηκαν κανονικοποιημένα).

### **8.4.1: Μετατροπή Προβλέψεων σε Πολικό Σύστημα Συντεταγμένων**

Όπως εξετάσαμε στο κεφάλαιο 4 ο κύριος παράγοντας από τον οποίο εξαρτάται η παραγόμενη ισχύς μιας ανεμογεννήτριας είναι η ταχύτητα του ανέμου. Η δυνατότητα των ανεμογεννητριών να περιστρέφονται ώστε η ωφέλιμη επιφάνεια των πτερυγίων να είναι κάθετη στην διεύθυνση του ανέμου μειώνει την επίδραση της κατεύθυνσης στην παραγόμενη ισχύ[46]. Εξ αιτίας αυτού αναμένουμε πως η μετατροπή των προβλέψεων ανέμου σε πολικές συντεταγμένες θα οδηγήσει σε μείωση του σφάλματος πρόβλεψης. Πιο αναλυτικά, αν οι προβλέψεις αποτελούνται από το μέτρο και την γωνία του ανέμου έναντι των καρτεσιανών τιμών, το μοντέλο θα είναι σε θέση να αναγνωρίσει πως το μέτρο είναι η κυρίαρχη μεταβλητή που επηρεάζει την παραγόμενη ισχύ

και να αυξήσει το βάρος της ώστε να έχει μεγαλύτερη συμμετοχή στην παραγωγή της τελικής πρόβλεψης.

Για την αξιολόγηση των αποτελεσμάτων, και σε αυτήν την περίπτωση χρησιμοποιήθηκαν τα μετρητικά σφάλματος MAE και RMSE και η μέθοδος 4-Fold Cross-Validation. Προηγουμένως, όταν τα δεδομένα ήταν σε καρτεσιανές συντεταγμένες βρήκαμε τις τιμές  $\overline{MAE} = 0.101608$  και  $\overline{RMSE} = 0.140517$ . Μετά την μετατροπή σε πολικές συντεταγμένες, οι αντίστοιχες διαμορφώθηκαν ως εξής:  $\overline{MAE} = 0.096689$  και  $\overline{RMSE} = 0.134189$ . Παρατηρούμε πως ο αρχικός ισχυρισμός επιβεβαιώνεται και η ακρίβεια της πρόβλεψης βελτιώνεται καθώς και οι δυο δείκτες μειώνονται.

#### 8.4.2: Κανονικοποίηση Προβλέψεων Ανέμου

Η κανονικοποίηση (normalization) αποτελεί μια πολύ συνηθισμένη μορφή επεξεργασίας των δεδομένων στον τομέα της μηχανικής μάθησης. Σκοπός της διαδικασίας είναι η αναπροσαρμογή των δεδομένων σε διαφορετική κλίμακα έτσι ώστε όλες οι τιμές να ανήκουν στο διάστημα  $[0,1]$ . Η κανονικοποίηση των δεδομένων έχει ως σκοπό την μείωση της διαφοράς τάξης μεγέθους μεταξύ δεδομένων εισόδου και εξόδου. Αυτό συνεπάγεται πως, εφόσον η διαδικασία της εκπαίδευσης βασίζεται στις αριθμητικές πράξεις μεταξύ βαρών και δεδομένων, τυχούσες πολύ μεγάλες ή μικρές τιμές και μεγάλες διαφορές δεν επηρεάζουν σε μεγαλύτερο βαθμό από άλλες παρατηρήσεις το αποτέλεσμα.

Υπάρχουν αρκετές διαφορετικές τεχνικές παραμετροποίησης οι οποίες εφαρμόζονται, όμως για τα δεδομένα εισόδου της παρούσας εργασίας επιλέχθηκε η κανονικοποίηση μεγίστου-ελαχίστου η οποία βασίζεται στον τύπο:

$$x_{new} = \frac{x - x_{max}}{x_{max} - x_{min}}$$

όπου  $x_{new}$  είναι η νέα τιμή και  $x_{max}, x_{min}$  είναι η μέγιστη και ελάχιστη αντίστοιχα τιμή στο σύνολο των παρατηρήσεων. Κάνοντας λοιπόν την παραπάνω διαδικασία λάβαμε τις τιμές  $\overline{MAE} = 0.099534$  και  $\overline{RMSE} = 0.138038$ . Επομένως παρατηρούμε πως υπάρχει μικρή βελτίωση της ακρίβειας πρόβλεψης εφόσον οι δείκτες μειώνονται σε πολύ μικρό βαθμό. Το γεγονός αυτό πιθανότατα οφείλεται στο ότι τα δεδομένα εισόδου περιγράφουν προβλέψεις αέρα, οπότε οι ακραίες τιμές παραμένουν συγκρίσιμες σε τάξη μεγέθους με τα δεδομένα εξόδου τα οποία είναι κανονικοποιημένα.

## 8.5: Μοντέλο Πιθανοτικής Πρόβλεψης

Για να αναπτύξουμε ένα μοντέλο με την δυνατότητα παραγωγής πιθανοτικών προβλέψεων, χρησιμοποιήσαμε την μέθοδο της πρόβλεψης συνόλου (ensemble forecasting) χρησιμοποιώντας αποκλειστικά ένα μοντέλο, το οποίο παράγει ένα πλήθος συνόλου προβλέψεων (ensemble forecast) για την μεταβλητή ενδιαφέροντος, κάθε φορά με διαφοροποιημένα δεδομένα εκπαίδευσης. Το σημειακό μοντέλο που επιλέχθηκε είναι το ELM που κατασκευάσαμε παραπάνω, με συνάρτηση ενεργοποίησης την  $\text{sigmoid}(x)$  και 149 κόμβους κρυφού επιπέδου.

Για να κατασκευάσουμε, από τα αρχικά δεδομένα εκπαίδευσης  $\mathbf{X}_{train}_{8485 \times 4}$  και  $\mathbf{Y}_{train}_{8485 \times 1}$  αντίστοιχα  $B$  διαφοροποιημένα σύνολα δεδομένων εκπαίδευσης χρησιμοποιήσαμε την τεχνική bootstrapping όπως αυτή αναλύθηκε στην ενότητα 7.2. Στην συνέχεια, κατασκευάσαμε  $B$  ντετερμινιστικά μοντέλα BELM (Bootstrap ELM) όπου το καθένα εκπαιδεύτηκε με το αντίστοιχο σύνολο δεδομένο εκπαίδευσης. Αφού ολοκληρώθηκε η διαδικασία της εκπαίδευσης, τα Bootstrapped ELM κλήθηκαν να παράγουν ένα σύνολο  $B$  διαφορετικών προβλέψεων  $\hat{y}_j(x_i)$  όπου  $j=1,2,\dots,B$ , και  $i=1,2,\dots,N$  (με  $N=300$  το πλήθος των παρατηρήσεων πραγματικής αιολικής ισχύος κάθε ώρα) έχοντας ως είσοδο το ίδιο σύνολο δεδομένων ( $\mathbf{X}_{test}_{300 \times 4}$ ). Έπειτα, από το σύνολο προβλέψεων  $\hat{y}_j(x_i)$  αιολικής παραγωγής κατασκευάσαμε τα διαστήματα εμπιστοσύνης σύμφωνα με την θεωρία της ενότητας 7.3. Στην συνέχεια, αξιολογήθηκε σύμφωνα με τις πραγματικές τιμές αιολικής ισχύος ( $\mathbf{X}_{test}_{300 \times 1}$ ).

Για να έχει το πιθανοτικό μοντέλο την δυνατότητα παραγωγής αξιόπιστων διαστημάτων εμπιστοσύνης θα πρέπει να καθορίσουμε τις υπερπαραμέτρους του. Μοναδική υπερπαραμέτρος του μοντέλου αποτελεί το  $B$ , ο αριθμός δηλαδή των Bootstrap ELM που θα κληθούν να παράγουν προβλέψεις επί των  $B$  bootstrapped δεδομένων αξιολόγησης με σκοπό την παραγωγή των διαστημάτων εμπιστοσύνης. Ως προς την αξιολόγηση της αξιοπιστίας του μοντέλου, για τις διαφορετικές τιμές του πλήθους των Bootstrap ELM, έγινε χρήση του δείκτη  $ACE = PICP - PINC$ . Όπως έχει προαναφερθεί το  $PICP$  αναφέρεται στην πιθανότητα κάλυψης του μοντέλου και υπολογίζεται από τον τύπο:

$$PICP = \frac{1}{N} \sum_{i=1}^N c_i \text{ όπου } c_i = \begin{cases} 1, & y(x_i) \in I_K^a \\ 0, & \text{αλλιώς} \end{cases}$$

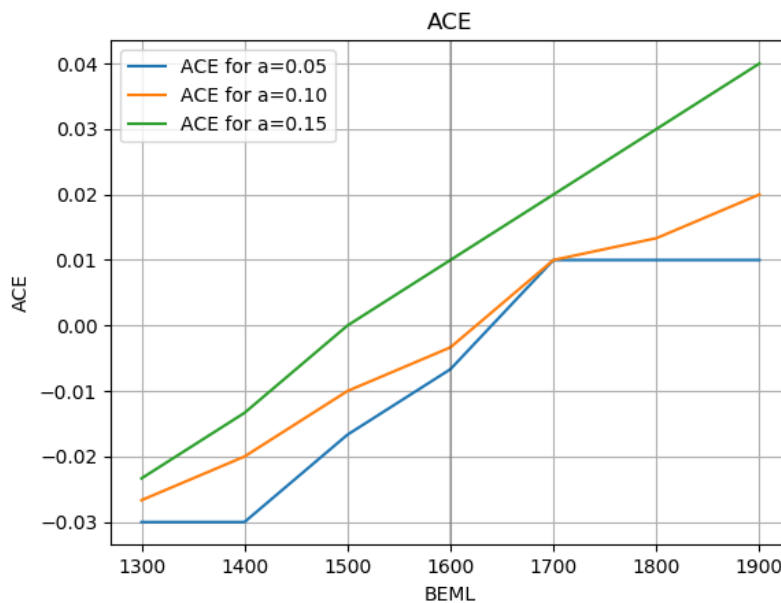
Επομένως, για να είναι αξιόπιστα τα διαστήματα εμπιστοσύνης του μοντέλου θα πρέπει  $ACE \rightarrow 0$ . Δηλαδή θα πρέπει η πραγματική πιθανότητα κάλυψης ( $PICP$ ) που υπολογίζουμε (ανάλογα με το  $B$ ), να προσεγγίζει όσο καλύτερα γίνεται το επιθυμητό επίπεδο εμπιστοσύνης  $PINC = P(x_i \in I_K^a) = 100(1 - a)\%$ .



Για τον καθορισμό του αριθμού των Bootstrap ELM που παράγουν τα πιο αξιόπιστα διαστήματα εμπιστοσύνης ελέγχθηκαν οι τιμές από  $B = 100$  έως  $B = 1900$  με βήμα 100. Η διαδικασία επαναλήφθηκε για 3 διαφορετικά επίπεδα εμπιστοσύνης  $PINC = P(x_i \in I_K^a) = 100(1 - \alpha)\%$ : 95% ( $\alpha=0,05$ ), 90% ( $\alpha=0,1$ ) και 85% ( $\alpha=0,15$ ).

Για κάθε ένα από τα επίπεδα εμπιστοσύνης καταγράψαμε σε κάθε βήμα την τιμή του  $ACE$  ως προς το πλήθος των Bootstrap ELM. Επίσης καταγράφηκε η τιμή που λαμβάνει ο δείκτης  $Scy^a$  (για την αξιολόγηση του εύρους των διαστημάτων εμπιστοσύνης(Ενότητα 7.5)) και η πιθανότητα κάλυψης  $PICP$  καθώς βοηθούν στην καλύτερη κατανόηση των αποτελεσμάτων. Για την διερεύνηση της επίδρασης του αριθμού των Bootstrap ELM στην διαμόρφωση των παρακάτω παρουσιάζονται οι πίνακες και οι γραφικές παραστάσεις των αποτελεσμάτων που λάβαμε.

Δείκτης ACE:

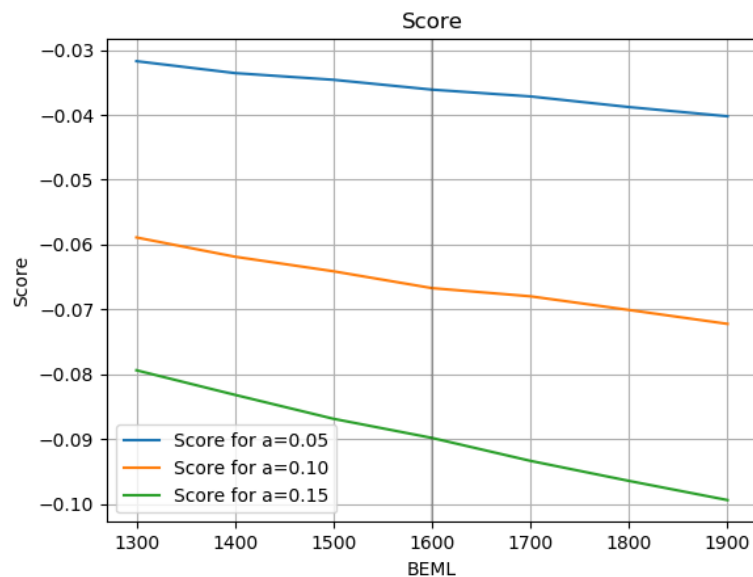


Σχήμα 8.10

$\alpha=0,05$		$\alpha=0,1$		$\alpha=0,15$	
BELM	ACE	BELM	ACE	BELM	ACE
100	-0.48333	100	-0.51	100	-0.51333
200	-0.35	200	-0.37333	200	-0.38333
300	-0.27667	300	-0.30333	300	-0.29667
400	-0.22	400	-0.23333	400	-0.24
500	-0.17667	500	-0.21	500	-0.2
600	-0.14667	600	-0.16	600	-0.15333
700	-0.13	700	-0.13333	700	-0.12667
800	-0.10333	800	-0.10333	800	-0.10333
900	-0.08	900	-0.08333	900	-0.08
1000	-0.06667	1000	-0.07333	1000	-0.06333
1100	-0.06	1100	-0.05667	1100	-0.05
1200	-0.04333	1200	-0.05	1200	-0.03667
1300	-0.03	1300	-0.02667	1300	-0.02333
1400	-0.03	1400	-0.02	1400	-0.01333
1500	-0.01667	1500	-0.01	1500	0
1600	-0.00667	1600	-0.00333	1600	0.01
1700	0.01	1700	0.01	1700	0.02
1800	0.01	1800	0.013333	1800	0.03
1900	0.01	1900	0.02	1900	0.04

Πίνακας 8.9

Δείκτης Score:

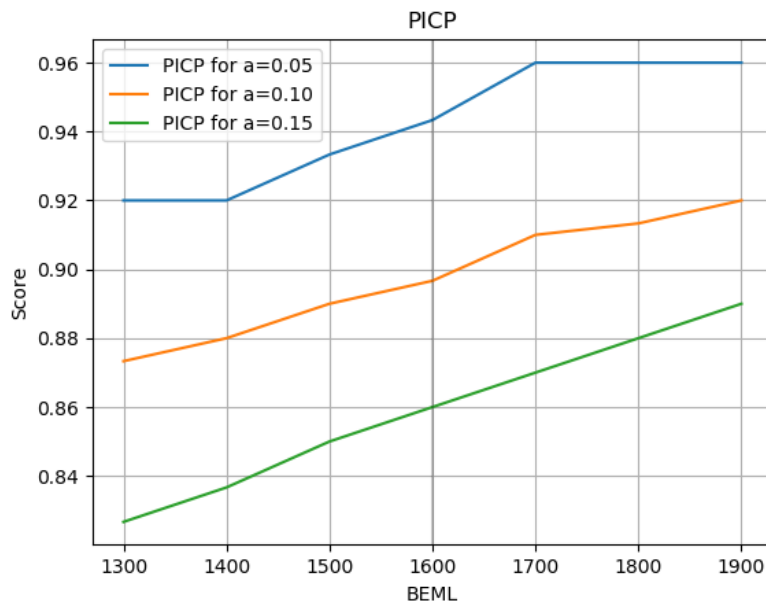


Σχήμα 8.11

$\alpha=0,05$		$\alpha=0,1$		$\alpha=0,15$	
BELM	Score	BELM	Score	BELM	Score
100	0.02605244	100	0.02302840	100	0.01489434
200	0.01389054	200	0.00452024	200	0.00182518
300	0.00348007	300	-0.00724221	300	-0.01512886
400	-0.00421797	400	-0.0155013	400	-0.02335305
500	-0.01045343	500	-0.02351780	500	-0.03408925
600	-0.01452521	600	-0.0304884	600	-0.04115403
700	-0.01895633	700	-0.03638533	700	-0.04846205
800	-0.02242043	800	-0.04232339	800	-0.05669240
900	-0.02523734	900	-0.04558001	900	-0.0613733
1000	-0.02585890	1000	-0.05017508	1000	-0.06607111
1100	-0.02858671	1100	-0.05370775	1100	-0.0717137
1200	-0.02960051	1200	-0.05537455	1200	-0.07638271
1300	-0.0317297	1300	-0.05889233	1300	-0.07935696
1400	-0.03356384	1400	-0.06185847	1400	-0.08314535
1500	-0.03459663	1500	-0.06410401	1500	-0.08683378
1600	-0.0361136	1600	-0.0666991	1600	-0.08978438
1700	-0.03716258	1700	-0.06796271	1700	-0.09331886
1800	-0.03880085	1800	-0.07006473	1800	-0.09640533
1900	-0.04021849	1900	-0.07220869	1900	-0.09936021

Πίνακας 8.10

Πιθανότητα κάλυψης(PICP):



Σχήμα 8.12

$\alpha=0,05$		$\alpha=0,1$		$\alpha=0,15$	
BELM	PICP	BELM	PICP	BELM	PICP
100	0.466667	100	0.39	100	0.336667
200	0.6	200	0.526667	200	0.466667
300	0.673333	300	0.596667	300	0.553333
400	0.73	400	0.666667	400	0.61
500	0.773333	500	0.69	500	0.65
600	0.803333	600	0.74	600	0.696667
700	0.82	700	0.766667	700	0.723333
800	0.846667	800	0.796667	800	0.746667
900	0.87	900	0.816667	900	0.77
1000	0.883333	1000	0.826667	1000	0.786667
1100	0.89	1100	0.843333	1100	0.8
1200	0.906667	1200	0.85	1200	0.813333
1300	0.92	1300	0.873333	1300	0.826667
1400	0.92	1400	0.88	1400	0.836667
1500	0.933333	1500	0.89	1500	0.85
1600	0.943333	1600	0.896667	1600	0.86
1700	0.96	1700	0.91	1700	0.87
1800	0.96	1800	0.913333	1800	0.88
1900	0.96	1900	0.92	1900	0.89

Πίνακας 8.11

Όπως ήταν αναμενόμενο, αυξάνοντας τον αριθμό των bootstrap που κάνουμε επί των αρχικών δεδομένων (και κατά συνέπεια το πλήθος των διαφορετικών προβλέψεων που έχουμε από τα Bootstrap ELM), μεταβάλλεται και ο δείκτης ACE οπότε και η αξιοπιστία του μοντέλου. Αυτό συμβαίνει διότι, αυξάνοντας τον αριθμό των διαθέσιμων διαφορετικών προβλέψεων για το ίδιο γεγονός (πρόβλεψη ισχύος για μια χρονική στιγμή), αυξάνεται η διακύμανση (variance) των προβλέψεων. Κατά συνέπεια, όπως επιβεβαιώνεται και από τα αποτελέσματα του δείκτη Score, παρουσιάζεται και διεύρυνση του εύρους του αντίστοιχου διαστήματος εμπιστοσύνης με αποτέλεσμα να μεγαλώνει η συνολική πιθανότητα κάλυψης (PICP). Όταν ο ACE είναι αρνητικός, συνεπάγεται πως  $PINC > PICP$ , οπότε θα πρέπει να αυξήσουμε τον αριθμό των BELM εως ότου επιτύχουμε  $PINC = PICP$  ( $ACE \cong 0$ ). Αν συνεχίσουμε όμως να τον αυξάνουμε, ενώ έχουμε επιτύχει  $ACE \cong 0$ , η πραγματική πιθανότητα κάλυψης ξεπερνάει το επιθυμητό επίπεδο εμπιστοσύνης και το εύρος των διαστημάτων εμπιστοσύνης δεν είναι το βέλτιστο που μπορεί να παράγει το μοντέλο.


Αξίζει επίσης να επισημάνουμε πως, για τον ίδιο αριθμό BELM, όσο αυξάνεται το επιθυμητό επίπεδο εμπιστοσύνης ο δείκτης  $Sc_y^a$  μειώνεται απεικονίζοντας την διεύρυνση του μέσου εύρους των διαστημάτων εμπιστοσύνης. Επίσης, διαπιστώνουμε πως όταν το πιθανοτικό μοντέλο πρόβλεψης αποτελείται από λιγότερα από 400 ELM, παρουσιάζει  $Sc_y^a \cong 0$ , όμως το μοντέλο έχει πιθανότητα κάλυψης  $PICP < 75\%$  και για τα 3 επίπεδα εμπιστοσύνης. Επομένως,

όπως αναφέραμε στην ενότητα 7.5, διαφαίνεται ο λόγος για τον οποίο, αν και ο δείκτης  $Sc_y^a$  επηρεάζεται θετικά από την αξιοπιστία του μοντέλου, δεν μπορεί να χρησιμοποιηθεί για την αξιολόγηση της. Για τον λόγο αυτό, χρησιμοποιείται συμπληρωματικά για την αξιολόγηση του εύρους των διαστημάτων εφόσον έχει εξασφαλιστεί η αξιοπιστία του μοντέλου.

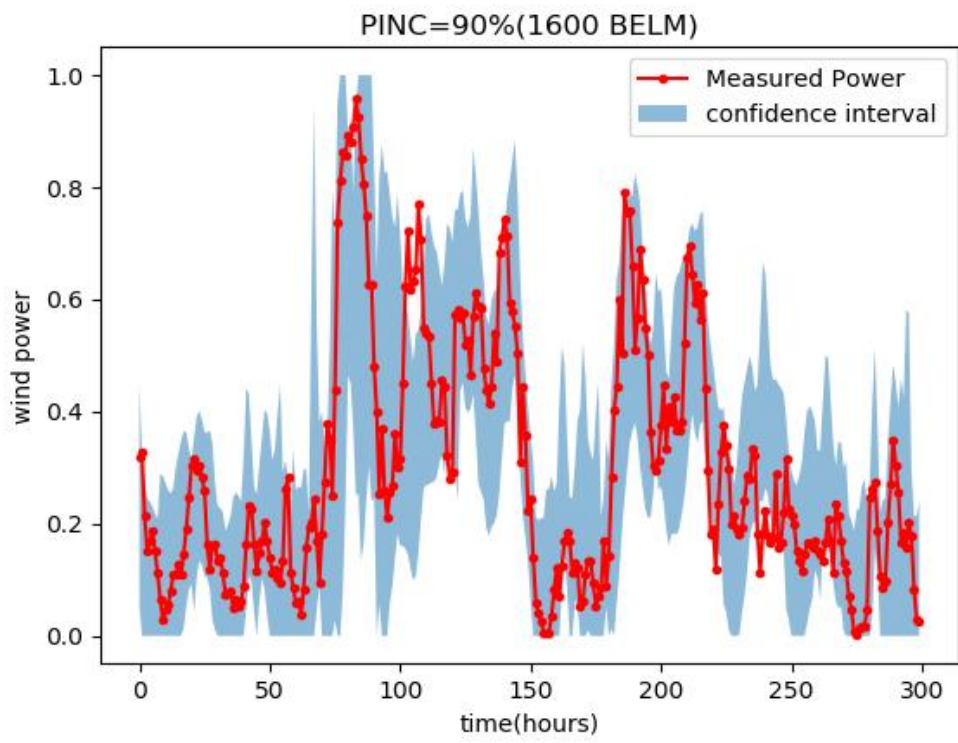
Συνοψίζοντας, παρατηρούμε πως ο βέλτιστος αριθμός BELM για να έχουμε αξιόπιστες πιθανοτικές προβλέψεις για τις τελευταίες 300 παρατηρήσεις (πραγματικές ωριαίες παρατηρήσεις αιολικής ισχύος) των διαθέσιμων δεδομένων είναι:

- 1600 Bootstrap ELM για επίπεδο εμπιστοσύνης 95% με ACE = -0.667% και  $Sc_y^{0,05} = -0.0361136$
- 1600 Bootstrap ELM για επίπεδο εμπιστοσύνης 90% με ACE = -0.333% και  $Sc_y^{0,1} = -0.0666991$
- 1500 Bootstrap ELM για επίπεδο εμπιστοσύνης 85% με ACE = 0% και  $Sc_y^{0,15} = -0.08683378$


Επομένως διαπιστώνουμε πως για να εξασφαλίσουμε τον βέλτιστο βαθμό αξιοπιστίας του μοντέλου πιθανοτικής πρόβλεψης απαιτείται και διαφορετικός αριθμός BELM (1500 BELM για PINC=0.85 και 1600 για PINC=0.90 και PINC=0.95) χρησιμοποιώντας αντίστοιχο αριθμό Bootstrapped δεδομένων  $X_{train}_{8485 \times 4}$  και  $Y_{train}_{8485 \times 1}$  για την εκπαίδευση τους και  $X_{test}_{300 \times 4}$  και  $Y_{test}_{300 \times 1}$  για την αξιολόγηση τους. Τα διαστήματα εμπιστοσύνης που παρήχθησαν για τα αντίστοιχα επίπεδα εμπιστοσύνης (95%, 90%, 85%) παρουσιάζονται στα παρακάτω στα σχήματα 8.13, 8.14 και 8.15 .



Σχήμα 8.13



Σχήμα 8.14



Σχήμα 8.15

Παρατηρούμε, πως εως τώρα, έχουμε κατασκευάσει ένα φαινομενικά αξιόπιστο πιθανοτικό μοντέλο προβλέψεων με τα παραπάνω διαστήματα εμπιστοσύνης. Όμως οι δείκτες αξιοπιστίας ACE, που υπολογίσαμε ως τώρα, αφορούν την αξιοπιστία των μοντέλων να παράγουν προβλέψεις ως προς τα δεδομένα αξιολόγησης  $X\_test_{300 \times 4}$  και  $Y\_test_{300 \times 1}$ . Κατά την ανάπτυξη του ντετερμινιστικού μοντέλου διαπιστώσαμε πως όταν το μοντέλο κλήθηκε να προβλέψει για τα δεδομένα αξιολόγησης  $X\_test_{300 \times 4}$  και  $Y\_test_{300 \times 1}$  παρουσίασε MAE = 0.086164 ενώ κάνοντας 4-Fold Cross-Validation, αξιοποιώντας έτσι όλο το σύνολο των διαθέσιμων δεδομένων για την αξιολόγηση της ακρίβειας των σημειακών προβλέψεων, παρουσίασε  $\overline{MAE} = 0.101608$ . Εφόσον, τα πιθανοτικά μοντέλα χρησιμοποιούν ένα μεγάλο πλήθος ντετερμινιστικών μοντέλων για την παραγωγή των διαστημάτων εμπιστοσύνης, αναμένουμε πως επαληθεύοντας και πάλι τα αποτελέσματά τους με 4-Fold Cross-Validation η αξιοπιστία τους θα μειωθεί, καθώς θα απαλειφθεί η μεροληψία ως προς τα αρχικά δεδομένα αξιολόγησης. Κάνοντας Cross-Validation για τα τρία διαφορετικά επίπεδα εμπιστοσύνης 95%, 90% και 85%, και καταγράφοντας και πάλι τον δείκτη ACE, λάβαμε τα παρακάτω αποτελέσματα.

	$\alpha=0.05$ (1600ELM)	$\alpha=0.10$ (1600ELM)	$\alpha=0.15$ (1500ELM)
ACE(without CV)	-0.667%	-0.333%	0%
ACE(with CV)	-8.468%	-9.148%	-9.51%

Πίνακας 8.12

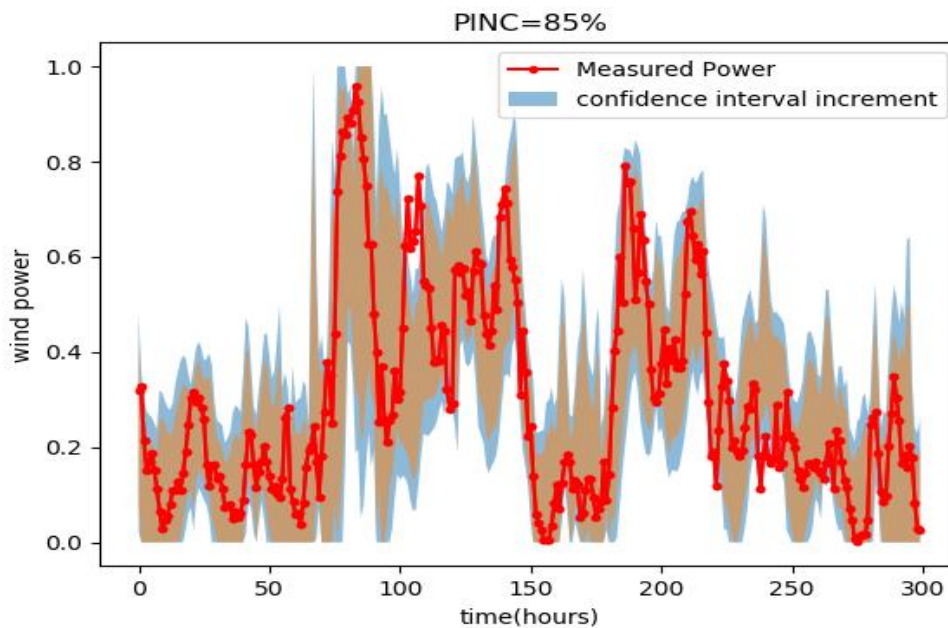
Επομένως το πιθανοτικό μοντέλο πρόβλεψης που αναπτύξαμε ως τώρα, δεν είναι αξιόπιστο όταν εκτεθεί σε μεγαλύτερο εύρος δεδομένων αξιολόγησης. Ιδιαίτερο ενδιαφέρον παρουσιάζει το γεγονός, πως αξιολογώντας τα αποτελέσματα για σύνολο των δεδομένων που διαθέτουμε, το MAE αυξήθηκε κατά  $MAE_{cv} - MAE_{no-cv} = 0.015444$  ενώ οι συντελεστές ACE διαμορφώθηκαν περίπου στο -9%. Σύμφωνα με τον ορισμό του ACE αυτή είναι και η διαφορά του επιθυμητού επιπέδου εμπιστοσύνης από αυτό που είναι ικανό να προσφέρει το μοντέλο ανάλογα με τον αντίστοιχο αριθμό των Bootstrap ELM.

Επομένως, γνωρίζοντας πως το μοντέλο είναι ικανό να παράγει ικανοποιητικές πιθανοτικές προβλέψεις για το σύνολο δεδομένων αξιολόγησης  $X\_test_{300 \times 4}$  και  $Y\_test_{300 \times 1}$ , θα αυξήσουμε τον αριθμό των Bootstrap ELM ώστε να αναπτύξουμε όσο το δυνατόν πιο αξιόπιστα διαστήματα εμπιστοσύνης για το σύνολο των δεδομένων που διαθέτουμε. Πλέον το μοντέλο θα αξιολογηθεί στο σύνολο των δεδομένων που διαθέτουμε, το οποίο αφορά το έτος 2012-2013. Για να υπολογίσουμε πάλι την βέλτιστη τιμή της υπερπαραμέτρου B, αυτή την φορά με 4-Fold Cross-Validation, δοκιμάσαμε διαδοχικά μεγαλύτερους αριθμούς Bootstrap ELM (2600-3800 με βήμα 200) και λάβαμε τα εξής αποτελέσματα του πίνακα 8.13:

$\alpha=0.05$		$\alpha=0.10$		$\alpha=0.15$	
BELM	ACE	BELM	ACE	ACE	ACE
2600	-0.03151	2600	-0.01623	2600	-0.00517
2800	-0.02445	2800	-0.00827	2800	0.006785
3000	-0.01796	3000	-0.00166	3000	0.016576
3200	-0.01307	3200	0.006193	3200	0.025911
3400	-0.0084	3400	0.011999	3400	0.033766
3600	-0.00533	3600	0.016325	3600	0.039686
3800	-0.00089	3800	0.020651	3800	0.045719


Πίνακας 8.13

Βλέπουμε πως το πιθανοτικό μοντέλο για να παράγει αξιόπιστες πιθανοτικές προβλέψεις, για επίπεδο εμπιστοσύνης 95% ( $\alpha=0.05$ ) απαιτούνται 3800 Bootstrapped ELM (ACE= -0.089%), για επίπεδο εμπιστοσύνης 90% ( $\alpha=0.1$ ) απαιτούνται 3000 BELM (ACE= -0.166%) και για επίπεδο εμπιστοσύνης 85% ( $\alpha=0.15$ ) απαιτούνται 2600 BELM (ACE= -0.517%). Οι αντίστοιχοι δείκτες Score που καταγράφηκαν είναι  $Sc_y^{0,05}=-0.04163$   $Sc_y^{0,1}=-0.07654$  και  $Sc_y^{0,15}=-0.0977$ . Αυξάνοντας τον αριθμό των Bootstrap ELM αυξήσαμε, όπως προαναφέραμε, τα διαστήματα εμπιστοσύνης ώστε να εξασφαλίσουμε το επιθυμητό επίπεδο εμπιστοσύνης. Το μοντέλο κλήθηκε να παράγει νέα διαστήματα εμπιστοσύνης επί των αρχικών δεδομένων αξιολόγησης  $X_{test}_{300 \times 4}$  και  $Y_{test}_{300 \times 1}$  με διαφορετικό πλέον αριθμό BELM για να διαπιστώσουμε την μεταβολή των διαστημάτων εμπιστοσύνης. Στα σχήματα 8.16, 8.17 και 8.18 παρουσιάζεται, με μπλε χρώμα, η αύξηση των διαστημάτων εμπιστοσύνης για τα τρία επίπεδα εμπιστοσύνης καθώς αυξάνουμε τον αριθμό των Bootstrap ELM από 1500 σε 2600 για βαθμό εμπιστοσύνης 85%, από 1600 σε 3000 για 90% και από 1600 σε 3800 για 95%.




Σχήμα 8.16





*Σχήμα 8.17*




*Σχήμα 8.18*

Η αύξηση του εύρους των διαστημάτων εμπιστοσύνης, σε σχέση με αυτά που είχαμε πριν το C-V, οφείλεται στην μεροληψία του ντετερμινιστικού μοντέλου, καθώς έχει καλύτερη ικανότητα πρόβλεψης στα δεδομένα των τελευταίων 300 ωρών συγκριτικά με το σύνολο των δεδομένων.

Η καλύτερη αυτή ικανότητα πρόβλεψης, αποτυπώνεται και στον δείκτη CPRS ο οποίος αναλύθηκε στην ενότητα 5.4. Ο δείκτης CRPS καταδεικνύει την συνολική ακρίβεια πρόβλεψης του πιθανοτικού μοντέλου. Μια πολύ σημαντική παρατήρηση που μπορούμε να κάνουμε είναι πως το CPRS παραμένει σταθερό κατά την αύξηση του αριθμού των Bootstrap που κάνουμε για την διεύρυνση των διαστημάτων εμπιστοσύνης όμως μεταβάλλεται ανάλογα με τα δεδομένα αξιολόγησης στα οποία καλείται να προβλέψει το μοντέλο. Πιο συγκεκριμένα όταν το πιθανοτικό μοντέλο κληθεί να προβλέψει για τις τελευταίες 300 παρατηρήσεις των δεδομένων είχε  $CRPS = 0.7907$  ενώ κάνοντας Cross-Validation και υπολογίζοντας το για το σύνολο των δεδομένων είχε τιμή  $CRPS = 0.1005$  επιβεβαιώνοντας έτσι την μεροληψία του μοντέλου ως προς τις τελευταίες 300 παρατηρήσεις.

Μια σημαντική παρατήρηση που μπορούμε να κάνουμε επί των διαστημάτων εμπιστοσύνης είναι, πως όσο μεγαλύτερη είναι η πραγματική τιμή της παραγόμενης αιολικής ισχύος τόσο μεγαλύτερο φαίνεται να είναι και το εύρος των αντίστοιχων διαστημάτων εμπιστοσύνης που παράγει το μοντέλο για την συγκεκριμένη χρονική στιγμή. Για να παρατηρήσουμε καλύτερα την εξάρτηση του εύρους από την τιμή της αιολικής ισχύος για την οποία παράχθηκε, στο παρακάτω διάγραμμα, παρουσιάζεται το πλάτος του διαστήματος εμπιστοσύνης ως προς την εκάστοτε αιολική ισχύ στην οποία αναφέρεται. Τα δεδομένα του σχήματος (σχήμα 8.19) αποτελούν τα δεδομένα που λάβαμε για βαθμό εμπιστοσύνης 90% (σχήμα 8.17). Στα δεδομένα αυτά έγινε επίσης γραμμική παλινδρόμηση για να φανεί καλύτερα η εξάρτηση η οποία παρατηρείται.



Σχήμα 8.19

Βλέπουμε, πως υπάρχει άμεση εξάρτηση του εύρους του διαστήματος εμπιστοσύνης που παράγει το μοντέλο από την καταγεγραμμένη αιολική ισχύ και επομένως από την πραγματική μέτρηση του ανέμου την παρούσα χρονική στιγμή. Αυτό είναι αναμενόμενο αν αναλογιστούμε την μορφή της καμπύλης φορτίου μιας ανεμογεννήτριας. Καθώς αυξάνεται η ταχύτητα του ανέμου (και επομένως η παραγόμενη ισχύς) βρισκόμαστε στις περιοχές της καμπύλης φορτίου με μεγάλη κλίση και επομένως μικρά σφάλματα στις προβλέψεις ανέμου παρουσιάζουν μεγάλες αποκλίσεις στην πρόβλεψη παραγόμενης αιολικής ισχύος ως προς την πραγματική. Η διεύρυνση επομένως των διαστημάτων εμπιστοσύνης εξασφαλίζει την ενσωμάτωση των εσφαλμένων (συγκριτικά με τις προβλέψεις ανέμου) τιμών αιολικής ισχύος σε αυτά.

# Κεφάλαιο 9: Επίλογος

## 9.1: Σύνοψη και Συμπεράσματα

Σκοπός της παρούσας διπλωματικής εργασίας αποτελεί η πιθανοτική πρόβλεψη αιολικής παραγωγής, με χρονικό ορίζοντα πρόβλεψης μια ημέρα, χρησιμοποιώντας Extreme Learning Machines. Η ολοένα αυξανόμενη χρήση αιολικών σταθμών παραγωγής για την τροφοδότηση του δικτύου, σε πανευρωπαϊκό επίπεδο, δημιουργεί προβλήματα ευστάθειας σε αυτό. Η αδυναμία της ανθρώπινης παρέμβασης στην παραγωγή αιολικής ισχύος, καθιστά ζωτικής σημασίας την βελτίωση της ακρίβειας των προβλέψεων για την βέλτιστη, οικονομική και λειτουργική, ένταξη των αιολικών σταθμών παραγωγής στο δίκτυο. Όμως, η χαοτική συμπεριφορά της ατμόσφαιρας, και κατ' επέκταση του ανέμου, καθιστά την ακριβή πρόβλεψη αιολικής παραγωγής αδύνατη. Για τον λόγο αυτό παρουσιάζεται η ανάγκη για ανάπτυξη πιθανοτικών μοντέλων πρόβλεψης με σκοπό την ποσοτικοποίηση της αβεβαιότητας των ντετερμινιστικών προβλέψεων.

Η ανάπτυξη και η αξιολόγηση του πιθανοτικού μοντέλου με τα δεδομένα ενός έτους, που αφορούν έναν αιολικό σταθμό παραγωγής στην Αυστραλία, κατέδειξε πως η πιθανοτική πρόβλεψη αιολικής παραγωγής είναι εφικτή, μεταβάλλοντας τον αριθμό των ντετερμινιστικών μοντέλων ELM που θα χρησιμοποιήσουμε ανάλογα με το επιθυμητό βαθμό εμπιστοσύνης, με σκοπό την διασφάλιση της αξιοπιστίας του. Σημαντικό πλεονέκτημα της χρήσης ELM για την παραγωγή πιθανοτικών προβλέψεων, έναντι συμβατικών νευρωνικών δικτύων τα οποία χρησιμοποιούν τον αλγόριθμο backpropagation, αποτελεί η ταχύτητα εκπαίδευσής τους.

## 9.2: Μελλοντικές Επεκτάσεις

Εντούτοις, ο όγκος των δεδομένων που χρησιμοποιήθηκε, στα πλαίσια της εργασίας, περιορίστηκε σε έναν αιολικό σταθμό και ένα έτος παρατηρήσεων. Για την θεμελίωση της αξιοπιστίας της παρούσας μεθόδου πιθανοτικής πρόβλεψης αιολικής ισχύος, θα πρέπει τα ευρήματα να επαληθευτούν σε ένα ευρύτερο πλαίσιο δεδομένων, τα οποία αφορούν διαφορετικές χρονικές περιόδους και διαφορετικούς αιολικούς σταθμούς.

Τέλος, διαπιστώθηκε άμεση σύνδεση μεταξύ της ακρίβειας πρόβλεψης του ντετερμινιστικού μοντέλου με το εύρος των διαστημάτων εμπιστοσύνης που παράχθηκαν. Επομένως, για την βελτίωση του εύρους των διαστημάτων εμπιστοσύνης και την παροχή ακριβέστερων πληροφοριών σχετικά με την αβεβαιότητα της παραγωγής, η βελτίωση της ακρίβειας του ντετερμινιστικού μοντέλου, θα μπορούσε να αποτελέσει αντικείμενο μελλοντικής έρευνας. Ενδεικτικά, θα μπορούσαν να μελετηθούν περαιτέρω συναρτήσεις ενεργοποίησης και να εξετασθούν διαφορετικοί τρόποι ανάθεσης τυχαίων μεταβλητών στα βάρη και τα Biases των Extreme Learning Machines.



## ***Βιβλιογραφία:***

- [1] I. González-Aparicio, A. Zucker, “Impact of wind power uncertainty forecasting on the market integration of wind energy in Spain”, *Applied Energy*, vol. 159, pp 334-349, 2015
- [2] <https://windeurope.org/>
- [3] H. Holttinen, J. Miettinen & S.i Sillanpää, “Wind power forecasting accuracy and uncertainty in Finland”, *VTT Technology* 95, 60 p. + app. 8 p., 2013
- [4] S. Alessandrini, L. Delle Monache, S. Sperati, J.N. Nissen, “A novel application of an analog ensemble for short-term wind power forecasting”, *Renewable Energy*. vol. 76, pp 768-781, 2015
- [5] P. Pinson a, H.Aa. Nielsen, H. Madsen, G. Kariniotakis, “Skill forecasting from ensemble predictions of wind power”, *Applied Energy*, vol. 86, pp 1326-1334, 2009
- [6] A. Fabbri, T. Gómez San Román, Member, IEEE, J. Rivier Abbad, Member, IEEE, and V. H. Méndez Quezada, “Assessment of the Cost Associated With Wind Generation Prediction Errors in a Liberalized Electricity Market”, *IEEE Transactions On Power Systems*, Vol. 20, NO. 3, pp. 1440-1446 August 2005
- [7] P. Pinson, H. Aa. Nielsen, J. K. Møller, H. Madsen, G. N. Kariniotakis, “Non-parametric Probabilistic Forecasts of Wind Power: Required Properties and Evaluation”, *Wind Energy*, vol. 10, pp. 497–516, 2007
- [8] C. Wan, Z. Xu, P. Pinson, Z. Yang Dong and Kit Po Wong, “Probabilistic Forecasting of Wind Power Generation Using Extreme Learning Machine”, *IEEE Transactions On Power Systems*, Vol. 29, No. 3, pp 1033-1044, May 2014
- [9] Zhaoxia Pu and E. Kalnay, “Numerical Weather Prediction Basics: Models, Numerical Methods, and Data Assimilation”, *Handbook of Hydrometeorological Ensemble Forecasting*, Springer, pp 67-97
- [10] <https://public.wmo.int/en>
- [11] R. Buizza, “Chaos and weather prediction”, *European Centre for Medium-Range Weather*, 2000
- [12] L. Bengtsson, “Four Dimensional Data Assimilation”, *European Centre for Medium-Range Weather*, 1984
- [13] R. Daley, “*Atmospheric Data Analysis*”, Cambridge University Press, Nov 1993

- [14] G. Dow, “Developments in Observational Requirements for Global Numerical Weather Prediction”, UNIVERSITY OF READING, Department of Meteorology, Aug 2004
- [15] Sultan Al-Yahyai, Yassine Charabi, Adel Gastli, “Review of the use of Numerical Weather Prediction (NWP) Models for wind energy assessment”, *Renewable and Sustainable Energy Reviews*, vol.14, pp. 3192-3198, 2010
- [16] M. A. Tolstykh and A. V. Frolov, “Some Current Problems in Numerical Weather Prediction”, *Izvestiya, Atmospheric and Oceanic Physics*, Vol. 41, No. 3, pp. 285–295, 2005
- [17] S. F. Milton, C. A. Wilson, “The Impact of Parameterized Subgrid-Scale Orographic Forcing on Systematic Errors in a Global NWP Model”, *Monthly Weather Review*, vol. 124, No. 9, pp. 2023–2045, 1996
- [18] D. Orrell, L. Smith, J. Barkmeijer and T. N. Palmer, “Model error in weather forecasting”, *Nonlinear Processes in Geophysics*, Vol.8, pp. 357–371, 2001
- [19] <http://www.cosmo-model.org/>
- [20] L. LEI And J. P. HACKER, “Nudging, Ensemble, and Nudging Ensembles for Data Assimilation in the Presence of Model Error”, *National Center for Atmospheric Research*, vol. 143, pp. 2600-2610, 2015
- [21] L. Bengtsson, U. Andrae, T. Aspelién, Y. Batrak, J. Calvo, W. De Rooy, E. Gleeson, B. Hansen-Saas, M. Homleid, M. Hortal, K. Ivarsson, G. Lenderink, S. Niemela, K. P. Nielsen, J. Onvlee, L. Rontu, P. Samuelsson, D. S. Muñoz, A. Subias, S. Tjmm, V. Toll, X. Yang, M. Ø. Koltzow, “The HARMONIE–AROME Model Configuration in the ALADIN–HIRLAM NWP System”, *Monthly Weather Review*, Vol.145, Issue 5, pp. 1919–1935, May 2017
- [22] I. Sanchez, “Short-term prediction of wind energy production”, *International Journal of Forecasting*, Vol. 22, pp. 43-56, 2006
- [23] Godfrey Boyle, “Renewable Electricity and the Grid: The Challenge of Variability”, 1<sup>st</sup> edition, Routledge, 2009, ISBN 9781844077892
- [24] Y. Zhang, J. Wang, X. Wang, “Review on probabilistic forecasting of wind power generation”, *Renewable and Sustainable Energy Reviews*, Vol. 32, pp.255-270, 2014
- [25] A. Botterud, J. Wang, C. Monteiro, V. Miranda “Wind Power Forecasting and Electricity Market Operations”, Retrieved from [https://www.researchgate.net/publication/228407500\\_Wind\\_power\\_forecasting\\_and\\_electricity\\_market\\_operations](https://www.researchgate.net/publication/228407500_Wind_power_forecasting_and_electricity_market_operations)



- [26] P. Pinson, H.Aa. Nielsen, H. Madsen, M. Lange, G. Kariniotakis, “ Methods for the Estimation of the Uncertainty of Wind Power Forecasts”, Retrieved from [https://www.researchgate.net/publication/233400498\\_Methods\\_for\\_the\\_estimation\\_of\\_the\\_uncertainty\\_of\\_wind\\_power\\_forecasts](https://www.researchgate.net/publication/233400498_Methods_for_the_estimation_of_the_uncertainty_of_wind_power_forecasts)
- [27] P. Pinson, “Estimation of the uncertainty in wind power forecasting”. Engineering Sciences [physics]. École Nationale Supérieure des Mines de Paris, 2006. English. ffNNT: 2006ENMP1432ff. ffpastel00002187
- [28] C. Jung, D. Schindler “Wind speed distribution selection – A review of recent development and progress”, Renewable and Sustainable Energy Reviews, Vol. 114, 2019
- [29] F. Koch, M. Gresch, F. Shewarega, I. Erlich, U. Bachmann, “Consideration of wind farm wake effect in power system dynamic simulation”, 2005 IEEE Russia Power Tech, DOI: 10.1109/PTC.2005.4524572, 2005
- [30] D. Koracin, R. Belu, B. Canadillas, K. Horvath, R. Vellore, C. Smith, J. Jiang, T. Mccord, “A Review Of Challenges In Assessment And Forecasting Of Wind Energy Resources”, Croatian Meteorological Journal, Vol.47, pp.13-33, 2012
- [31] E. N. Lorenz, “The essence of chaos”, UCL Press, Pp 227, 1993
- [32] Giebel, G., Badger, J., Landberg, L., Nielsen, H. A., Nielsen, T. S., Madsen, H., ... Voulund, L. (2005). Wind Power Prediction using Ensembles. (Denmark. Forskningscenter Risoe. Risoe-R; No. 1527(EN)).
- [32] M. V. Shcherbakov, A. Brebels, N. L. Shcherbakova, A. P. Tyukov, T. A. Janovsky and V. A. Kamaev, ”A Survey of Forecast Error Measures”, World Applied Sciences Journal, Vol. 24, pp. 171-176, 2013
- [33] A. G. Tsikalakis, N. D. Hatziargyriou, Y. A. Katsigiannis, P. S. Georgilakis, “Impact of wind power forecasting error bias on the economic operation of autonomous power systems”, Wind Energy, Vol.12, Issue 4, pp.315-331, May 2009
- [34] M. Zamo, P. Naveau, “Estimation of the Continuous Ranked Probability Score with Limited Information and Applications to Ensemble Weather Forecasts”, Mathematical Geosciences, Vol.50, pp. 209-234, 2018
- [35] D. Anderson, G. McNeill, “Artificial Neural Networks Technology”, A DACS State-of-the-Art Report, Contract Number F30602-89-C-0082, Prepared for: Rome Laboratory RL/C3C Griffiss AFB, NY 13441-5700, Aug 1992

- [36] C. W. Dawson & R. Wilby (1998) “An artificial neural network approach to rainfall-runoff modelling, *Hydrological Sciences Journal*”, 43:1, 47-66, DOI: 10.1080/02626669809492102
- [37] S. Haykin, “*Neural Networks: A Comprehensive Foundation*”, 2nd Edition, Prentice Hall, 1998, ISBN: 9780132733502
- [39] Guang-Bin Huang, Qin-Yu Zhu, Chee-Kheong Siew, “Extreme learning machine: Theory and applications”, *Neurocomputing*, Vol. 70, pp. 489–501, 2006
- [40] R. Sathya, A. Abraham, “Comparison of Supervised and Unsupervised Learning Algorithms for Pattern Classification”, *International Journal of Advanced Research in Artificial Intelligence*, Vol. 2, No. 2, pp. 34-38, 2013
- [41] P. J. Werbos, “Backpropagation Through Time: What It Does and How to Do It”, *Proceedings of the IEEE*, Volume: 78, Issue: 10 , Oct. 1990, pp. 1550-1560
- [42] H.B. Barlow, “Unsupervised Learning”, *Neural Computation*, Volume 1, Issue 3, pp.295-311, 1989
- [43] D. A. Freedman, “Bootstrapping Regression Models”, *The Annals of Statistics*, Vol. 9, No. 6, pp. 1218-1228, 1981
- [44] Γ. Κοκολάκης, Ι. Σπηλιώτης, “Θεωρία Πιθανοτήτων και Στατιστική με Εφαρμογές”, Εκδόσεις Συμεών, Αθήνα 2010
- [45] D. Pevec, I. Kononenko, “Prediction intervals in supervised learning for model evaluation and discrimination”, *Applied Intelligence*, Vol. 42, pp.790-804, 2015
- [46] M. Khalid, A. V. Savkin. “Direction Dependent Power Curves for Wind Power Prediction: A Case Study”, *Sustainability in Energy and Buildings*, pp.121-127, 2011
- [47] G. I. Nagya, G. Barta, S. Kazi, G. Borbély, G. Simon, “GEFCom 2014: Probabilistic solar and wind power forecasting using a generalized additive tree ensemble approach”, *International Journal of Forecasting*, Vol. 32, No.3, 2016
- [48] M. Landry, T. P. Erlinger, D. Patschke, C. Varrichio , „Probabilistic gradient boosting machines for GEFCom2014 wind forecasting”, *International Journal of Forecasting*, Vol. 32, pp. 1061-1066, No.3, 2016
- [49] D. Rumelhal, G. hinton, R. Williams, “Learning Representations by Back-Propagating Errors”, *Nature*, Vol. 323, pp533-536, 1986

## Περιεχόμενα Σχημάτων:

- Σχήμα 1.1: Εγκατεστημένη αιολική ισχύς στην Ευρώπη από το 2009 ως το 2019
- Σχήμα 3.1: Αναπαράσταση τρισδιάστατου κύβου μοντέλων πλεγματικών σημείων
- Σχήμα 3.2: Αναπαράσταση θερμοκρασίας από μοντέλα πλεγματικών σημείων
- Σχήμα 3.3: Αναπαράσταση μεταβλητών από μοντέλα φασματικής ανάλυσης
- Σχήμα 3.4: Οριζόντια ανάλυση 28χλμ και 7χλμ ενός μοντέλου NWP
- Σχήμα 3.5: Υβριδική σίγμα συντεταγμένη για την αναπαράσταση κάθετης ανάλυσης
- Σχήμα 3.6: Προβλέψεις ανέμου για την Ελλάδα από το μοντέλο COSMOS
- Σχήμα 3.7: Προβλέψεις ανέμου για την κεντρική Ευρώπη από το μοντέλο HARMONIE-AROME
- Σχήμα 4.1: Θεωρητική μορφή της καμπύλης ισχύος μιας ανεμογεννήτριας
- Σχήμα 4.2: Συνάρτηση πυκνότητας πιθανότητας της ταχύτητας ανέμου(Weibull)
- Σχήμα 4.3: Πραγματική μορφή της καμπύλης ισχύος μιας ανεμογεννήτριας
- Σχήμα 4.4: Εκτιμώμενη αθροιστική καμπύλη ισχύος για έναν αιολικό σταθμό και οι πραγματικές τιμές παραγόμενης ισχύος
- Σχήμα 6.1: Βασική δομή ενός νευρωνικού δικτύου
- Σχήμα 6.2: Σχηματική απεικόνιση ενός κόμβου κρυφού επιπέδου
- Σχήμα 6.3: Feedforward και feedback αρχιτεκτονική νευρωνικών δικτύων
- Σχήμα 8.1: Σχηματική απεικόνιση της δομής ενός Extreme Learning Machine
- Σχήμα 8.2: MAE και RMSE για την ReLU(x) από 1 ως 400 κόμβους κρυφού επιπέδου
- Σχήμα 8.3: Γραφική της παράσταση της sigmoid(x)
- Σχήμα 8.4: MAE και RMSE για την sigmoid(x) από 1 ως 400 κόμβους κρυφού επιπέδου
- Σχήμα 8.5: Γραφική της παράσταση της tanh(x)
- Σχήμα 8.6: MAE και RMSE για την tanh(x) από 1 ως 400 κόμβους κρυφού επιπέδου
- Σχήμα 8.7: Αναπαράσταση K-Fold Cross-Validation
- Σχήμα 8.8: νέες τιμές MAE και RMSE για την ReLU(x) και την sigmoid(x) από 1 ως 400 κόμβους κρυφού επιπέδου κάνοντας 4-Fold Cross-Validation
- Σχήμα 8.9: Σημειακές προβλέψεις με ELM επί των τελευταίων 300 προβλέψεων ανέμου
- Σχήμα 8.10: Δείκτης ACE για κάθε επιθυμητό βαθμό εμπιστοσύνης ως προς τον διαφορετικό αριθμό BELM
- Σχήμα 8.11: Δείκτης Score για κάθε επιθυμητό βαθμό εμπιστοσύνης ως προς τον διαφορετικό αριθμό BELM
- Σχήμα 8.12: PICP για κάθε επιθυμητό βαθμό εμπιστοσύνης ως προς τον διαφορετικό αριθμό BELM
- Σχήμα 8.13: Διαστήματα εμπιστοσύνης επί των τελευταίων 300 προβλέψεων ανέμου για θεωρητικό B.E. 95% με 1600 BELM
- Σχήμα 8.14: Διαστήματα εμπιστοσύνης επί των τελευταίων 300 προβλέψεων ανέμου για θεωρητικό B.E. 90% με 1600 BELM
- Σχήμα 8.15: Διαστήματα εμπιστοσύνης επί των τελευταίων 300 προβλέψεων ανέμου για θεωρητικό B.E. 85% με 1500 BELM
- Σχήμα 8.16: Νέα διαστήματα εμπιστοσύνης επί των τελευταίων 300 προβλέψεων ανέμου για θεωρητικό B.E. 85% με 2600 BELM
- Σχήμα 8.17: Νέα διαστήματα εμπιστοσύνης επί των τελευταίων 300 προβλέψεων ανέμου για θεωρητικό B.E. 90% με 3000 BELM

- *Σχήμα 8.18:* Νέα διαστήματα εμπιστοσύνης επί των τελευταίων 300 προβλέψεων ανέμου για θεωρητικό B.E. 95% με 3800 BELM
- *Σχήμα 8.19:* Σχηματική αναπαράσταση εξάρτησης του εύρους των διαστημάτων εμπιστοσύνης από την ισχύ

## ***Περιεχόμενα Πινάκων:***

- *Πίνακας 8.1:* Τιμή MAE για την ReLU(x) για αριθμό νευρώνων από 41 ως 70
- *Πίνακας 8.2:* Τιμή RMSE για την ReLU(x) για αριθμό νευρώνων από 41 ως 70
- *Πίνακας 8.3:* Τιμή MAE για την Sigmoid(x) για αριθμό νευρώνων από 131 ως 160
- *Πίνακας 8.4:* Τιμή RMSE για την Sigmoid(x) για αριθμό νευρώνων από 131 ως 160
- *Πίνακας 8.5:* Τιμή MAE για την Sigmoid(x) για αριθμό νευρώνων από 131 ως 170 κάνοντας 4-Fold Cross-Validation
- *Πίνακας 8.6:* Τιμή RMSE για την Sigmoid(x) για αριθμό νευρώνων από 131 ως 170 κάνοντας 4-Fold Cross-Validation
- *Πίνακας 8.7:* Τιμή MAE για την ReLU(x) για αριθμό νευρώνων από 41 ως 80 κάνοντας 4-Fold Cross-Validation
- *Πίνακας 8.8:* Τιμή RMSE για την ReLU(x) για αριθμό νευρώνων από 41 ως 80 κάνοντας 4-Fold Cross-Validation
- *Πίνακας 8.9:* Τιμή ACE για B.E. 95%, 90%, 85% για διαφορετικό αριθμό BELM
- *Πίνακας 8.10:* Τιμή Score για B.E. 95%, 90%, 85% για διαφορετικό αριθμό BELM
- *Πίνακας 8.11:* Τιμή PICP για B.E. 95%, 90%, 85% για διαφορετικό αριθμό BELM
- *Πίνακας 8.12:* Νέος συντελεστής ACE για B.E. 95%, 90%, 85% κάνοντας 4-Fold Cross-Validation
- *Πίνακας 8.13:* Τιμή ACE για B.E. 95%, 90%, 85% για διαφορετικό αριθμό BELM κάνοντας 4-Fold Cross-Validation