



# ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΤΜΗΜΑ ΜΗΧΑΝΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ

ΔΗΜΙΟΥΡΓΙΑ ΜΟΝΤΕΛΩΝ ΠΡΟΓΝΩΣΗΣ ΤΗΣ ΠΑΡΑΓΟΜΕΝΗΣ ΕΝΕΡΓΕΙΑΣ ΣΕ  
ΑΙΟΛΙΚΟ ΠΑΡΚΟ ΜΕ ΤΗΝ ΧΡΗΣΗ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Λάιος Ιωάννης

ΑΜ:18392008

Επιβλέπων : Δρ. Μουστρίης Κωνσταντίνος, Καθηγητής

Αθήνα 2024



**UNIVERSITY OF WEST ATTICA**  
**SCHOOL OF ENGINEERING**  
**DEPARTMENT OF MECHANICAL ENGINEERING**

**DEVELOPMENT OF FORECASTING MODELS CONCERNING THE ENERGY  
PRODUCED IN A WIND FARM USING ARTIFICIAL NEURAL NETWORKS**

**DIPLOMA THESIS**

Laios Ioannis

Registration Number:18392008

Supervisor: Dr. Moustris Konstantinos , Professor

Athens 2024

Η Διπλωματική Εργασία έγινε αποδέκτη και βαθμολογήθηκε από την ακόλουθη τριμελή επιτροπή :

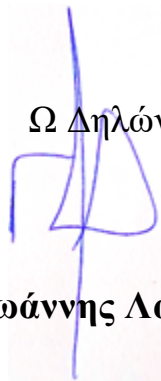
A/A	ΟΝΟΜΑ ΕΠΩΝΥΜΟ	ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ
1	ΜΟΥΣΤΡΗΣ ΚΩΝΣΤΑΝΤΙΝΟΣ (Καθηγητής)	
2	ΖΑΦΕΙΡΑΚΗΣ ΔΗΜΗΤΡΙΟΣ (Επίκουρος Καθηγητής)	
3	ΣΠΥΡΟΠΟΥΛΟΣ ΓΕΩΡΓΙΟΣ (Ε.Δι.Π.)	

## ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Ο κάτωθι υπογεγραμμένος Λάιος Ιωάννης του Αχιλλέα , με αριθμό μητρώου 18392008 φοιτητής του Πανεπιστημίου Δυτικής Αττικής της Σχολής Μηχανικών του Τμήματος Μηχανολόγων Μηχανικών , δηλώνω υπεύθυνα ότι :

«Είμαι συγγραφέας αυτής της διπλωματικής εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος. Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του πτυχίου μου».

Ω Δηλών



**Ιωάννης Λάιος**



# Πίνακας Περιεχομένων

Πίνακας Περιεχομένων.....	3
Πίνακας Διαγραμμάτων-Σχημάτων-Εικόνων.....	4
1. Εισαγωγή.....	7
1.1 Προβλέψεις βραχυπρόθεσμου φορτίου.....	8
1.2 Ανανεώσιμες Πηγές Ενέργειας.....	9
1.3 Αιολική Ενέργεια.....	10
1.4 Ανεμογεννήτριες.....	11
1.5 Τύποι δεδομένων για προβλέψεις παραγωγής ενέργειας.....	14
1.6 Ανάλυση των δεδομένων.....	15
1.7 Τεχνητή Νοημοσύνη.....	15
1.8 Αρχιτεκτονική.....	16
1.9 MultiLayer Perceptron Νευρωνικό Δίκτυο.....	17
1.9.1 Αρχιτεκτονικές Βασισμένες στα MLP.....	18
1.10 Ανάλυση Μοντέλου LSTM.....	19
1.10.1 Αρχιτεκτονικές Βασισμένες στα LSTM.....	23
1.11 Κύριες Διαφορές των Μοντέλων.....	26
2. Μεθοδολογία.....	26
2.1 Στατικότητα χρονοσειρών.....	26
2.2 Μη συγγραμμικότητα των δεδομένων χρονοσειρών που βασίζονται στα στοιχεία του αέρα.....	27
2.3 προεπεξεργασία δεδομένων (preprocessing).....	28
2.3.1 Εργαλείο Augmented Dickey-Fuller.....	32
2.3.2 Πίνακας συσχέτισης ( Correlation Matrix).....	33
2.3.3 MinMaxScaler.....	35
2.4 Αρχιτεκτονική Μοντέλου MLP.....	35
2.5 Αρχιτεκτονική Μοντέλου LSTM.....	37
2.6 Εκπαίδευση μοντέλων και Αξιολόγηση.....	38
2.6.1 Εκπαίδευση.....	38
2.6.2. Αξιολόγηση των Μοντέλων.....	40
3. Αποτελέσματα.....	41
3.1 Αποτελέσματα πρόβλεψης MLP.....	42
3.2 Αποτελέσματα μοντέλου LSTM.....	43
3.3 Σύγκριση Αποτελεσμάτων.....	45
4. Προτάσεις- Επόμενα βήματα.....	48

5.Επίλογος .....	48
------------------	----

## Πίνακας Διαγραμμάτων-Σχημάτων-Εικόνων.

Διάγραμμα 1:Καμπύλη ισχύος μίας ανεμογεννήτριας.....	13
Διάγραμμα 2:Τεχνητό Νευρωνικό Δίκτυο που Χρησιμοποιήθηκε στην Δημοσίευση της Sarropona.....	18
Διάγραμμα 3:Καμπύλη ισχύος της ανεμογεννήτριας για κάθε τιμή της ταχύτητας αέρα στο σέτ δεδομένων.....	31
Διάγραμμα 4:Συχνότητα εμφάνισης τιμών παραγόμενης Ενέργειας.....	31
Διάγραμμα 5:Αναπαράσταση του ΤΝΔ που κατασκευάστηκε για την πειραματική διαδικασία .....	36
Διάγραμμα 6:48ωρη πρόβλεψη του μοντέλου MLP.....	43
Διάγραμμα 7:Αποτελέσματα 48ωρης πρόβλεψης του LSTM μοντέλου. ....	45
Διάγραμμα 8: τελευταίες 24 ώρες της αρχικής πρόβλεψη για το MLP μοντέλο.....	47
Διάγραμμα 9:τελευταίες 24 ώρες της αρχικής πρόβλεψη για το LSTM μοντέλο.....	47
Σχήμα 1:Αρχιτεκτονική ενός τεχνητού νευρωνικού δικτύου .....	16
Σχήμα 2:Βασικό αναδρομικό νευρωνικό δίκτυο .....	20
Σχήμα 3:Long Short Term Memory breakdown.....	22
Εικόνα 1: Ετήσια συνολική ισχύ Αιολικής Ενέργειας στην επικράτεια.....	10
Εικόνα 2: Κατανομή παραγόμενης ισχύος στην επικράτεια.....	11
Εικόνα 3:Οι τύποι ανεμογεννητριών.....	12
Εικόνα 4: Βιβλιοθήκη NumPy.....	29
Εικόνα 5: Βιβλιοθήκη Pandas .....	29
Εικόνα 6:Αποτελέσματα του τεστ ADF στα δεδομένα εισόδου και εξόδου.....	32
Εικόνα 7:Πίνακας συσχέτισης των δεδομένων .....	34
Πίνακας 1:Τιμές μετρικών αξιολόγησης του MLP.....	<b>Σφάλμα! Δεν έχει οριστεί σελιδοδείκτης.</b>
Πίνακας 2:Τιμές μετρικών αξιολόγησης του LSTM.....	<b>Σφάλμα! Δεν έχει οριστεί σελιδοδείκτης.</b>

## Περίληψη

Η παρούσα διπλωματική εργασία μελετά την δυνατότητα πρόβλεψης παραγόμενης ενέργειας μίας ανεμογεννήτριας στο Μεσσόπιο Όρος . Αρχικά , πραγματοποιήθηκε βιβλιογραφική ανασκόπηση του παρόντος θέματος ,όπου εκεί εξετάστηκε εκτενέστερα η ανεμογεννήτρια του αιολικού πάρκου με αναφορά στα δεδομένα χρονοσειρών και οι μέθοδοι βραχυπρόθεσμης πρόβλεψης φορτίου παραγωγής. Έπειτα, έλαβε χώρα η ανάλυση των τεχνικών νευρωνικών δικτύων (ΤΝΔ) και μελετήθηκε ο τρόπος που χρησιμοποιούνται για την κατανόηση και ανάλυση σύνθετων προβλημάτων. Όσον αναφορά το πρακτικό κομμάτι όπου παρουσιάζονται η μεθοδολογία και τα αποτελέσματα της πειραματικής διαδικασίας, έγινε η εφαρμογή των μοντέλων βραχυπρόθεσμης πρόβλεψης με τη χρήση της γλώσσας προγραμματισμού Python. Στις παραπάνω εφαρμογές έγινε πρόβλεψη με τη χρήση δύο μοντέλων τεχνητής νοημοσύνης. Αναλυτικότερα έγινε χρήση ενός μοντέλου πολυστρωματικής αντίληψης-νόησης MLP (Multilayer Perceptron) και ένα αναδρομικό νευρωνικό δίκτυο (RNN) LSTM (Long Short-Term Memory) . Πιο αναλυτικά , για την διεξαγωγή της ανάλυσης έγινε χρήση δεδομένων από μία ελεύθερης πρόσβασης βάση δεδομένων (Renables.ninja.com) για μία ανεμογεννήτρια τύπου Vestas V90 με μορφή χρονοσειρών , για το έτος 2019. Ως δεδομένα για τα μοντέλα προβλέψεων χρησιμοποιήθηκαν η ταχύτητα του ανέμου με ωριαίο βήμα , η ονομαστική-Θεωρητική παραγόμενη ενέργεια της ανεμογεννήτριας και η πραγματική παραγόμενη ενέργεια. Μετά την κατάλληλη εκπαίδευση, παρουσιάζονται διαγράμματα όπου φαίνεται η ακρίβεια πρόβλεψης των μοντέλων για πρόβλεψη 48 εμπρόθεσμων ωρών ( με ωριαίο βήμα) και γίνεται σύγκριση των αποτελεσμάτων. Τέλος , παρουσιάζονται τα συμπεράσματα και η βιβλιογραφία που χρησιμοποιήθηκε για την παρούσα διπλωματική εργασία.

Λέξεις-Κλειδιά : Πρόβλεψη φορτίου, ανάλυση φορτίου, νευρωνικά δίκτυα, χρονοσειρές  
.βραχυπρόθεσμο μοντέλο, μηχανική μάθηση, τεχνητή νοημοσύνη



## **Abstract**

This thesis examines the potential for predicting the energy output of a wind turbine on Messopeio Mountain. Initially, a literature review on the subject was conducted, which extensively examined the wind turbine of the wind farm with reference to time series data and short-term load forecasting methods. Subsequently, the analysis of neural network techniques (NNT) was carried out, studying how they are used for understanding and analyzing complex problems. Regarding the practical section, which presents the methodology and the results of the experimental process, short-term prediction models were implemented using the Python programming language. In these applications, predictions were made using two models: an MLP (Multilayer Perceptron) neural network and an LSTM (Long Short-Term Memory) recurrent neural network (RNN). More specifically, for the analysis, data from an open-access database (Reneables.ninja.com) were used for a Vestas V90 wind turbine in the form of time series for the year 2019. The data used for the prediction models included wind speed, the nominal energy output of the wind turbine, and the actual energy output. Subsequently, diagrams are presented showing the prediction accuracy of the models for a forecast of 48 hours ahead, and a comparison of the results is made. Finally, the conclusions and the bibliography used for this thesis are presented.

Keywords: Load forecasting, load analysis, neural networks, time series, short-term model, machine learning, artificial intelligence.

# 1. Εισαγωγή

Η αιολική ενέργεια βιώνει ταχεία ανάπτυξη παγκοσμίως, με αυξανόμενη ζήτηση χρόνο με τον χρόνο. Η ακριβής πρόβλεψη της αιολικής ενέργειας είναι ουσιώδης για την αποτελεσματική λειτουργία των αιολικών πάρκων, καθώς επιτρέπει τη βέλτιστη παραγωγή ενέργειας, τη μείωση του κόστους μέσω της ισορροπίας προσφοράς και ζήτησης, και ενισχύει την αξιοπιστία της προσφοράς ενέργειας. Κατά τη διάρκεια του χρόνου, η πρόβλεψη της αιολικής ενέργειας έχει εξελιχθεί από απλές μετρήσεις της ταχύτητας του ανέμου σε πιο σύνθετα μοντέλα που λαμβάνουν υπόψη πολλαπλές περιβαλλοντικές παραμέτρους, όπως η θερμοκρασία, η πίεση και η ταχύτητα του ανέμου για να δημιουργήσουν ακριβείς προβλέψεις. Παραδοσιακές μέθοδοι όπως η αριθμητική πρόβλεψη και στατιστικά μοντέλα έχουν χρησιμοποιηθεί, αλλά πρόσφατες εξελίξεις στην τεχνολογία έχουν οδηγήσει στη χρήση ΤΝΔ, συμπεριλαμβανομένων τεχνικών βαθιάς μάθησης, λόγω της ικανότητάς τους να χειρίζονται μεγάλα σύνολα δεδομένων και να μοντελοποιούν πολύπλοκες σχέσεις.

Η μελέτη που έχει γίνει επικεντρώνεται στην πρόβλεψη της αιολικής ενέργειας με χρονικό ορίζοντα δύο (2) ημερών μπροστά χρησιμοποιώντας αρχιτεκτονικές βαθιάς μάθησης. Εκπαιδεύτηκαν δύο μοντέλα ΤΝΔ, ένα τύπου MLP και ένα LSTM αναδρομικό νευρωνικό δίκτυο. Ως δεδομένα για τα μοντέλα χρησιμοποιήθηκαν οι τιμές ταχύτητας αέρα και πραγματικής παραγόμενης ενέργειας για μία ανεμογεννήτρια τύπου Vestas V90 με ονομαστική ισχύ 2000 KW. Τα δεδομένα ταχύτητας και οι τιμές ονομαστικής ισχύος της ανεμογεννήτριας χρησιμοποιήθηκαν ως δεδομένα εισόδου για το μοντέλο MLP και η πραγματική παραγόμενη ενέργεια ως δεδομένα στόχου. Για το δεύτερο μοντέλο χρησιμοποιήθηκαν με μορφή ιστορικών δεδομένων οι τιμές μόνο της παραγόμενης ενέργειας .

Η διπλωματική εργασία διαιρείται σε πέντε ενότητες. Σε πρώτο στάδιο, γίνεται ανασκόπηση της βιβλιογραφίας σχετικά με την πρόβλεψη της αιολικής ενέργειας, τα μοντέλα ΤΝΔ και τις πηγές των δεδομένων που χρησιμοποιήθηκαν. Στη δεύτερη ενότητα, παρουσιάζεται εκτενώς την προσέγγιση που θα ακολουθήσει η διπλωματική εργασία, συμπεριλαμβανομένης της προεπεξεργασίας των δεδομένων, της επιλογής του κάθε μοντέλου και της αρχιτεκτονικής του. Όπως αναφέρθηκε, χρησιμοποιούμε 2 μοντέλα για την πειραματική διαδικασία, το ένα εξόρυξης χαρακτηριστικών MLP για την εξαγωγή χωρικών πληροφοριών και το δεύτερο ένα χρονικό μοντέλο LSTM. Ο στόχος είναι να δούμε αν είναι εφικτό το μοντέλο LSTM να μπορέσει να κάνει παρόμοιας ακρίβειας πρόβλεψη με το MLP μοντέλο. Η τρίτη ενότητα παρουσιάζει τα πειραματικά αποτελέσματα, ακολουθούμενα από μια εκτενή ανάλυση ενώ στη τέταρτη παρουσιάζονται προτάσεις για βελτίωση των μοντέλων. Στην πέμπτη ενότητα, που είναι και η τελευταία, η διπλωματική εργασία ολοκληρώνεται με συμπεράσματα βασισμένα στα ευρήματα του πειράματος.

## 1.1 Προβλέψεις βραχυπρόθεσμου φορτίου.

Η πρόβλεψη με χρήση μεγάλων δεδομένων είναι ένα ερευνητικό θέμα που έχει μεγάλη έμφαση στην νέα τάξη πραγμάτων και είναι κρίσιμο για τη βιομηχανία ηλεκτρικής ενέργειας στο τομέα της παραγωγής και της κατανάλωσης. Ο σχεδιασμός και η πρόβλεψη βραχυπρόθεσμου φορτίου ηλεκτρικής ενέργειας είναι ένα πολύπλοκο πρόβλημα που συνήθως επιλύεται σε σχέση με τον καιρό, την τοποθεσία, τους κοινωνικούς και οικονομικούς παράγοντες [7]. Επιπλέον, η ψηφιακή οικονομία έχει επιβάλει μεγαλύτερη ζήτηση στην αξιοπιστία της παροχής ηλεκτρικής ενέργειας, με περισσότερους καταναλωτές και ηλεκτρικά οχήματα (EVs), συνδεδεμένα στο ηλεκτρικό δίκτυο. Οι διαχειριστές ενέργειας ανησυχούν περισσότερο για την αξιοπιστία και την ασφάλεια των συστημάτων ισχύος. Ως εκ τούτου, οι σχεδιαστές ενέργειας χρησιμοποιούν διάφορες μεθόδους και τεχνολογίες για να υποστηρίξουν τη βιώσιμη επέκταση συστημάτων ηλεκτρικής ενέργειας, όπως μοντέλα πρόβλεψης ζήτησης ηλεκτρικής ενέργειας, στοχαστική βελτιστοποίηση, ισχυρή βελτιστοποίηση και προσομοίωση [8].

## 1.2 Ανανεώσιμες Πηγές Ενέργειας

Η γρήγορη αύξηση στην κατανάλωση ηλεκτρικής ενέργειας απαιτεί μια ακριβή πρόβλεψη της κατανομής της κατανάλωσης και της παραγωγής της [1]. Γι' αυτό, οι λύσεις με βάση τα δεδομένα για την πρόβλεψη της κατανάλωσης και παραγωγής ηλεκτρικής ενέργειας επικεντρώνονται σε λύσεις που βασίζονται σε χρονοσειρές [2].

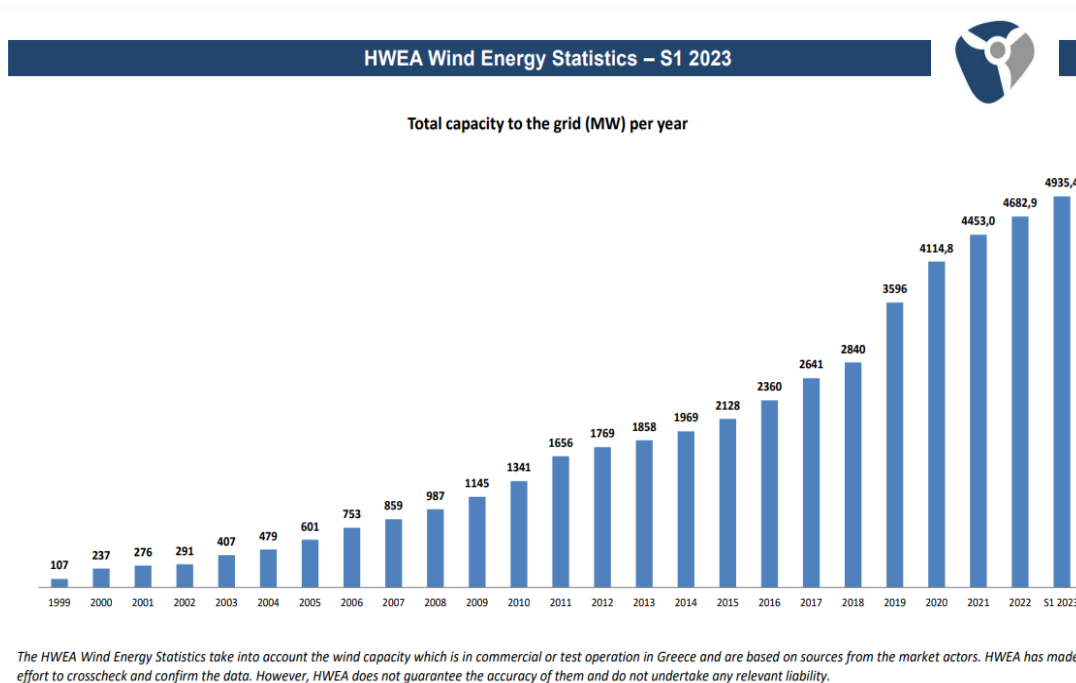
Η παραγωγή ενέργειας από ανανεώσιμες πηγές είναι ένας εξαιρετικά σημαντικός παράγοντας για τη μετάβαση του κόσμου σε ένα περιβάλλον με χαμηλότερα ποσοστά διοξειδίου του άνθρακα. Για να μπορέσει να πραγματοποιηθεί το σχέδιο μετάβασης του πλανήτη σε ένα σύστημα που παράγει "πράσινη" ενέργεια, τα συστήματα ηλεκτροδότησης υφίστανται μια διαδικασία μετασχηματισμού από ένα βαριά κεντροποιημένο δίκτυο, βασισμένο σε μεγάλες εγκαταστάσεις παραγωγής με ουράνιο, άνθρακα, φυσικό αέριο ή πετρέλαιο, σε ένα νέο αποκεντρωμένο μοντέλο με μικρές μονάδες αιολικής ή ηλιακής ενέργειας. Αυτή η αλλαγή απαιτεί υψηλό βαθμό συντονισμού, που διευκολύνεται από την εκτεταμένη χρήση αλγορίθμων υπολογιστή [3].

Η παραγωγή ενέργειας που βασίζεται στο νερό έχει θεωρηθεί ως ένα πρωτοποριακό ανανεώσιμο τρόπος παραγωγής ενέργειας. Η παραγωγή ενέργειας αυτής της μορφής έχει μεγάλο εύρος, από πολύ μεγάλα φράγματα που παράγουν εκατοντάδες MW έως μικρές μονάδες που παράγουν λίγα KW ηλεκτρισμού από την ροή του νερού από υψηλότερα επίπεδα σε πιο χαμηλά. Η παραγωγή ενέργειας που χρησιμοποιεί ως μέσο το νερό είναι οικονομική και ασφαλής. Με την προσθήκη διαφορετικών μορφών τεχνολογιών αποθήκευσης όπως οι αντλίες αποθήκευσης, τα φράγματα μπορούν να μετατραπούν σε συστήματα αποθήκευσης ηλεκτρικής ενέργειας, βοηθώντας στον έλεγχο των συστημάτων ηλεκτροδότησης σε όλο τον κόσμο [4]. Το νερό όμως είναι ένας πόρος που δεν είναι πάντα διαθέσιμος ή είναι ανεπαρκής, και η αδυναμία να κλιμακωθεί επαρκώς για να καλύψει τις ενεργειακές ανάγκες του κόσμου, ανοίγει τον δρόμο για άλλες καθαρές πηγές. Η ηλιακή και η αιολική ενέργεια εμφανίζουν την ταχύτερη ανάπτυξη παγκοσμίως. Και οι δύο τεχνολογίες μοιράζονται τα προβλήματα διακοπόμενης λειτουργίας που είναι ουσιώδη για τις ανανεώσιμες πηγές· επομένως, η πρόβλεψη γίνεται ένα κρίσιμο επεξεργαστικό βήμα για την ολοκλήρωση όλων αυτών των νέων πηγών

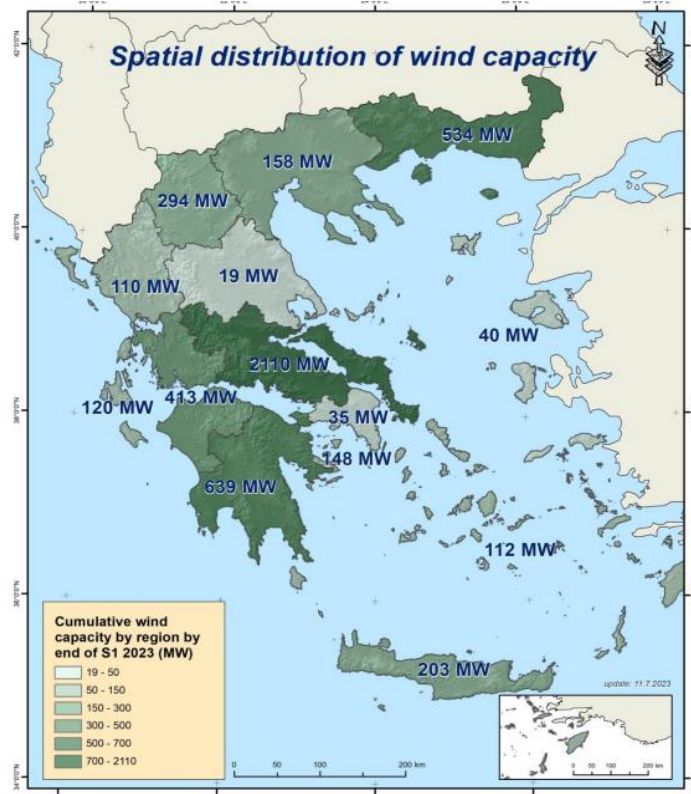
ενέργειας ενώ διατηρεί το δίκτυο σταθερό. Υπάρχουν διάφορες μελέτες που αφορούν τη σημασία της πρόβλεψης στην ενσωμάτωση στο δίκτυο, οι οποίες δείχνουν, με μοντελοποίηση που πραγματοποιήθηκε σε ευρωπαϊκό επίπεδο, πόσο σημαντικές είναι οι διαδικασίες πρόβλεψης, για βραχυπρόθεσμα, μεσοπρόθεσμα και μακροπρόθεσμα, για να εξασφαλιστεί η σταθερότητα του δικτύου [5].

### 1.3 Αιολική Ενέργεια

Η Ελλάδα είναι μια χώρα με έναν πολύ μεγάλο αριθμό νησιών, έτσι ισχυροί άνεμοι εμφανίζονται σε νησιωτικές και παράκτιες περιοχές. Αυτό είναι ιδιαίτερα ευεργετικό για την ανάπτυξη της αιολικής ενέργειας στη χώρα. Στο τέλος του Ιουνίου του 2023, σύμφωνα με στατιστικά στοιχεία που δημοσιεύτηκαν από τον Ελληνικό Επιστημονικό Σύλλογο Αιολικής Ενέργειας (ΕΕΑΕ) [14], η Ελλάδα διαθέτε συνολική ισχύ αιολικής ενέργειας 4.935,4 μεγαβάτ. (Εικόνα 1)



Εικόνα 1: Ετήσια συνολική ισχύ Αιολικής Ενέργειας στην επικράτεια




Εικόνα 2: Κατανομή παραγόμενης ισχύος στην επικράτεια

Επίσης, στην εικόνα 2 φαίνεται η γεωγραφική κατανομή της αιολικής ενέργειας στην Ελλάδα ανά περιοχή. Πρώτη έρχεται η περιοχή της Κεντρικής Ελλάδος με παραγωγή 2110 MW. Δεύτερη η Πελοπόννησος και τρίτη η Ανατολική Μακεδονία.

## 1.4 Ανεμογεννήτριες

Μία ανεμογεννήτρια λειτουργεί ως μηχανισμός που μετατρέπει την κινητική ενέργεια που υπάρχει στον αέρα σε ηλεκτρισμό. Οι ανεμογεννήτριες συνήθως ομαδοποιούνται μαζί σε αιολικά πάρκα, όπου συμβάλλουν συλλογικά στο ηλεκτρικό δίκτυο. Τα αιολικά πάρκα μπορούν να βρίσκονται είτε στην ξηρά είτε στη θάλασσα. Κατά τη λειτουργία τους, ο αέρας ωθεί τις λεπίδες της ανεμογεννήτριας, οι οποίες είναι συνδεδεμένες σε έναν ρότορα. Καθώς ο ρότορας περιστρέφεται, κινεί μία γεννήτρια, δημιουργώντας έτσι ηλεκτρισμό. Υπάρχουν δύο κύριοι τύποι ανεμογεννητριών: ανεμογεννήτριες οριζόντιου άξονα (HAWTs) και ανεμογεννήτριες κατακόρυφου άξονα (VAWTs).


Οι HAWTs, χαρακτηρισμένες από τις μακριές, λεπτές λεπίδες που μοιάζουν με προπέλες αεροπλάνου, είναι ο πιο κοινός τύπος ανεμογεννητριών. Τοποθετημένες έτσι ώστε να αντιμετωπίζουν απευθείας τον αέρα, τοποθετούνται σε υψηλούς πύργους για να απορροφήσουν ισχυρότερους ανέμους, με αποτέλεσμα αυξημένη απόδοση και ισχύ εξόδου. Ωστόσο, οι δαπάνες κατασκευής, μεταφοράς και συντήρησης που συνδέονται με τις HAWTs είναι σχετικά υψηλές. Επιπλέον, το μέγεθος τους μερικές φορές διαταράσσει την αισθητική αρμονία του φυσικού τοπίου[15]. Αντίθετα, οι VAWTs παρουσιάζουν μικρότερες, πιο φαρδιές λεπίδες που μοιάζουν με αναδευτήρα που χρησιμοποιείται σε ηλεκτρικούς μίκτες[15]. Αυτές οι ανεμογεννήτριες μπορούν να παράγουν ηλεκτρισμό ανεξάρτητα από την κατεύθυνση του αέρα, προσφέροντας πλεονεκτήματα σε θέματα κατασκευής και συντήρησης λόγω των απλούς απαιτήσεων για τον πύργο στήριξης. Οι VAWTs είναι ιδιαίτερα κατάλληλες για περιοχές με ακραίες καιρικές συνθήκες και παρουσιάζουν χαμηλότερους κινδύνους για πουλιά και ανθρώπους λόγω της πιο αργής περιστροφής των λεπίδων τους. Ωστόσο, συνήθως είναι λιγότερα αποδοτικές σε σχέση με τις HAWTs λόγω της αυξημένης αντίστασης των λεπίδων κατά την περιστροφή τους[16].



Εικόνα 3:Οι τύποι ανεμογεννητριών

Έχει διενεργηθεί σημαντική έρευνα για τη βελτίωση της παραγόμενης ισχύος των ανεμογεννητριών, εστιάζοντας στους μηχανισμούς παραγωγής ηλεκτρικής ενέργειας από αέρα και τον έλεγχο του σημείου μέγιστης ισχύος. Πραγματοποιήθηκε εκτενής

ανασκόπηση και σύγκριση τεσσάρων δημοφιλών μεθόδων ελέγχου του σημείου μέγιστης ισχύος (MPPT), καθώς και βελτιώσεων για κάθε μέθοδο[17]. Επιπλέον, εξετάστηκαν τεχνολογικά προηγμένοι γεννήτριες μετατροπής άνεμο-ενέργειας, όπως οι ασύρματες διπλής τροφοδοσίας γεννήτριες εισαγωγής, οι σύγχρονες γεννήτριες μετατροπής μόνιμου μαγνητικού στάτορα, οι μαγνητικές γεννήτριες, κ.λπ. Επιπλέον, αναλύθηκαν τρεις τεχνικές για την αξιολόγηση της απόδοσης των ανεμογεννητριών (Πειραματική - Αναλυτική - Υπολογιστική)[17]. Αυτές οι μεθοδολογίες στοχεύουν στο να σχεδιαστούν οι ανεμογεννήτριες για την βέλτιστη παραγωγή ενέργειας με χαμηλότερο κόστος[18].



Διάγραμμα 1: Καμπύλη ισχύος μίας ανεμογεννήτριας

Η ενέργεια που παράγεται από μία ανεμογεννήτρια συνδέεται στενά με την ταχύτητα του αέρα. Η ενέργεια που παράγεται αυξάνεται όσο αυξάνεται και η ταχύτητα του αέρα. Η σχεδίαση και η λειτουργία μίας ανεμογεννήτριας απαιτεί ένα συγκεκριμένο εύρος ταχύτητας αέρα. Τα όρια αυτού του εύρους είναι η ταχύτητα εκκίνησης και η ταχύτητα διακοπής. Ειδικότερα, όταν η ταχύτητα του αέρα είναι πολύ χαμηλή, οι λεπίδες του ανεμογεννήτριας δεν κινούνται με αποτέλεσμα να μην παράγεται ηλεκτρισμός. Η ανεμογεννήτρια ξεκινά να περιστρέφεται για πρώτη φορά και να παράγει ισχύ στην ταχύτητα εκκίνησης. Όταν η ταχύτητα του αέρα αυξάνεται, η ισχύς υπερβαίνει σταδιακά την ταχύτητα εκκίνησης και φτάνει το μέγιστο όριο που μπορεί να υποστηρίξει η σχεδίαση της ανεμογεννήτριας. Η ταχύτητα διακοπής είναι η τιμή της ταχύτητας του ανέμου η οποία μπορεί να αποβεί ζημιογόνα για τα μηχανικά μέρη της ανεμογεννήτριας. Όταν η ταχύτητα



του αέρα παίρνει αυτές τις τιμές διακόπτεται η λειτουργία της ανεμογεννήτριας και οι λεπίδες της μπαίνουν σε θέση μικρής αεροδυναμικής αντίστασης[18].

## 1.5 Τύποι δεδομένων για προβλέψεις παραγωγής ενέργειας

Η πρόβλεψη της ενέργειας του ανέμου μπορεί να κατηγοριοποιηθεί σε δύο βασικές προσεγγίσεις, ανάλογα με την προέλευση της εισόδου, μετεωρολογική ή με τη χρήση χρονοσειρών. Η πρώτη κατηγορία, βασίζεται στη χρήση μοντέλων Πρόβλεψης Καιρού (NWP) ως είσοδο, ενώ η πρόβλεψη με τη χρήση χρονοσειρών βασίζεται μόνο στη χρήση χρονοσηματοδοτημένων παρελθοντικών παρατηρήσεων. Σε αυτή την διπλωματική, η εστίαση είναι στη δεύτερη προσέγγιση, καθώς το αντικείμενο της έρευνας είναι να καθοριστεί πώς μερικές αρχιτεκτονικές βαθιάς μάθησης μπορούν να μάθουν μοτίβα παραγωγής ενέργειας από παρελθοντικές παρατηρήσεις του αιολικού πάρκου.

Οι χρονοσειρές εξαγωγής ενέργειας και οι χρονοσειρές ταχύτητας ανέμου, από την άποψη των στατιστικών, έχουν ορισμένα χαρακτηριστικά που καθορίζουν την πρόβλεψή τους ως ένα πολύπλοκο πρόβλημα (για μια ανάλυση της πρόβλεψης της αιολικής ενέργειας,)[10]. Οι πιο κοινές στατιστικές μέθοδοι που χρησιμοποιούνται στις τεχνικές πρόβλεψης (forecasting) είναι ο αυτοπαλινδρομικός κινούμενος μέσος όρος (ARMA), ο αυτοπαλινδρομικός ολοκληρωμένος κινούμενος μέσος όρος (ARIMA), η εκθετική εξομάλυνση, η γραμμική παλινδρόμηση και άλλες παρόμοιες προσεγγίσεις. Ωστόσο, αυτές οι μέθοδοι είναι περιορισμένες στην εκμάθηση των πολύπλοκων μη γραμμικών αλληλεπιδράσεων μεταξύ των μεταβλητών εισόδου και εξόδου. Ως εκ τούτου, δεν παρέχουν ικανοποιητικά αποτελέσματα [11].

Η εισαγωγή αλγορίθμων μηχανικής μάθησης στον τομέα της πρόβλεψης του ανέμου έχει συμβεί παράλληλα με την ανάπτυξη λογισμικών εργαλείων (tools) για τη χρήση αυτών των μοντέλων σε μεγάλη κλίμακα. Αυτά τα νέα εργαλεία έχουν επιτρέψει το σχεδιασμό προσεγγίσεων με υψηλής ακρίβειας αποτελέσματα που εφαρμόζονται σε χρονοσειρές ανέμου και χρονοσειρές παραγωγής ενέργειας[12].

## 1.6 Ανάλυση των δεδομένων

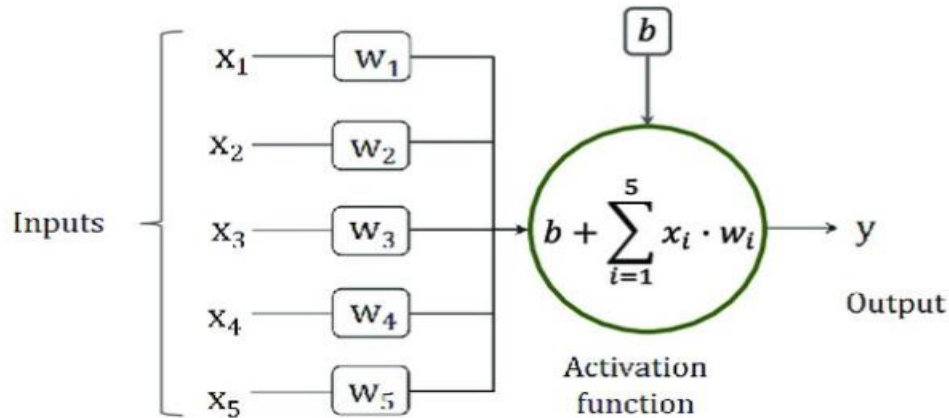
Η συλλογή των δεδομένων έγινε από την ελεύθερη βάση δεδομένων **Renewables.ninja** και περιέχει την ταχύτητα του ανέμου στις συντεταγμένες ( 38.459, 23.469) στο Μεσσάπιο όρος , καθώς και την παραγόμενη ενέργεια για μία ανεμογεννήτρια τύπου Vestas V90. Η βάση δεδομένων αυτή λαμβάνει πληροφορίες και στοιχεία από την NASA (MERRA reanalysis ) και είναι ένας γνωστός σύνδεσμος μεταξύ μελετητών και ακαδημαϊκών για την απόκτηση δεδομένων σχετικά με αιολικά-ηλιακά δυναμικά διάφορων περιοχών. Η περιοχή αυτή επιλέχθηκε με γνώμονα την ύπαρξη αιολικού πάρκου σε εκείνες τις συντεταγμένες, το οποίο πάρκο έχει επτά ανεμογεννήτριες ίδιου τύπου.

## 1.7 Τεχνητή Νοημοσύνη


Η τεχνητή νοημοσύνη έχει καταλάβει την κεντρική θέση στην επιστήμη των υπολογιστών, στην υπολογιστική μηχανική, και στην επιστήμη των δεδομένων χάρη στις εξελίξεις στην τεχνολογία και τη δημιουργία γρήγορων, ισχυρών υπολογιστών. Τα νευρωνικά δίκτυα είναι το κύριο εργαλείο σε αυτό τον τομέα. Ένα νευρωνικό δίκτυο αξιοποιεί αλγόριθμους μηχανικής μάθησης για να προσομοιώσει τις λειτουργίες του ανθρώπινου εγκεφάλου. Τα ΤΝΔ επεξεργάζονται μεγάλες ποσότητες δεδομένων και επιλύουν πολύπλοκα προβλήματα. Η δομή τους βασίζεται στις συνδέσεις νευρώνων σε διάφορα επίπεδα και, συνεπώς, μιμείται τις διαδικασίες σήματος των βιολογικών νευρώνων[19]. Τα ΤΝΔ μπορούν να εφαρμοστούν σε διάφορους τομείς όπως η αναγνώριση εικόνων, η επεξεργασία φυσικής γλώσσας και τα αυτόνομα οχήματα. Έχουν συμβάλει σημαντικά στην εξέλιξη διάφορων τομέων παρέχοντας λύσεις σε πολύπλοκα προβλήματα που προηγουμένως ήταν δύσκολο ή αδύνατο να επιλυθούν χρησιμοποιώντας παραδοσιακούς αλγόριθμους. Με τη συνεχή έρευνα και ανάπτυξη, τα ΤΝΔ συνεχίζουν να προχωρούν, σπρώχνοντας τα όρια του τι μπορεί να επιτύχει το εργαλείο αυτό σε όλες τις επιστήμες. Η ικανότητά τους να μαθαίνουν από δεδομένα και να προσαρμόζονται σε νέες καταστάσεις τα καθιστά απίστευτα ισχυρά εργαλεία στον τομέα της τεχνητής νοημοσύνης[19][20].

## 1.8 Αρχιτεκτονική

Όπως φαίνεται στο Σχήμα 1, ένα ΤΝΔ αποτελείται από επίπεδα κόμβων που κατανέμονται σε ένα επίπεδο εισόδου, ένα ή περισσότερα κρυφά επίπεδα και ένα επίπεδο εξόδου. Οι νευρώνες που συνδέονται μεταξύ τους ονομάζονται κόμβοι. Το επίπεδο εξόδου παρέχει τις τελικές πληροφορίες από τα κρυφά επίπεδα που έχουν επεξεργαστεί τα δεδομένα που εισήχθησαν από τους νευρώνες[19].



(a) A perceptron with  $N = 5$  inputs  $x_i$  and one output  $y$ .



(b) Feed-forward fully connected neural network.

Σχήμα 1: Αρχιτεκτονική ενός τεχνητού νευρωνικού δικτύου

Ένα τυπικό ΤΝΔ περιλαμβάνει ένα πλήρως συνδεδεμένο επίπεδο νευρώνων, που σημαίνει ότι η έξοδος κάθε νευρώνα χρησιμεύει ως είσοδος για κάθε νευρώνα του επόμενου επιπέδου. Ο αριθμός των επιπέδων σε ένα ΤΝΔ ποικίλει και περιγράφει το βάθος του

δικτύου. Η αρχιτεκτονική των νευρωνικών δικτύων διαφοροποιείται ανάλογα με διάφορους παράγοντες, όπως το βάθος τους, ο αριθμός των κρυφών τους επιπέδων και οι δυνατότητες εισόδου-εξόδου κάθε κόμβου. Το βάθος, ο αριθμός των κρυφών επιπέδων κάθε κόμβου είναι μόνο μερικά από τα χαρακτηριστικά που διακρίνουν την αρχιτεκτονική του νευρωνικού δικτύου[20].

## 1.9 MultiLayer Perceptron Νευρωνικό Δίκτυο

Η πιο απλή αρχιτεκτονική των ΤΝΔ ονομάζεται Forward Multilayer Perceptron ή Πολυστρωματικής αντίληψης-νόησης (Σχήμα 1). Σε αυτήν την αρχιτεκτονική, κάθε στρώμα του δικτύου έχει μόνο προς τα εμπρός συνδέσεις με το επόμενο στρώμα. Ο ορισμός του Perceptron περιγράφηκε στο βιβλίο των Minsky και Papert "Perceptrons" [21], αλλά οι πρώτες του υλοποιήσεις προέρχονται από μερικά χρόνια νωρίτερα. Η βάση του Perceptron είναι να μιμηθεί (με ελεύθερο λογισμό) τη συμπεριφορά του φυσικού νευρώνα και των συνδέσεών του. Ένα σήμα ή τύπος δεδομένων εισέρχεται στον στρώμα εισόδου, στη συνέχεια επεξεργάζεται από τους κρυφούς νευρώνες και το αποτέλεσμα διατίθεται στην έξοδο. Ο στόχος ενός δικτύου MLP είναι να προσεγγίσει κάποια συνάρτηση  $f^*$ , όταν υπάρχουν πολλαπλά στρώματα, κάθε στρώμα είναι μια συνάρτηση της συνάρτησης:

$$f(x) = f(3)(f(2)(f(1)(x))), (1)$$

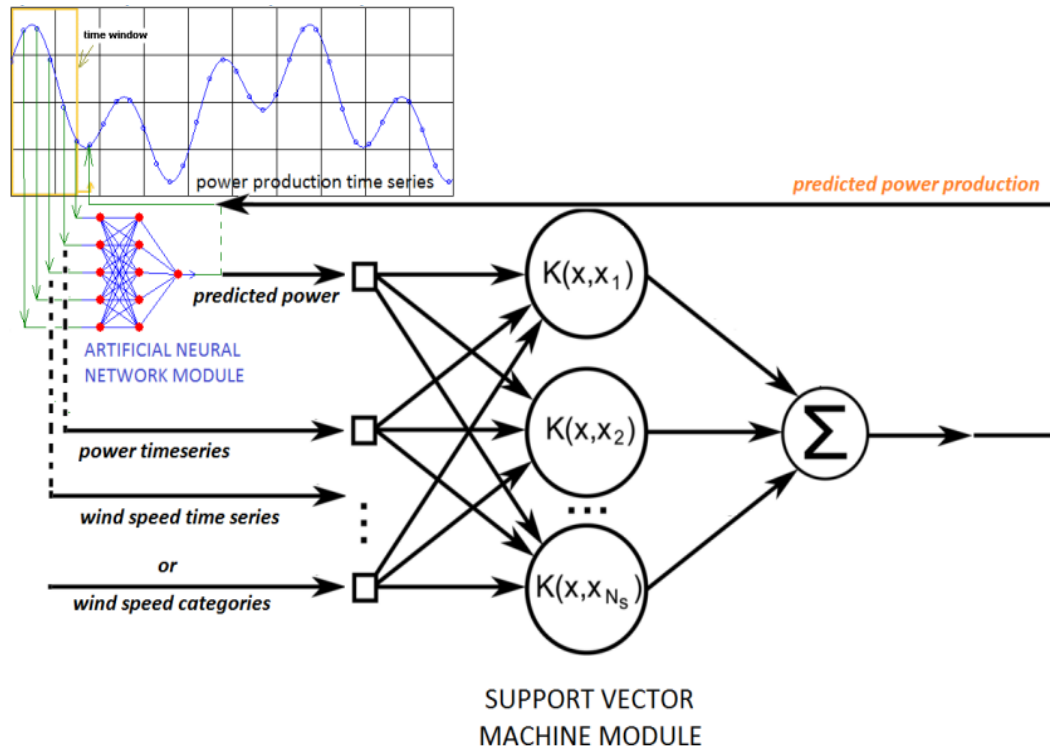
Σε αυτό το παράδειγμα τριών στρωμάτων, κάθε συνάρτηση είναι ένα στρώμα στο δίκτυο (ένα, δύο, τρία). Αυτός ο αριθμός ορίζει το βάθος του μοντέλου, με το τελευταίο στρώμα να είναι το στρώμα εξόδου.

Τα ΤΝΔ έχουν σε κάθε νευρώνα μια συνάρτηση ενεργοποίησης που επιδρά στις εισροές που λαμβάνονται και δημιουργεί μια έξοδο, συν ένα αλγόριθμο οπισθοδιάδοσης που βελτιστοποιεί τα βάρη σε κάθε σύνδεση σε μια διαδικασία για να βρει τον βέλτιστο συνδυασμό για την έξοδο. Τα ΤΝΔ δεν είναι γραμμικά και αυτό το χαρακτηριστικό τους

επιτρέπει να παράγουν καλύτερα αποτελέσματα από τα γραμμικά μοντέλα σε χρονοσειρές δεδομένων ανέμου.[22]

### 1.9.1 Αρχιτεκτονικές Βασισμένες στα MLP

Η Sarpouona στο [24] παρουσιάζει μια προσέγγιση Βαθιάς Μάθησης (DL) που ξεπερνά τη γραμμική εξωτερική πόλωση και τα δίκτυα Τεχνητών Νευρωνικών Δικτύων (ΤΝΔ) με λίγα στρώματα για βραχυπρόθεσμες προβλέψεις (έως 30 λεπτά), το μοντέλο που χρησιμοποίησαν φαίνεται στο Διάγραμμα 2. Η αρχιτεκτονική DL δεν προσδιορίζεται λεπτομερώς και ένα από τα συμπεράσματα του πειράματος είναι ότι η χρήση δεδομένων Πρότυπου Πρόγνωσης Καιρού (NWP) δεν βελτιώνει τα συνολικά αποτελέσματα για τα χρονικά πλαίσια πρόβλεψης (30 λεπτά).



Διάγραμμα 2: Τεχνητό Νευρωνικό Δίκτυο που Χρησιμοποιήθηκε στην Δημοσίευση της Sarpouona.

Ο Shi στο [25] αναπτύσσει μια υβριδική προσέγγιση με αρχιτεκτονικές ΤΝΔ και SVM ή ARIMA. Η ιδέα πίσω από αυτόν τον σχεδιασμό είναι η ανάπτυξη μοντέλων που μπορούν να αναγνωρίσουν τα γραμμικά στοιχεία (ARIMA-SVM) και τα μη γραμμικά στοιχεία (ΤΝΔ) από μια χρονοσειρά. Το πείραμα διεξάγεται σε διάφορα χρονικά βήματα

(από 1 έως 7) και οι επιδόσεις των υβριδικών μεθόδων δείχνουν μικρή βελτίωση σε σχέση με την απομονωμένη προσέγγιση (λιγότερο από 3%). Το συμπέρασμα είναι ότι μια υβριδική μεθοδολογία είναι μια βιώσιμη επιλογή, αλλά δεν αποδίδει πάντα καλύτερες επιδόσεις από τις μεθόδους χωρίς ΤΝΔ.

Ο Liu στο [23] χρησιμοποιώντας δεδομένα που λαμβάνονται κάθε μισή ώρα από έναν κινεζικό αιολικό σταθμό στο Qinghai (20 ημέρες) αναπτύσσει διάφορα υβριδικά μοντέλα, ARIMA, Wavelet (αποσύνθεση σήματος) και ΤΝΔ με διάφορους αλγορίθμους εκπαίδευσης. Συμπεραίνει ότι οι υβριδικοί αλγόριθμοι έχουν καλύτερες επιδόσεις από τους απομονωμένους ARIMA ή Persistence, και ο καλύτερος αλγόριθμος εκπαίδευσης είναι ο BFGS Quasi-Newton Back Propagation. Ωστόσο, οι βελτιώσεις που υπολογίζονται σε όρους MAE, MSE και MAPE δεν είναι εντυπωσιακές.

Ο Li στο [26] συγκρίνει διάφορες αρχιτεκτονικές ΤΝΔ (γραμμική, οπισθοδιάδοση και ακτινική βάση) χρησιμοποιώντας δεδομένα παρατηρήσεων στη Βόρεια Ντακότα (ΗΠΑ). Αξιολογεί τα αποτελέσματα σε MAE, RMSE και MAPE. Συμπεραίνει ότι δεν υπάρχει ανώτερη αρχιτεκτονική καθώς τα αποτελέσματα εξαρτώνται από τα δεδομένα. Με καλύτερο συντονισμό των μοντέλων επιτυγχάνονται διαφορές της τάξης του 20%. Οι συγγραφείς προτείνουν μεθοδολογία μετα-επεξεργασίας για εφαρμογή στα αποτελέσματα πρόβλεψης για να μειωθούν οι διαφορές μεταξύ των μοντέλων.


## 1.10 Ανάλυση Μοντέλου LSTM

Το LSTM (Long Short-Term Memory) είναι ένα είδος ΤΝΔ που σχεδιάστηκε για την αντιμετώπιση της αναγνώρισης μοτίβων και της ανάλυσης χρονοσειρών. Αυτό το νευρωνικό δίκτυο μπορεί να "θυμάται" πληροφορίες για μεγάλα χρονικά διαστήματα, επιλύοντας προβλήματα όπως η αναγνώριση μοτίβων σε κείμενο, η αναγνώριση φωνής και η πρόβλεψη χρονοσειρών.

Η βασική ιδέα πίσω από το LSTM είναι η χρήση μονάδων μνήμης, οι οποίες ονομάζονται "κυψέλες μνήμης" (memory cells), οι οποίες μπορούν να διατηρήσουν πληροφορία για πολλά χρονικά βήματα. Αυτές οι κυψέλες ελέγχονται από πύλες που επιτρέπουν την πρόσβαση, την ενημέρωση και την εξαγωγή πληροφορίας από τη μνήμη.

Οι τέσσερις βασικές πύλες είναι η πύλη εισόδου (input gate), η πύλη λήθης (forget gate), η πύλη εξόδου (output gate) και η πύλη μνήμης (memory gate). Η πύλη εισόδου ελέγχει πόση από τη νέα πληροφορία θα εισέλθει στην κυψέλη μνήμης, η πύλη λήθης ελέγχει πόση από την υπάρχουσα πληροφορία θα διαγραφεί, η πύλη εξόδου ελέγχει πόση από την ενημερωμένη πληροφορία θα εξαχθεί ως εξόδος του κελιού, και η πύλη μνήμης ελέγχει πόση από την ενημερωμένη πληροφορία θα διατηρηθεί στη μνήμη.

Ο τρόπος που λειτουργεί το LSTM μοντέλο είναι αρκετά σύνθετος, βασίζεται στον μηχανισμό των αναδρομικών νευρωνικών δικτύων (RNN) (σχήμα 3) χρησιμοποιώντας ένα σειριακό μοντέλο που μπορεί να εφαρμοστεί αποτελεσματικά με την επεξεργασία χρονοσειρών δεδομένων ως ένα διάνυσμα εισόδου και την παροχή του διανύσματος εξόδου από τη δομή νευρωνικού δικτύου στις κυψέλες του μοντέλου [11].



Σχήμα 2:Βασικό αναδρομικό νευρωνικό δίκτυο

Ως αποτέλεσμα, τα δεδομένα εισόδου περνούν από τις κυψέλες σε ένα σειριακό διάνυσμα, και οι τιμές εξόδου συνενώνονται με τα δεδομένα εισόδου του επόμενου χρονικού βήματος σε κάθε βήμα, με τις τιμές εξόδου της κυψέλης να λειτουργούν ως είσοδος για το επόμενο βήμα. Η βασική δομή του LSTM είναι απεικονισμένη στο σχήμα 4. Η ικανότητα του LSTM να διατηρεί μια κατάσταση κυψέλης  $ct$  από την προηγούμενη ακολουθία εισόδου είναι μία από τα βασικά του χαρακτηριστικά. Μπορεί επίσης να αφαιρέσει μη ουσιώδεις λειτουργίες ή πληροφορίες.

Αυτό επιτυγχάνεται μέσω της διαχείρισης της διατήρησης των πληροφοριών μέσω τριών πυλών: εισόδου ( $It$ ), λήθης ( $ft$ ) και εξόδου ( $Ot$ ) όπως αναφέρθηκε και στην αρχή του κεφαλαίου. Σε ένα δεδομένο χρονικό σημείο  $t$ , κάθε μία από τις πύλες αποκτά μια

μεταβλητή κατάσταση. Οι τιμές εξόδου της πύλης λήθης κυμαίνονται από 0 έως 1. Η  $f_t(1)$  δεν θυμάται την προηγούμενη κατάσταση της κυψέλης, η οποία είναι περιττή. Απλά αποθηκεύει τις πληροφορίες  $C_t$  που χρειάζονται για να πραγματοποιηθεί η διαδικασία πρόβλεψης, όπως:

$$[f_t = \sigma(W_f[h_{t-1}, X_t] + b_f)](2)$$

Όπου, η συνάρτηση σιγμοειδούς (sigmoid function) (σημείωσης) ορίζεται ως:

$$[\sigma(X) = \frac{1}{1 + e^{-x}}](3)$$

Η επόμενη διαδικασία εξαρτάται από το  $I_t$ , και μια νέα ενεργοποίηση της πύλης υποψηφίου εισόδου γίνεται για να δημιουργηθεί μια νέα τιμή  $C_t$  που μετακινείται στο επόμενο  $t$  ως ανανέωση της  $C_t$ . Στην πύλη υποψηφίου εισόδου, χρησιμοποιείται η υπερβολική εφαπτομετρική συνάρτηση ως συνάρτηση ενεργοποίησης, ενώ στην πύλη εισόδου χρησιμοποιείται η σιγμοειδής συνάρτηση. Αυτό παράγει εξόδους  $I_t$  καθώς και μια νέα κατάσταση κυψέλης  $C'_t$ , η οποία διατυπώνεται ως εξής:

$$[I_t = \sigma(W_i[h_{t-1}, X_t] + b_t)](4)$$

$$[C'_t = \tanh(W_c[h_{t-1}, X_t] + b_c)](5)$$


όπου η συνάρτηση της υπερβολικής εφαπτομετρικής είναι ορισμένη ως:

$$[\tanh(X) = \frac{e^x - e^{-x}}{e^x + e^{-x}}](6)$$

Οι εξισώσεις αυτές λαμβάνουν εφαρμογή όπως φαίνεται στην εικόνα#. Η οποία δίνει μια καλύτερη αντίληψη της εσωτερικής ακολουθίας διαδικασιών που πραγματοποιούνται στην προσωρινή μνήμη του νευρωνικού δικτύου. Με αυτόν τον τρόπο, το LSTM μπορεί να μάθει και να αποθηκεύσει μακροπρόθεσμες εξαρτήσεις στα



δεδομένα εισόδου, κάνοντάς το ιδανικό για εφαρμογές που απαιτούν την κατανόηση και την πρόβλεψη μακροπρόθεσμων μοτίβων[11],[13].



Σχήμα 3: Long Short Term Memory breakdown.

Το LSTM είναι ικανό να αντιμετωπίζει το πρόβλημα της εξαφάνισης ή της εκρηκτικής αύξησης του κλιμακίου (vanishing/exploding gradients) των γραμμικών μοντέλων όταν εφαρμόζονται σε μεγάλου όγκου δεδομένων χρονοσειρών [13]. Αυτό συμβαίνει επειδή το LSTM μπορεί να διατηρήσει αυτές τις πληροφορίες για μεγάλα χρονικά διαστήματα, επιτρέποντας έτσι την αποτελεσματική ανάλυση και πρόβλεψη μακροπρόθεσμων τάσεων και μοτίβων στα δεδομένα όπως επεξηγήθηκε στην μαθηματική ανάλυση.

Για τους λόγους που αναφέρθηκαν παραπάνω, το LSTM έχει εφαρμογές σε πολλούς τομείς, όπως η φυσική και η μηχανική πρόβλεψη, η αναγνώριση και η σύνθεση φωνής, η αναγνώριση αντικειμένων σε εικόνες και βίντεο, η ανάλυση κειμένου και η αυτόματη παραγωγή κειμένου, η ρομποτική, και πολλά άλλα. Όπως θα δούμε και σε αυτή

την διπλωματική το μοντέλο LSTM χρησιμοποιείται ευρέως σε εφαρμογές που απαιτούν ανάλυση και πρόβλεψη χρονοσειρών και τη πρόβλεψη παραγωγής ενέργειας στη προκειμένη περίπτωση. Η ικανότητα του LSTM να αντιμετωπίζει πολύπλοκα προβλήματα και να μάθει από μακροπρόθεσμες εξαρτήσεις το καθιστά ένα από τα πιο ισχυρά εργαλεία στον τομέα της επεξεργασίας σήματος και της επαυξημένης νοημοσύνης[12].

### 1.10.1 Αρχιτεκτονικές Βασισμένες στα LSTM

Οι αρχιτεκτονικές LSTM έχουν αναδειχθεί ως ένα σημαντικό εργαλείο για την πρόβλεψη ταχύτητας ανέμου και την ανάλυση αιολικών πάρκων, κυρίως λόγω της ικανότητάς τους να χειρίζονται δεδομένα χρονοσειρών και να διατηρούν πληροφορίες για εκτεταμένες χρονικές περιόδους. Οι αρχιτεκτονικές LSTM που θα αναλυθούν παρακάτω έχουν αποδειχθεί εξαιρετικά αποτελεσματικές στην πρόβλεψη της ταχύτητας ανέμου και στην ανάλυση αιολικών πάρκων. Η ενσωμάτωση επιπρόσθετων τεχνικών, όπως οι Wavelet Transforms, CNN, Attention Mechanisms, και Feature Selection, μπορούν να βελτιώσουν σημαντικά την απόδοση των μοντέλων πρόβλεψης, προσφέροντας πιο ακριβή αποτελέσματα και μειώνοντας τα σφάλματα πρόβλεψης. Η σωστή προεπεξεργασία των δεδομένων και η επιλογή των κατάλληλων χαρακτηριστικών είναι επίσης σημαντικοί παράγοντες που συμβάλλουν στην επιτυχία των LSTM μοντέλων.

Κάποιες από τις τεχνικές που έχουν χρησιμοποιηθεί είναι:

Ο Zhang στο [27] μελετά τη χρήση LSTM για την πρόβλεψη ταχύτητας ανέμου σε βραχυπρόθεσμο ορίζοντα. Στην δημοσίευση αυτή, χρησιμοποιείται μια αρχιτεκτονική LSTM για την επεξεργασία δεδομένων χρονοσειρών από αιολικά πάρκα στην Κίνα. Τα αποτελέσματα δείχνουν ότι τα μοντέλα LSTM υπερέχουν σε σύγκριση με τις παραδοσιακές μεθόδους πρόβλεψης, όπως τα ARIMA και SVM, προσφέροντας μεγαλύτερη ακρίβεια και μικρότερο σφάλμα πρόβλεψης (MAE και RMSE). Η ικανότητα του LSTM να απομνημονεύει μακροπρόθεσμες εξαρτήσεις αποδεικνύεται κρίσιμη για την αποτελεσματική πρόβλεψη των μεταβαλλόμενων αιολικών συνθηκών.

Σύμφωνα με τον Liu στο [28], μια υβριδική προσέγγιση που συνδυάζει LSTM και μια μέθοδο αποσύνθεσης σήματος (Wavelet Transform) εφαρμόστηκε για την πρόβλεψη της παραγωγής ενέργειας από ανεμογεννήτριες. Η έρευνα αυτή αποδεικνύει ότι η χρήση του Wavelet για την προεπεξεργασία των δεδομένων πριν την εισαγωγή τους στο LSTM βελτιώνει σημαντικά την ακρίβεια της πρόβλεψης. Συγκεκριμένα, τα αποτελέσματα δείχνουν μειωμένα σφάλματα πρόβλεψης (MAPE) σε σύγκριση με τη χρήση μόνο LSTM ή Wavelet Transform. Η δυνατότητα του Wavelet να αποσυνθέτει τα σήματα σε διάφορες συχνότητες επιτρέπει στο LSTM να επικεντρώνεται σε συγκεκριμένα χαρακτηριστικά των δεδομένων.

Ο Chen στο [29] προτείνει μια εξελιγμένη αρχιτεκτονική LSTM, όπου ενσωματώνει εξωτερικές μεταβλητές όπως δεδομένα πρόγνωσης καιρού για την πρόβλεψη της παραγωγής ενέργειας από αιολικά πάρκα. Το μοντέλο αυτό δοκιμάστηκε σε δεδομένα από ανεμογεννήτριες στην Ευρώπη και έδειξε ότι η ενσωμάτωση εξωτερικών μεταβλητών μπορεί να βελτιώσει σημαντικά την πρόβλεψη σε σχέση με τα παραδοσιακά LSTM μοντέλα. Η χρήση εξωτερικών δεδομένων παρέχει επιπλέον πληροφορίες που βοηθούν το μοντέλο να προβλέψει καλύτερα τις μεταβολές της παραγωγής ενέργειας.

Ο Feng στο [30] διερευνά τη χρήση LSTM σε συνδυασμό με τη χρήση Convolutional Neural Networks (CNN) για την ανάλυση και πρόβλεψη της ταχύτητας ανέμου. Η εργασία αυτή προτείνει μια υβριδική αρχιτεκτονική CNN-LSTM που συνδυάζει την ικανότητα των CNN να εξάγουν χαρακτηριστικά από τα δεδομένα και την ικανότητα των LSTM να μοντελοποιούν χρονοσειρές. Τα αποτελέσματα δείχνουν βελτιωμένες επιδόσεις πρόβλεψης σε σύγκριση με την απομονωμένη χρήση των LSTM ή CNN. Η υβριδική αυτή προσέγγιση εκμεταλλεύεται τα πλεονεκτήματα και των δύο αρχιτεκτονικών, οδηγώντας σε πιο ακριβείς προβλέψεις.

Ο Wang στο [31] παρουσιάζει μια μελέτη που συνδυάζει LSTM με Attention Mechanism για την πρόβλεψη της ταχύτητας ανέμου. Αυτή η προσέγγιση επιτρέπει στο μοντέλο να δίνει μεγαλύτερη βαρύτητα σε σημαντικές χρονικές περιόδους ή γεγονότα,

βελτιώνοντας έτσι την ακρίβεια της πρόβλεψης. Η μελέτη δείχνει ότι το LSTM με Attention Mechanism υπερτερεί σε σύγκριση με τα κλασικά LSTM μοντέλα, ιδιαίτερα σε δεδομένα με μεγάλες χρονικές εξαρτήσεις. Το Attention Mechanism βοηθά το μοντέλο να εστιάζει σε σημαντικές πληροφορίες, αυξάνοντας την αποδοτικότητά του.

Επιπλέον, ο He στο [32] αναλύει μια αρχιτεκτονική LSTM για την πρόβλεψη της παραγωγής ενέργειας σε αιολικά πάρκα με δεδομένα χρονοσειρών από ανεμογεννήτριες στη Βόρεια Αμερική. Το μοντέλο ενσωματώνει προσεγγίσεις κανονικοποίησης και δεδομένα καιρού, αποδεικνύοντας ότι οι τεχνικές αυτές βελτιώνουν την ακρίβεια της πρόβλεψης. Η έρευνα υπογραμμίζει τη σημασία της σωστής προεπεξεργασίας των δεδομένων για την επίτευξη καλύτερων αποτελεσμάτων.

Ο Yao στο [33] χρησιμοποιεί μια παραλλαγή της αρχιτεκτονικής LSTM, γνωστή ως Bidirectional LSTM, για την πρόβλεψη της ταχύτητας ανέμου. Η Bidirectional LSTM εκπαιδεύεται τόσο προς τα εμπρός όσο και προς τα πίσω στις χρονοσειρές, προσφέροντας ένα πλεονέκτημα στην κατανόηση της σχέσης μεταξύ των δεδομένων σε διαφορετικές χρονικές στιγμές. Τα αποτελέσματα της έρευνας δείχνουν ότι η Bidirectional LSTM υπερέχει σε σύγκριση με τα παραδοσιακά LSTM, παρέχοντας μεγαλύτερη ακρίβεια και αξιοπιστία στις προβλέψεις.

Τέλος, ο Qiu στο [34] διερευνά τη χρήση LSTM σε συνδυασμό με μια τεχνική Feature Selection για την πρόβλεψη της παραγωγής ενέργειας σε αιολικά πάρκα. Η μελέτη αυτή δείχνει ότι η επιλογή των πιο σημαντικών χαρακτηριστικών από τα δεδομένα εισόδου πριν από την εφαρμογή του LSTM μπορεί να βελτιώσει την ακρίβεια της πρόβλεψης και να μειώσει τον υπολογιστικό χρόνο. Τα αποτελέσματα υποδεικνύουν ότι η κατάλληλη προεπεξεργασία και η επιλογή χαρακτηριστικών είναι κρίσιμα για την αποτελεσματική χρήση των LSTM μοντέλων.

## 1.11 Κύριες Διαφορές των Μοντέλων

Οι διαφορές μεταξύ ενός μοντέλου MLP και ενός μοντέλου LSTM αποκαλύπτουν τις διαφορετικές δυνατότητες και τη χρήση τους σε διαφορετικά προβλήματα μηχανικής μάθησης. Το MLP είναι ένα βασικό feed-forward νευρωνικό δίκτυο, το οποίο αποτελείται από επίπεδα κρυφών νευρώνων που συνδέονται πλήρως με τα επόμενα επίπεδα, χωρίς καμία μνήμη για την προηγούμενη κατάσταση. Από την άλλη πλευρά, το LSTM είναι ένα είδος αναδρομικού νευρωνικού δικτύου, σχεδιασμένο ειδικά για την επεξεργασία σειριακών δεδομένων και τη διατήρηση μνήμης μεγάλων χρονικών διαστάσεων. Η κύρια διαφορά είναι ότι το LSTM χρησιμοποιεί πύλες για τον έλεγχο της μνήμης και της παρεμβολής, επιτρέποντας του να μάθει και να διατηρεί πληροφορίες για περισσότερες χρονικές στιγμές. Ενώ το MLP είναι κατάλληλο για προβλήματα όπως η ταξινόμηση και η παλινδρόμηση, το LSTM είναι ιδανικό για ακολουθιακά δεδομένα όπως τα χρονοσειρές και οι φυσικές γλώσσες. Κάθε ένα από αυτά τα μοντέλα έχει την κατάλληλη εφαρμογή του, ανάλογα με τις απαιτήσεις του προβλήματος [36,39], η φύση τους όμως τα κάνει ιδανικά για την εφαρμογή τους σε μελέτες εκτίμησης τιμών και προβλέψεων.

## 2. Μεθοδολογία

### 2.1 Στατικότητα χρονοσειρών.

Η στατικότητα μιας χρονοσειράς αναφέρεται στην ιδιότητα των στατιστικών της στοιχείων, όπως ο μέσος όρος, η διακύμανση και η συσχέτιση, να παραμένουν σταθερά με την πάροδο του χρόνου. Μια στατική χρονοσειρά σημαίνει ότι τα στατιστικά της στοιχεία δεν αλλάζουν, ανεξάρτητα από το χρονικό σημείο στο οποίο βρισκόμαστε. Αυτή η σταθερότητα μπορεί να περιλαμβάνει σταθερά επίπεδα και μοτίβα που επαναλαμβάνονται, όπως η εποχικότητα ή η διαφορά μεταξύ νυχτερινών και ημερήσιων τιμών. Η ύπαρξη στατικότητας είναι σημαντική στην ανάλυση χρονοσειρών, διότι καθιστά πιο εύκολη την πρόβλεψη μελλοντικών τιμών, αφού τα ιστορικά δεδομένα θεωρούνται αξιόπιστα για την πρόβλεψη του μέλλοντος.

Για να ελέγξουμε αν μια χρονοσειρά είναι στατική, χρησιμοποιούμε διάφορα στατιστικά τεστ. Ένα από τα πιο γνωστά τεστ είναι το Augmented Dickey-Fuller (ADF) τεστ. Το ADF τεστ ελέγχει την ύπαρξη μοναδιαίας ρίζας στη χρονοσειρά. Η μοναδιαία ρίζα υποδηλώνει ότι η χρονοσειρά δεν είναι στατική, καθώς οι στατιστικές ιδιότητες αλλάζουν με την πάροδο του χρόνου. Όσο πιο αρνητικό είναι το αποτέλεσμα του ADF τεστ, τόσο χαμηλότερη είναι η πιθανότητα η χρονοσειρά να έχει μοναδιαία ρίζα, δηλαδή, τόσο μεγαλύτερη είναι η πιθανότητα να είναι στατική[50].

Η στατικότητα είναι κρίσιμη για την ανάλυση και τη μοντελοποίηση χρονοσειρών, καθώς πολλές στατιστικές μέθοδοι και μοντέλα υποθέτουν ότι τα δεδομένα είναι στατικά. Εάν η χρονοσειρά δεν είναι στατική, μπορεί να χρειαστεί να εφαρμόσουμε μετασχηματισμούς, όπως η διαφορά, για να επιτύχουμε στατικότητα. Αυτό βοηθά στη σταθεροποίηση των στατιστικών ιδιοτήτων και διευκολύνει την ανάλυση και την πρόβλεψη. Με την επιβεβαίωση της στατικότητας, μπορούμε να είμαστε πιο βέβαιοι ότι τα αποτελέσματα της ανάλυσης μας θα είναι αξιόπιστα και χρήσιμα για την κατανόηση και πρόβλεψη των τάσεων και των μοτίβων της χρονοσειράς.

Το εργαλείο ADF χρησιμοποιήθηκε και στο σετ δεδομένων της παρούσας διπλωματικής και από τα αποτελέσματα φαίνεται η στατικότητα των δεδομένων. Το ADF λαμβάνει αρνητική τιμή όπως ήταν αναμενόμενο. Οι χρονοσειρές που βασίζονται σε στοιχεία που αφορούν τον αέρα, συνήθως παρουσιάζουν μη στατικότητα. Υπάρχουν κάποιες ιδιαίτερες περιπτώσεις όπου παρατηρούνται σταθερά μοτίβα ταχύτητας αέρα ή σταθερών προσανατολισμών καταλήγοντας έτσι σε στατικά αποτελέσματα.

## 2.2 Μη συγγραμμικότητα των δεδομένων χρονοσειρών που βασίζονται στα στοιχεία του αέρα.

Η συγγραμμικότητα είναι ένα πολύ κρίσιμο στοιχείο στην επιστήμη της Μηχανικής Μάθησης, δείχνει την άμεση συσχέτιση έναν ή περισσότερων μεταβλητών με την αντίστοιχη μεταβλητή-στόχο. Η γραμμικότητα επιτρέπει την χρήση γραμμικών αλγορίθμων για την ανάλυση και πρόβλεψη των δεδομένων που έχουμε κληθεί να μελετήσουμε στη κάθε περίπτωση. Η εύρεση γραμμικότητας στις χρονοσειρές ανέμου είναι ένα πολύ δύσκολο εγχείρημα. Όπως φαίνεται στο [35] μπορεί να παρατηρηθεί

γραμμικότητα σε δεδομένα ανέμου όπως και συσχέτιση με διαφοροποιημένα δεδομένα σε συγκεκριμένες περιπτώσεις. Για τις προβλέψεις σε δεδομένα ανέμου μπορούν να χρησιμοποιηθούν γραμμικά μοντέλα επειδή οι χρονοσειρές ανέμου περιέχουν δομές που παρουσιάζουν γραμμικότητα. Το καλύτερο μοντέλο προβλέψεων θα καταλάβει τις πληροφορίες των εσωτερικών δομών αυτών και θα παράξει αποτελέσματα με μεγαλύτερη ακρίβεια. Για να μπορέσει να γίνει η καλύτερη προσέγγιση στο συγκεκριμένο σετ δεδομένων που μελετάται στη συγκεκριμένη διπλωματική, τα μοντέλα MLP και LSTM έχουν επικαλεστεί για να διαχειριστούν αυτή τη δύσκολη αποστολή.

## 2.3 προεπεξεργασία δεδομένων (preprocessing)

Για να μπορέσει να γίνει η εκπαίδευση των μοντέλων χρειάζονται συνολικά τρεις στήλες από δεδομένα . Οι πρώτες δύο στήλες έχουν ληφθεί από την βάση δεδομένων της Renewable.ninja ενώ η τρίτη πρέπει να κατασκευαστεί .

Για το μοντέλο MLP χρειάζεται μία τρίτη στήλη , ώστε να χρησιμοποιηθεί σαν δεύτερο στοιχείο δεδομένων εισόδου. Η στήλη αυτή είναι η θεωρητική ισχύς της ανεμογεννήτριας η οποία θα μπορέσει να προσφέρει στο μοντέλο MLP τα στοιχεία για να κάνει καλύτερη συσχέτιση μεταξύ των δεδομένων εισόδου και εξόδου.

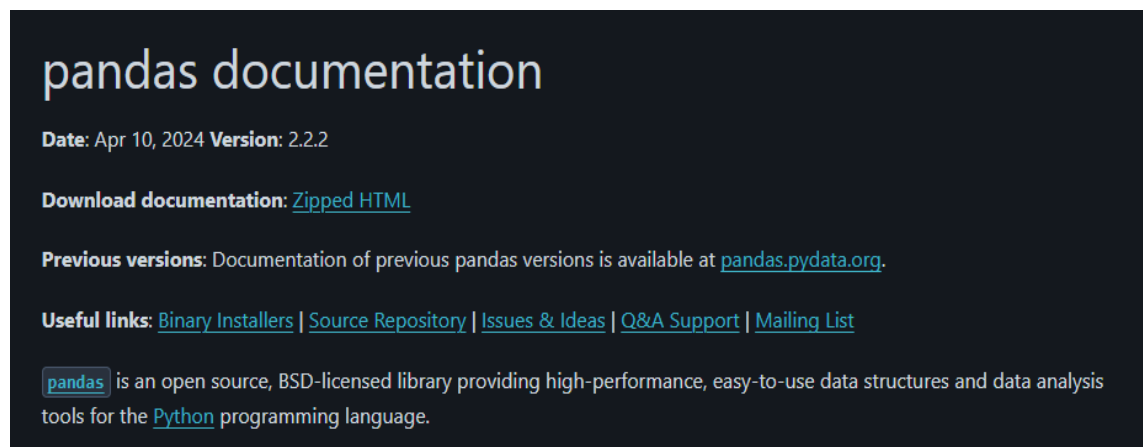
# What is NumPy?

NumPy is the fundamental package for scientific computing in Python. It is a Python library that provides a multidimensional array object, various derived objects (such as masked arrays and matrices), and an assortment of routines for fast operations on arrays, including mathematical, logical, shape manipulation, sorting, selecting, I/O, discrete Fourier transforms, basic linear algebra, basic statistical operations, random simulation and much more.

At the core of the NumPy package, is the `ndarray` object. This encapsulates  $n$ -dimensional arrays of homogeneous data types, with many operations being performed in compiled code for performance. There are several important differences between NumPy arrays and the standard Python sequences:

- NumPy arrays have a fixed size at creation, unlike Python lists (which can grow dynamically). Changing the size of an `ndarray` will create a new array and delete the original.
- The elements in a NumPy array are all required to be of the same data type, and thus will be the same size in memory. The exception: one can have arrays of (Python, including NumPy) objects, thereby allowing for arrays of different sized elements.
- NumPy arrays facilitate advanced mathematical and other types of operations on large numbers of data. Typically, such operations are executed more efficiently and with less code than is possible using Python's built-in sequences.
- A growing plethora of scientific and mathematical Python-based packages are using NumPy arrays; though these typically support Python-sequence input, they convert such input to NumPy arrays prior to processing, and they often output NumPy arrays. In other words, in order to efficiently use much (perhaps even most) of today's scientific/mathematical Python-based software, just knowing how to use Python's built-in sequence types is insufficient - one also needs to know how to use NumPy arrays.

Εικόνα 4: Βιβλιοθήκη NumPy



**pandas documentation**

**Date:** Apr 10, 2024 **Version:** 2.2.2

**Download documentation:** [Zipped HTML](#)

**Previous versions:** Documentation of previous pandas versions is available at [pandas.pydata.org](https://pandas.pydata.org).

**Useful links:** [Binary Installers](#) | [Source Repository](#) | [Issues & Ideas](#) | [Q&A Support](#) | [Mailing List](#)

`pandas` is an open source, BSD-licensed library providing high-performance, easy-to-use data structures and data analysis tools for the [Python](#) programming language.

Εικόνα 5: Βιβλιοθήκη Pandas



Για να γίνει η προσθήκη της στήλης της θεωρητικής ισχύος της ανεμογεννήτριας, χρησιμοποιήθηκε η βιβλιοθήκη Numpy (Εικόνα 4)( <https://numpy.org/> ) και παράλληλα κατασκευάστηκε μία συνάρτηση που χρησιμοποιεί τις τιμές της καμπύλης ισχύος της ανεμογεννήτριας για την αντιστοίχιση των τιμών της ταχύτητας αέρα με την Θεωρητική ισχύ. Εάν η ταχύτητα του ανέμου είναι κάτω από 3 μέτρα ανά δευτερόλεπτο (m/s), η παραγόμενη ισχύς είναι μηδέν. Εάν η ταχύτητα του ανέμου είναι ίση ή μεγαλύτερη από 13,5 m/s, η παραγόμενη ισχύς παραμένει σταθερή στα 2000 KW. Για ταχύτητες ανέμου μεταξύ αυτών των τιμών, η συνάρτηση υπολογίζει την παραγόμενη ισχύ μέσω γραμμικής παρεμβολής μεταξύ των δύο πλησιέστερων σημείων της καμπύλης ισχύος. Συγκεκριμένα, βρίσκει τις δύο πλησιέστερες τιμές ταχύτητας ανέμου (μικρότερη και μεγαλύτερη) και τις αντίστοιχες τιμές ισχύος, και στη συνέχεια υπολογίζει την παραγόμενη ισχύ για την δεδομένη ταχύτητα ανέμου χρησιμοποιώντας γραμμική παρεμβολή. Αφετέρου, έγινε χρήση της βιβλιοθήκης Pandas (Εικόνα5)( <https://pandas.pydata.org/> ) για την κατασκευή και προσθήκη της στήλης στα υπόλοιπα δεδομένα ώστε να ακολουθήσει η εισαγωγή τους μέσα στα μοντέλα εκπαίδευσης.

```

df['local_time'] = pd.to_datetime(df['local_time'])
df.set_index('local_time', inplace=True)
df.drop(['time'], axis=1, inplace=True)
df=df.round(1)
# Constants
density_air = 1.225 # kg/m³ (density of air at sea level)
area_rotor = 6362 # m² (rotor swept area)

# Define wind speeds from 3 to 24 in increments of 0.5
wind_speed_c = [i for i in np.arange(3, 24.5, 0.5)]


# Power curve data
KW_p = [10, 20, 46, 110, 170, 240, 355, 460, 580, 732, 884, 1065, 1245, 1428, 1612, 1756, 1900, 1940, 1968, 1980, 1990, 2000]

# Calculate power output for each wind speed
power_output = []
for wind_speed in wind_speed_c:
    # linear interpolation for simplicity
    index = int(wind_speed * 2) - 6 # Adjust index to correlate with wind speed
    if index < 0:
        power_output.append(0) # Assuming power output is 0 for wind speeds below 3 m/s
    elif wind_speed >= 13.5 and wind_speed <= 24:
        power_output.append(2000) # Assuming power output is constant at 2000 KW for wind speeds between 13.5 and 24 m/s
    elif index >= len(KW_p):
        power_output.append(KW_p[-1]) # Assuming power output is maximum for wind speeds above 24 m/s
    else:
        # Linear interpolation between two closest points on the power curve
        power = KW_p[index]
        power_output.append(power)

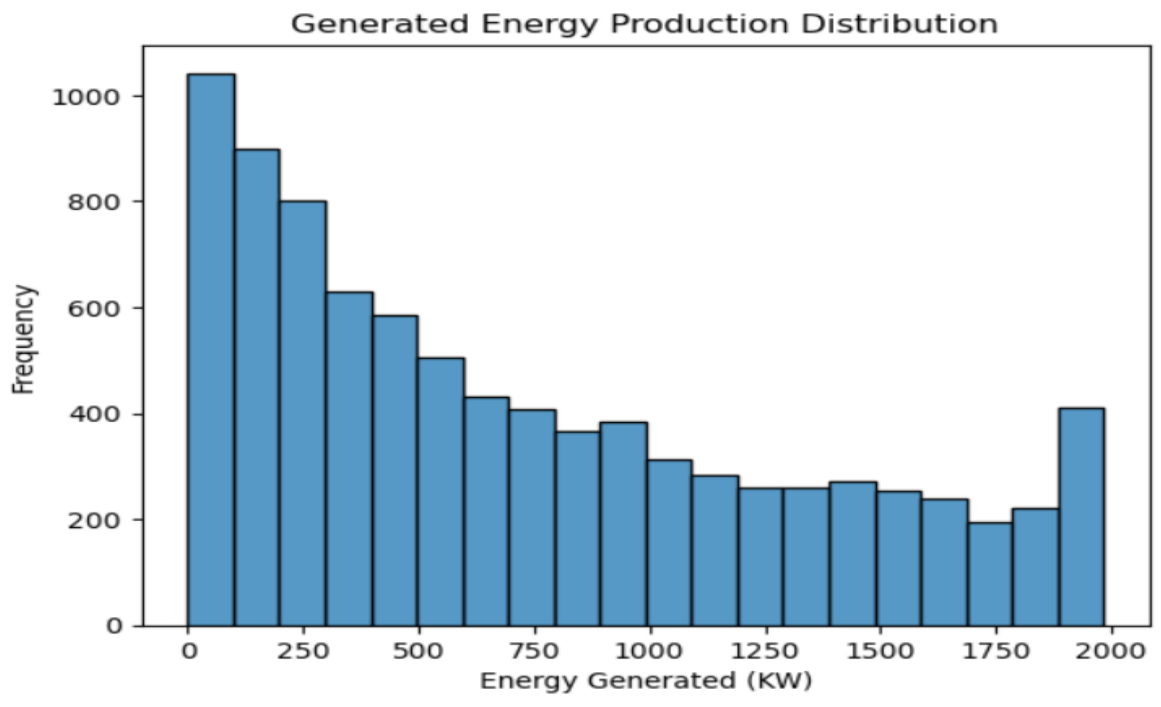
# Create a DataFrame to store wind speed and power output
df1= pd.DataFrame({'wind_speed': wind_speed_c, 'Power Output (KW)': power_output})

```

Εικόνα 6:Κώδικας για την δημιουργία της θεωρητικής καμπύλης ισχύος της ανεμογεννήτριας



Διάγραμμα 3: Καμπύλη ισχύος της ανεμογεννήτριας για κάθε τιμή της ταχύτητας αέρα στο σέτ δεδομένων



Διάγραμμα 4: Συχνότητα εμφάνισης τιμών παραγόμενης Ενέργειας

### 2.3.1 Εργαλείο Augmented Dickey-Fuller

Το Augmented Dickey-Fuller (ADF) test είναι ένα στατιστικό εργαλείο που χρησιμοποιείται για να ελέγξει αν μια χρονοσειρά είναι στάσιμη ή όχι. Λειτουργεί εξετάζοντας την ύπαρξη μοναδιαίας ρίζας στα δεδομένα, η οποία υποδεικνύει μη στασιμότητα. Το test εκτιμά ένα αυτοπαλίνδρομο μοντέλο και ελέγχει τη σημαντικότητα των συντελεστών. Η μηδενική υπόθεση είναι ότι η σειρά έχει μοναδιαία ρίζα (δηλαδή, είναι μη στάσιμη), ενώ η εναλλακτική υπόθεση είναι ότι η σειρά είναι στάσιμη. Το ADF test παράγει μια στατιστική τιμή και μια p-value, οι οποίες συγκρίνονται με κρίσιμες τιμές για να αποφασιστεί αν θα απορριφθεί η μηδενική υπόθεση. Αν η p-value είναι μικρότερη από το επίπεδο σημαντικότητας (συνήθως 0.05), απορρίπτουμε τη μηδενική υπόθεση και συμπεραίνουμε ότι η σειρά είναι στάσιμη. Στην εικόνα 6 φαίνονται τα αποτελέσματα της εφαρμογής του εργαλείου ADF .

Για την ταχύτητα ανέμου (wind\_speed), η ADF στατιστική τιμή είναι -8.40, που είναι πολύ μικρότερη από όλες τις κρίσιμες τιμές (1%: -3.43, 5%: -2.86, 10%: -2.567). Η p-τιμή είναι 2.23e-13, που είναι πολύ μικρότερη από 0.05. Αυτό δείχνει ότι απορρίπτουμε την μηδενική υπόθεση της ύπαρξης μονάδας ρίζας και συμπεραίνουμε ότι τα δεδομένα της ταχύτητας ανέμου είναι σταθερά.

```
ADF Statistic for wind_speed: -8.400894043517521
p-value for wind_speed: 2.2329764965682857e-13
Critical Values:
  1%: -3.431099968539641
  5%: -2.86187143613454
 10%: -2.5669464184887825

ADF Statistic for Theoretical Production (KW): -8.540854674861402
p-value for Theoretical Production (KW): 9.792284570801843e-14
Critical Values:
  1%: -3.431099882538333
  5%: -2.8618713981324873
 10%: -2.56694639826003

ADF Statistic for Energy_Generated: -8.484820635770873
p-value for Energy_Generated: 1.3622632241272052e-13
Critical Values:
  1%: -3.431099882538333
  5%: -2.8618713981324873
 10%: -2.56694639826003
```

Εικόνα 7: Αποτελέσματα του test ADF στα δεδομένα εισόδου και εξόδου.


Για τη θεωρητική παραγωγή Theoretical Production (KW), η ADF στατιστική τιμή είναι -8.54, που είναι επίσης πολύ μικρότερη από όλες τις κρίσιμες τιμές (1%: -3.43, 5%: -2.86, 10%: -2.57). Η p-τιμή είναι 9.79e-14, που είναι επίσης πολύ μικρότερη από 0.05. Συνεπώς, απορρίπτουμε την μηδενική υπόθεση και συμπεραίνουμε ότι τα δεδομένα της θεωρητικής παραγωγής είναι σταθερά.

Για την παραγόμενη ενέργεια Energy\_Generated, η ADF στατιστική τιμή είναι -8.48, και αυτή είναι πολύ μικρότερη από όλες τις κρίσιμες τιμές (1%: -3.43, 5%: -2.86, 10%: -2.57). Η p-τιμή είναι 1.36e-13, που είναι πολύ μικρότερη από 0.05. Αυτό σημαίνει ότι απορρίπτουμε την μηδενική υπόθεση και τα δεδομένα της παραγόμενης ενέργειας είναι σταθερά.

Συμπερασματικά, οι χαμηλές p-τιμές και οι ADF στατιστικές τιμές που είναι μικρότερες από τις κρίσιμες τιμές δείχνουν ότι όλες οι χρονοσειρές δεδομένων (ταχύτητα ανέμου, θεωρητική παραγωγή, και παραγόμενη ενέργεια) είναι σταθερές. Αυτό υποδηλώνει ότι δεν υπάρχει μονάδα ρίζας και τα δεδομένα είναι κατάλληλα για περαιτέρω ανάλυση και μοντελοποίηση χωρίς την ανάγκη μετασχηματισμού για στασιμότητα.

### 2.3.2 Πίνακας συσχέτισης ( Correlation Matrix)

Για τον πίνακα συσχέτισης έγινε η χρήση της βιβλιοθήκης Pandas (εικόνα 4). Τα δεδομένα παρουσιάζουν μεγάλη συσχέτιση μεταξύ τους όπως ήταν αναμενόμενο αφού έχουν άμεση εξαρτώμενη σχέση. Ο πίνακας συσχέτισης παρουσιάζει τους συντελεστές συσχέτισης Pearson μεταξύ των μεταβλητών "ταχύτητα ανέμου" wind\_speed, "θεωρητική παραγωγή" Theoretical Production και "παραγόμενη ενέργεια" Energy\_Generated. Οι τιμές των συντελεστών κυμαίνονται από -1 έως 1, όπου οι τιμές κοντά στο 1 ή -1 υποδηλώνουν ισχυρή συσχέτιση, και οι τιμές κοντά στο 0 υποδηλώνουν αδύναμη ή καθόλου συσχέτιση.



Εικόνα 8: Πίνακας συσχέτισης των δεδομένων

Για την ταχύτητα ανέμου `wind_speed` και τη θεωρητική παραγωγή `Theoretical Production (KW)`, ο συντελεστής συσχέτισης είναι 0.96. Αυτό δείχνει ότι υπάρχει πολύ ισχυρή θετική συσχέτιση μεταξύ της ταχύτητας ανέμου και της θεωρητικής παραγωγής.

Για την ταχύτητα ανέμου `wind_speed` και την παραγόμενη ενέργεια `Energy_Generated`, ο συντελεστής συσχέτισης είναι 0.97. Αυτό δείχνει ότι υπάρχει πολύ ισχυρή θετική συσχέτιση μεταξύ της ταχύτητας ανέμου και της παραγόμενης ενέργειας. Όταν αυξάνεται η ταχύτητα του ανέμου, η παραγόμενη ενέργεια αυξάνεται επίσης.

Για τη θεωρητική παραγωγή `Theoretical Production (KW)` και την παραγόμενη ενέργεια `Energy_Generated`, ο συντελεστής συσχέτισης είναι 0.99. Αυτό δείχνει ότι

υπάρχει εξαιρετικά ισχυρή θετική συσχέτιση μεταξύ της θεωρητικής παραγωγής και της παραγόμενης ενέργειας. Η θεωρητική παραγωγή σχεδόν ευθυγραμμίζεται με την πραγματική παραγόμενη ενέργεια, υποδεικνύοντας ότι η θεωρητική παραγωγή είναι πολύ καλή προσέγγιση της πραγματικής παραγωγής.


Συμπερασματικά, οι υψηλοί συντελεστές συσχέτισης υποδηλώνουν ότι οι μεταβλητές αυτές είναι πολύ στενά συνδεδεμένες μεταξύ τους. Η ισχυρή θετική συσχέτιση μεταξύ της ταχύτητας ανέμου, της θεωρητικής παραγωγής και της παραγόμενης ενέργειας υποδηλώνει ότι η αύξηση της ταχύτητας ανέμου οδηγεί σε αύξηση τόσο της θεωρητικής όσο και της πραγματικής παραγωγής ενέργειας όπως ήταν αναμενόμενο .

### 2.3.3 MinMaxScaler

Κοινό στάδιο και για τους δύο αλγόριθμους που χρησιμοποιήθηκαν είναι η κανονικοποίηση των δεδομένων. Η κανονικοποίηση έγινε κάνοντας χρήση της εντολής “MinMaxScaler” της βιβλιοθήκης Keras. Η Τεχνική αυτή κλιμακώνει και μετασχηματίζει τα χαρακτηριστικά κάνοντας χρήση της γραμμικής αντιστοίχισης σε ένα καθορισμένο εύρος, συνήθως μεταξύ 0 και 1. Υπολογίζει τις ελάχιστες και μέγιστες τιμές κάθε χαρακτηριστικού, και στη συνέχεια τα κλιμακώνει αντίστοιχα, εξαλείφοντας τις αποκλίσεις στις κλίμακες των χαρακτηριστικών. Αυτή η τεχνική είναι χρήσιμη όταν έχουμε δεδομένα με διαφορετικές κλίμακες και θέλουμε να τα φέρουμε σε μια κοινή κλίμακα χωρίς να παραμορφώνουμε τις διαφορές στο εύρος των τιμών. Αυτή η τεχνική χρησιμοποιείται συχνά σε αλγόριθμους ΤΝΔ[36] λόγω της εύκολης εφαρμογής της.

## 2.4 Αρχιτεκτονική Μοντέλου MLP

Το μοντέλο MLP που κατασκευάστηκε για την πρόβλεψη των 48 ωρών έχει τρία στρώματα κρυφών πυκνών επιπέδων νευρώνων. Στην αρχιτεκτονική του μοντέλου, οι συνδέσεις μεταξύ των νευρώνων προσδίδουν την δυνατότητα στο μοντέλο να μάθει πολύπλοκες αναπαραστάσεις δεδομένων. Η χρήση τριών επιπέδων πυκνών νευρωνικών δικτύων αποτελεί κοινή πρακτική σε προβλήματα μηχανικής μάθησης. Η επιλογή αυτού του αριθμού επιπέδων συνήθως βασίζεται στην πολυπλοκότητα του προβλήματος και στη διαθέσιμη ποσότητα δεδομένων εκπαίδευσης.



Διάγραμμα 5: Αναπαράσταση του ΤΝΔ που κατασκευάστηκε για την πειραματική διαδικασία

Η χρήση της συνάρτησης ενεργοποίησης ReLU επιτρέπει την αποτελεσματική αντιμετώπιση του προβλήματος της εξαφάνισης τους και της υπερεκπαίδευσης, καθώς επιτρέπει την αντιστοίχιση μη γραμμικών συναρτήσεων στα δεδομένα εισόδου και εξόδου[40]. Επιπλέον, η προσθήκη κανονικοποίησης (L2 regularization) στα βάρη των επιπέδων βοηθά στη μείωση του φαινομένου της υπερεκπαίδευσης καθώς προσθέτει έναν όρο περιορισμού στην αύξηση των βαρών του μοντέλου και συμβάλλοντας στη γενίκευση των προβλέψεών του [41]. Η επιλογή του optimizer στην εκπαίδευση είναι κρίσιμη για την επίτευξη καλών αποτελεσμάτων. Ο αλγόριθμος Adam έχει αποδειχθεί αποτελεσματικός σε πολλές εφαρμογές λόγω της ικανότητάς του να συνδυάζει την ταχεία σύγκλιση με την αποφυγή των τοπικών ελάχιστων. Ο Adam εκμεταλλεύεται τις ιδέες της αποθήκευσης και της εκθετικής καταβύθισης για να προσαρμόσει το ρυθμό μάθησης σε κάθε βήμα εκπαίδευσης, βελτιώνοντας έτσι την ταχύτητα και την αποτελεσματικότητα της διαδικασίας.[42] Τέλος, η τεχνική Early Stopping αποτελεί έναν έξυπνο μηχανισμό για τον αυτόματο τερματισμό της εκπαίδευσης μόλις η απόδοση του μοντέλου αρχίσει να υποβαθμίζεται. Αυτό είναι κρίσιμο για την αποφυγή της υπερεκπαίδευσης, επιτρέποντας

στο μοντέλο να γενικεύει καλύτερα σε νέα δεδομένα και να προσφέρει πιο αξιόπιστες προβλέψεις.[43]

Η επιλογή του αριθμού των νευρώνων σε κάθε επίπεδο νευρωνικού δικτύου είναι ένα σημαντικό βήμα στον σχεδιασμό ενός μοντέλου μηχανικής μάθησης. Συχνά, οι προγραμματιστές και οι ερευνητές επιλέγουν τον αριθμό των νευρώνων να είναι πολλαπλάσιο του 2 για λόγους αποδοτικότητας και ευκολίας στον υπολογισμό [47]. Αυτό δεν είναι κάτι τυχαίο, αλλά συνήθως βασίζεται σε αρχές που στηρίζονται στη θεωρία και την πρακτική εφαρμογή. Ένας από τους λόγους που η επιλογή του αριθμού των νευρώνων να είναι δύναμη του 2 είναι η βελτιστοποίηση των πράξεων που εκτελούνται σε διάφορα επίπεδα του δικτύου. Οι περισσότεροι σύγχρονοι επεξεργαστές υπολογιστών (CPU, GPU) είναι βελτιστοποιημένοι για πράξεις που εκτελούνται σε διαστάσεις που είναι δύναμη του 2, όπως 2, 4, 8, 16, κ.λπ. Αυτό σημαίνει ότι, όταν ο αριθμός των νευρώνων είναι δύναμη του 2, οι πράξεις μπορούν να εκτελεστούν πιο αποτελεσματικά από τον επεξεργαστή [40]. Επιπλέον, η επιλογή αυτή μπορεί να σχετίζεται και με την αρχιτεκτονική των δικτύων. Για παράδειγμα, σε πολλές αρχιτεκτονικές, όπως οι αρχιτεκτονικές CNN (Convolutional Neural Networks), η χρήση φίλτρων και πινάκων σε διαστάσεις που είναι δύναμη του 2 επιτρέπει την αποτελεσματική εφαρμογή συνεκτικών και μετασχηματιστικών λειτουργιών, κάνοντας τον υπολογισμό πιο άμεσο [49].

## 2.5 Αρχιτεκτονική Μοντέλου LSTM

Η αρχιτεκτονική του μοντέλου βασίζεται σε μια στοίβα επιπέδων LSTM (Long Short-Term Memory), σχεδιασμένης για την αντιμετώπιση χρονοσειρών ή άλλων δεδομένων που παρουσιάζουν μεγάλη χρονική εξάρτηση. Τα επίπεδα LSTM είναι συνδεδεμένα σειριακά, με το κάθε ένα να επιστρέφει την ακολουθία των εξόδων του, εκτός από το τελευταίο, το οποίο επιστρέφει μόνο την τελευταία έξοδο[36]. Η επιλογή της συνάρτησης ενεργοποίησης ‘Sigmoid’ στα επίπεδα LSTM επιτρέπει την προσθήκη μιας πύλης εισόδου, μιας πύλης εξόδου και μιας πύλης ενημέρωσης, που ελέγχουν τη ροή των πληροφοριών μέσα στο κελί μνήμης. Αυτό επιτρέπει την αποθήκευση και την ανάκληση πληροφοριών σε πολύ μεγάλα χρονικά διαστήματα [44]. Η συνάρτηση ενεργοποίησης ‘Relu’ χρησιμοποιείται για την αύξηση της εκμάθησης πολύπλοκων σχέσεων.



Ανάμεσα από κάθε επίπεδο LSTM έχουν τοποθετηθεί επίπεδα Dropout για την αντιμετώπιση της υπερεκπαίδευσης (overtraining). Η υπερεκπαίδευση είναι μια κοινή πρόκληση στην εκπαίδευση νευρωνικών δικτύων, όπου το μοντέλο είναι πολύ προσαρμοσμένο (overfitting) στα δεδομένα εκπαίδευσης και αδυνατεί να γενικεύσει σε νέα δεδομένα. Η τεχνική Dropout αποτελεί μια μορφή κανονικοποίησης που επιτρέπει την απενεργοποίηση τυχαίων νευρώνων κατά την εκπαίδευση, με σκοπό να αποτρέψει την εξάρτηση μεταξύ των νευρώνων και να διατηρήσει τη γενικότητα του μοντέλου [45].

Η συμπερίληψη ενός πυκνού επιπέδου με έναν νευρώνα στο τέλος του μοντέλου αναλαμβάνει την επίλυση του τελικού προβλήματος πρόβλεψης. Αυτό το επίπεδο είναι υπεύθυνο για την μετατροπή των εξόδων των LSTM επιπέδων σε μια μορφή που μπορεί να χρησιμοποιηθεί για την πρόβλεψη της επόμενης τιμής. Η επιλογή της συνάρτησης ενεργοποίησης σε αυτό το επίπεδο είναι η προκαθορισμένη linear, καθώς η έξοδος του πρέπει να είναι σε συνεχή μορφή, χωρίς περαιτέρω μετασχηματισμούς [46].

Τέλος, το μοντέλο συντίθεται με τη χρήση του optimizer Adam για τη βελτιστοποίηση των βαρών του μοντέλου όπως έγινε και στο μοντέλο MLP παραπάνω. Ο optimizer Adam, όπως είδαμε και στην αρχιτεκτονική του MLP, είναι ένας αποτελεσματικός αλγόριθμος που συνδυάζει την ιδέα της κατάστασης του στοχαστικού λογισμού κλίσης με το κλασικό μεταβατικό βήμα της κατάστασης σε κάθε ενεργοποίηση του μοντέλου[42].

## 2.6 Εκπαίδευση μοντέλων και Αξιολόγηση

### 2.6.1 Εκπαίδευση

Η εκπαίδευση των μοντέλων στο πλαίσιο της μηχανικής μάθησης κατέχει έναν κεντρικό ρόλο, καθώς αποτελεί τη διαδικασία μέσω της οποίας τα μοντέλα αναπτύσσουν την ικανότητά να αντλούν γνώση από τα δεδομένα. Είναι η φάση σε όλη την εφαρμογή μηχανικής μάθησης στην ανάλυση του αντικειμένου μελέτης όπου τα μοντέλα μάθησης καθοδηγούνται να προσαρμόσουν τις εσωτερικές τους παραμέτρους μέσω της εκπαίδευσης. Στόχος είναι η βελτίωση της απόδοσής τους στην πρόβλεψη ή την αναγνώριση προτύπων-μοτίβων. Η σημασία της εκπαίδευσης των μοντέλων

αναδεικνύεται στην ικανότητά τους να εξάγουν ακριβείς προβλέψεις για νέα δεδομένα, βασιζόμενα στην κατανόηση που αποκτούν από τα δεδομένα εκπαίδευσης που έχουν ήδη επεξεργαστεί. Κάθε επανάληψη της διαδικασίας εκπαίδευσης επιτρέπει στα μοντέλα να βελτιώσουν τις προβλέψεις τους και να προσαρμόσουν τις εσωτερικές τους παραμέτρους για μεγαλύτερη ακρίβεια.

Κρίνεται σημαντικό να σημειωθεί πως ο τρόπος με τον οποίο εκπαιδεύονται τα μοντέλα διαφέρει ανάλογα με τον τύπο του μοντέλου και τις ανάγκες της εφαρμογής. Για παράδειγμα, τα MLP εκπαιδεύονται συνήθως μέσω μεθόδων επιβλεπόμενης μάθησης, όπου το μοντέλο προσαρμόζει τα βάρη του προς την κατεύθυνση της μείωσης του σφάλματος (loss function) μεταξύ των προβλέψεων και των πραγματικών τιμών. Η διαδικασία επαναλαμβάνεται πολλές φορές, με το μοντέλο να βελτιώνει σταδιακά την ακρίβειά του. Παρακάτω έχει δημιουργηθεί ένας πίνακας για την απεικόνιση των δεδομένων που χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου MLP.

Training data for the MLP		
Input1 for MLP	Input2 for MLP	Output for MLP
Wind speed(m/s)	Theoretical Power (KW)	Actual Power Output (KW)
Num. of data : 8712	Num. of data : 8712	Num. of data : 8712
Test data for the MLP		
Input1 for MLP	Input2 for MLP	Output for MLP
Wind speed(m/s)	Theoretical Power (KW)	Actual Power Output (KW)
Num. of data : 48	Num. of data : 48	Num. of data : 48

Πίνακας 1: Δεδομένα εκπαίδευσης και ελέγχου του μοντέλου MLP

Αντίθετα, τα αναδρομικά νευρωνικά Μοντέλα πχ (LSTM) εκπαιδεύονται για να αντιληφθούν τις μακροπρόθεσμες εξαρτήσεις σε χρονοσειρές δεδομένων. Η εκπαίδευση εστιάζεται στην ανάλυση των ιστορικών τιμών και την κατανόηση των συμπεριφορών των χρονοσειρών. Τα LSTM μοντέλα εκμαθαίνουν την πληροφορία από τις προηγούμενες τιμές και τη χρησιμοποιούν για την πρόβλεψη μελλοντικών τιμών. Η χρήση μνήμης κατά τη διαδικασία της εκπαίδευσης, τους επιτρέπει να αντιμετωπίσουν αποτελεσματικά το πρόβλημα της διαρκούς αλληλουχίας των δεδομένων.

Η εκπαίδευση των μοντέλων αποτελεί θεμέλιο στην επίτευξη της ακρίβειας και της αποτελεσματικότητάς τους. Αν και η διαδικασία είναι διαφορετική για κάθε τύπο μοντέλου, η σημασία της είναι ίδια: την απόκτηση γνώσης από τα δεδομένα προκειμένου να γίνουν ακριβείς προβλέψεις για νέα δεδομένα (test data or new data).

Training data for the LSTM	
Input	Output
Actual Power Output (KW)	Actual Power Output (KW)
Num. of data : 8712	Num. of data : 8712
Test data for the LSTM	
Input	Output
Actual Power Output (KW)	Actual Power Output (KW)
Num. of data : 0	Num. of data : 48

Πίνακας 2: Δεδομένα εκπαίδευσης και ελέγχου του μοντέλου LSTM

## 2.6.2. Αξιολόγηση των Μοντέλων

Η αξιολόγηση των μοντέλων αποτελεί ένα κρίσιμο στάδιο στην μηχανική μάθηση, καθώς παρέχει πληροφορίες σχετικά με την απόδοση των μοντέλων και την ικανότητά τους να γενικεύουν σε νέα δεδομένα. Η αξιολόγηση μπορεί να γίνει με διάφορες μεθόδους, μεταξύ των οποίων συμπεριλαμβάνονται το Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error), το R-squared, το Μέσο Απόλυτο Σφάλμα (Mean Absolute Error) και η διακύμανση (variance). Η χρήση των παραπάνω κριτηρίων για την αξιολόγηση των μοντέλων επιτρέπει στους ερευνητές και τους προγραμματιστές να κατανοήσουν την απόδοσή των μοντέλων τους και την ικανότητά τους να γενικεύουν σε νέα δεδομένα. Κάθε μέθοδος παρέχει μια διαφορετική οπτική για την απόδοση του μοντέλου, ενώ η συνδυασμένη χρήση τους μπορεί να οδηγήσει σε μια πιο πλήρη κατανόηση του προβλήματος και της απόδοσης του μοντέλου.

Το Μέσο Τετραγωνικό Σφάλμα (MSE) είναι μια τεχνική αξιολόγησης που μετρά το μέσο τετραγωνικό σφάλμα μεταξύ των πραγματικών και των προβλεπόμενων τιμών. Η χαμηλότερη τιμή του MSE υποδηλώνει καλύτερη προσαρμογή του μοντέλου στα

δεδομένα. Η εφαρμογή του MSE στην αξιολόγηση των μοντέλων επιτρέπει την παρακολούθηση της ακρίβειας των προβλέψεων τους και την εκτίμηση του βαθμού σφάλματος. Η τεχνική αυτή χρησιμοποιείται πολύ συχνά από προγραμματιστές και ερευνητές ως κριτήριο αξιολόγησης καθώς αποτελεί έναν εύκολο τρόπο γενίκευσης των αποτελεσμάτων.

$$MSE = \frac{1}{n} * \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

Το  $R^2$ , ή Συντελεστής Προσδιορισμού, αντιπροσωπεύει το ποσοστό της διακύμανσης στην εξαρτημένη μεταβλητή (dependent variable) που μπορεί να εξηγηθεί από τις ανεξάρτητες μεταβλητές (independent variables). Ένα υψηλό  $R^2$  υποδεικνύει ισχυρή συσχέτιση μεταξύ των μεταβλητών και μια καλή εφαρμογή του μοντέλου στα δεδομένα. Το  $R^2$  μπορεί να προσδιοριστεί χρησιμοποιώντας τον τύπο:

$$R^2 = 1 - \frac{\text{Unexplained variation}}{\text{explained variation}} \quad (8)$$

Το Μέσο Απόλυτο Σφάλμα (Mean Absolute Error - MAE) είναι ένα μέτρο της ακρίβειας ενός μοντέλου πρόβλεψης. Υπολογίζεται ως ο μέσος όρος των απόλυτων διαφορών μεταξύ των πραγματικών τιμών και των προβλεπόμενων τιμών. Το MAE παρέχει μια ένδειξη του πόσο μακριά είναι οι προβλέψεις από τις πραγματικές τιμές, με χαμηλότερες τιμές να υποδηλώνουν καλύτερη απόδοση του μοντέλου.

$$MAE = \frac{1}{n} * \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

### 3.Αποτελέσματα

Σε αυτό το κεφάλαιο θα αναλυθούν τα ευρήματα της ανάλυσης που έγινε. Θα αξιολογηθεί η απόδοση των μοντέλων, η λειτουργικότητά τους και θα παρουσιαστούν πίνακες με τις πραγματικές τιμές και τις τιμές προβλέψεων που έγιναν από τα μοντέλα. Τέλος θα συμπεριληφθούν διαγράμματα που δείχνουν τις προβλέψεις που έγιναν από τα μοντέλα για 48 ώρες μπροστά.

### 3.1 Αποτελέσματα πρόβλεψης MLP

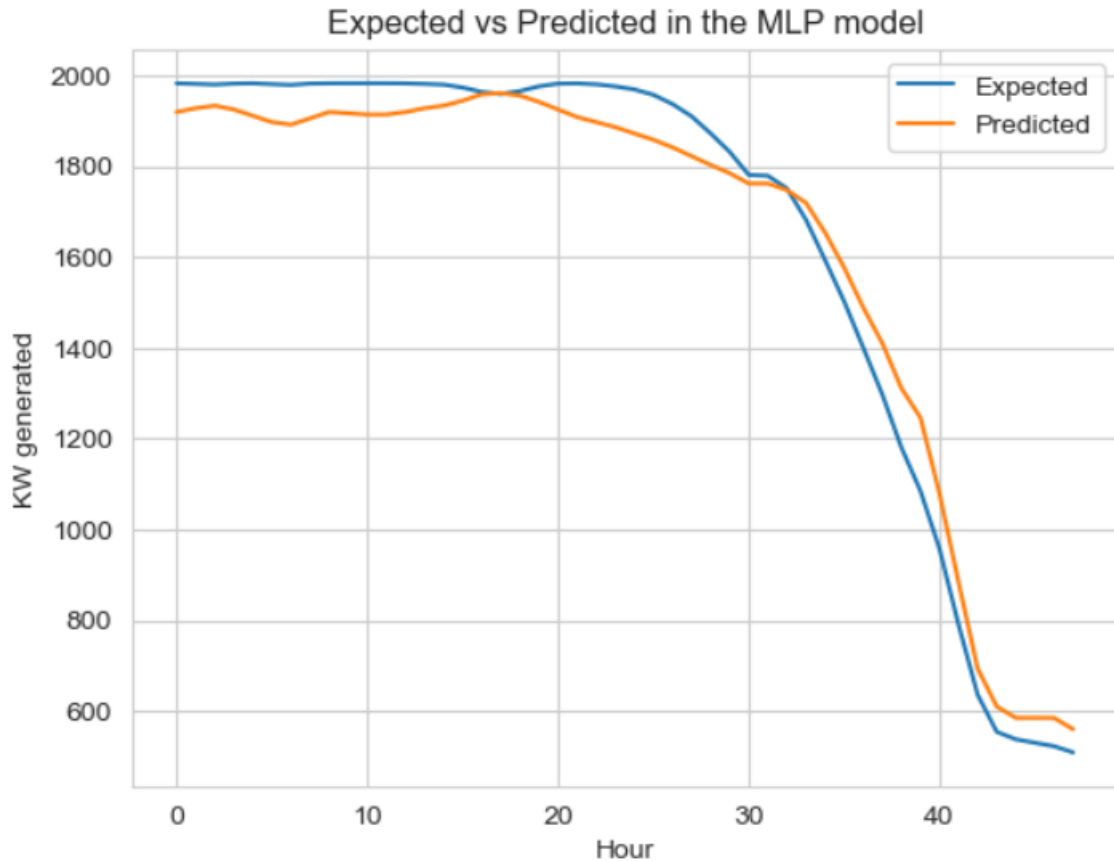
Για την κατανόηση των αποτελεσμάτων του MLP μοντέλου που εκπαιδεύτηκε , αναλύεται παρακάτω τι σημαίνουν οι συγκεκριμένες μετρικές και πόσο καλά αποδίδει το μοντέλο , με έμφαση στη σημασία των δεδομένων εισόδου και εξόδου.

Το Μέσο Απόλυτο Σφάλμα (MAE) είναι 64.52KW. Αυτή η τιμή υποδηλώνει ότι κατά μέσο όρο, η πρόβλεψη του μοντέλου για την παραγόμενη ενέργεια από την ανεμογεννήτρια αποκλίνει κατά περίπου 64.52 μονάδες από τις πραγματικές τιμές. Αυτό το σφάλμα είναι αρκετά χαμηλό, υποδεικνύοντας καλή απόδοση του μοντέλου.

Το Τετραγωνικό Μέσο Σφάλμα (RMSE) είναι 72.16KW. Αυτή η τιμή είναι ελαφρώς υψηλότερη από το MAE, λόγω της ευαισθησίας του RMSE σε μεγαλύτερα σφάλματα. Ωστόσο, εξακολουθεί να υποδηλώνει μια καλή προσαρμογή, καθώς τα μεγαλύτερα σφάλματα δεν είναι τόσο συχνά.

Το  $R^2$  score είναι 0.9797. Αυτή η υψηλή τιμή δείχνει ότι το μοντέλο εξηγεί περίπου το 97.97% της διακύμανσης στην παραγόμενη ενέργεια, που είναι εξαιρετικά υψηλό και υποδεικνύει ότι το μοντέλο έχει κατανοήσει πολύ καλά τις σχέσεις μεταξύ των εισόδων (ταχύτητα ανέμου και θεωρητική ισχύ) και της εξόδου (πραγματική παραγόμενη ενέργεια).

Οι τιμές των μεθόδων αξιολόγησης υποδεικνύουν ότι το MLP μοντέλο που εκπαιδεύτηκε έχει πολύ καλή απόδοση στη πρόβλεψη της πραγματικής παραγόμενης ενέργειας από την ανεμογεννήτρια. Το υψηλό  $R^2$  score, σε συνδυασμό με τα χαμηλά MAE και RMSE, δείχνουν ότι οι προβλέψεις του μοντέλου είναι κοντά στις πραγματικές τιμές, με ελάχιστα και μικρά σφάλματα.



Διάγραμμα 6:48ωρη πρόβλεψη του μοντέλου MLP

### 3.2 Αποτελέσματα μοντέλου LSTM

Το LSTM μοντέλο εκπαιδεύτηκε με δεδομένα χρονοσειρών, που περιλαμβάνουν μόνο την πραγματική παραγόμενη ισχύ από την ανεμογεννήτρια. Αυτό σημαίνει ότι το μοντέλο μαθαίνει να προβλέπει την παραγόμενη ισχύ χρησιμοποιώντας μόνο τις προηγούμενες τιμές της ίδιας μεταβλητής, χωρίς πρόσθετες εξωτερικές εισόδους όπως η ταχύτητα του ανέμου ή η θεωρητική τιμή ισχύος πράγμα που έγινε στο MLP μοντέλο.

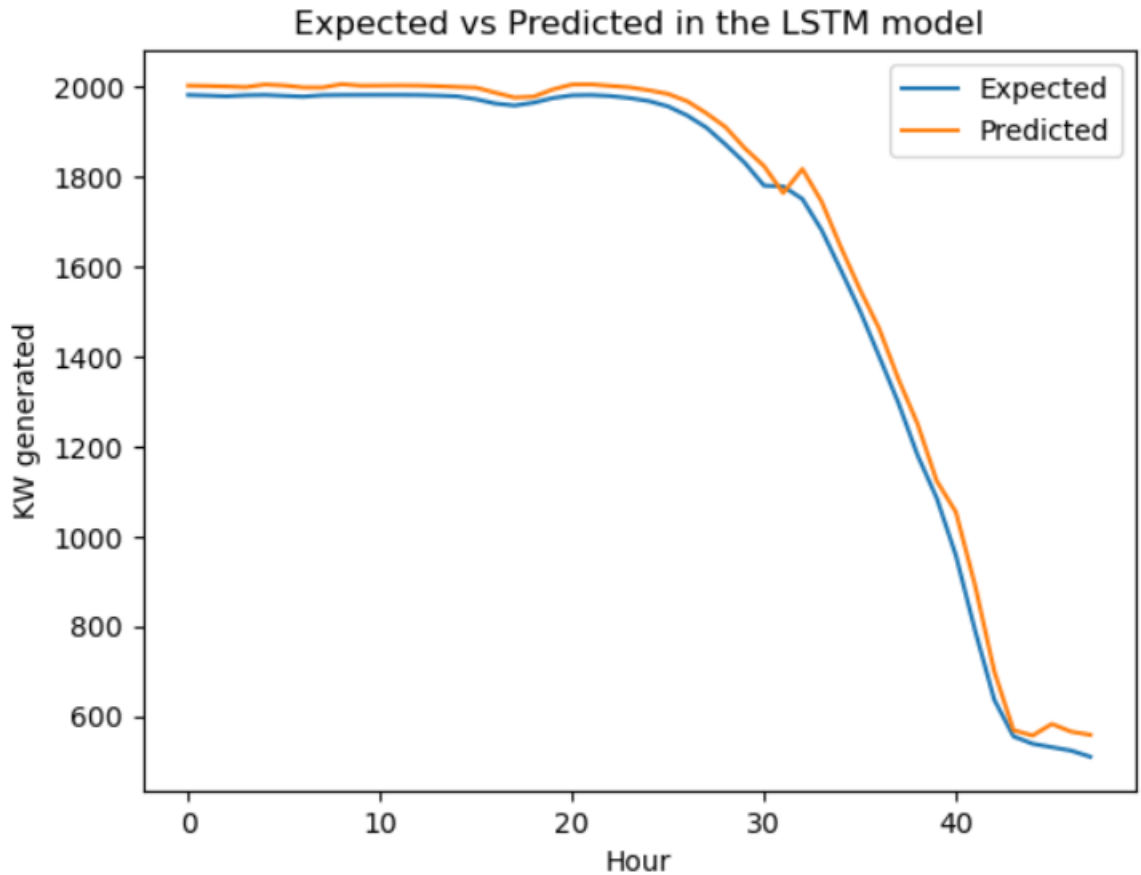
Το Μέσο Απόλυτο Σφάλμα (MAE) είναι 34.22KW. Αυτή η τιμή υποδηλώνει ότι κατά μέσο όρο, η πρόβλεψη του μοντέλου για την παραγόμενη ισχύ από την ανεμογεννήτρια αποκλίνει κατά περίπου 34.22 μονάδες από τις πραγματικές τιμές. Αυτό το σφάλμα είναι αρκετά χαμηλό, υποδεικνύοντας καλή απόδοση του μοντέλου.

Το Τετραγωνικό Μέσο Σφάλμα (RMSE) είναι 39.82KW. Αυτή η τιμή είναι επίσης χαμηλή και υποδεικνύει ότι οι μεγαλύτερες αποκλίσεις από τις προβλεπόμενες τιμές είναι σπάνιες. Η χαμηλή τιμή του RMSE σε σύγκριση με το MAE υποδηλώνει ότι τα σφάλματα δεν είναι συχνά μεγάλα, διατηρώντας την ακρίβεια του μοντέλου.

Το  $R^2$  score είναι 0.9938. Αυτή η πολύ υψηλή τιμή δείχνει ότι το μοντέλο εξηγεί περίπου το 99,38% της διακύμανσης στην παραγόμενη ισχύ. Αυτό υποδηλώνει ότι το μοντέλο έχει εξαιρετική προσαρμογή στα δεδομένα και είναι πολύ ικανό στο να προβλέπει την μελλοντική παραγόμενη ισχύ με βάση τις προηγούμενες τιμές.

Η φύση των χρονοσειρών σημαίνει ότι το LSTM μοντέλο είναι σχεδιασμένο να εκμεταλλεύεται την ακολουθία και τη χρονική εξάρτηση των δεδομένων. Οι χαμηλές τιμές MAE και RMSE, σε συνδυασμό με το υψηλό  $R^2$  score, δείχνουν ότι το μοντέλο μπορεί να παρακολουθεί τις μεταβολές και τις τάσεις στην παραγωγή ισχύος με μεγάλη ακρίβεια.

Όπως υποδηλώνουν και οι τιμές των παραπάνω μεθόδων αξιολόγησης, το LSTM μοντέλο έχει πολύ υψηλή απόδοση στην πρόβλεψη της παραγόμενης ισχύος από την ανεμογεννήτρια. Το υψηλό  $R^2$  score, μαζί με τα χαμηλά MAE και RMSE, δείχνουν ότι οι προβλέψεις του μοντέλου είναι εξαιρετικά κοντά στις πραγματικές τιμές, με ελάχιστα και μικρά σφάλματα. Αυτή η απόδοση είναι εντυπωσιακή δεδομένου ότι το μοντέλο χρησιμοποιεί μόνο την ίδια τη χρονοσειρά της παραγόμενης ισχύος χωρίς επιπλέον εξωτερικές εισόδους.



Διάγραμμα 7:Αποτελέσματα 48ωρης πρόβλεψης του LSTM μοντέλου.

### 3.3 Σύγκριση Αποτελεσμάτων

Συγκρίνοντας τα αποτελέσματα των δύο μοντέλων, παρατηρούμε σημαντικές διαφορές στις μετρικές τους, που υποδηλώνουν διαφορές στην απόδοση και την ικανότητα πρόβλεψης κάθε μοντέλου.


Metrics	LSTM	MLP
MAE	34.22KW	64.52KW
RMSE	39.82KW	72.16KW
R <sup>2</sup>	0.99	0.98

Το MLP μοντέλο, το οποίο εκπαιδεύτηκε με δεδομένα εισόδου την ταχύτητα του ανέμου και τη θεωρητική απόδοση ισχύος της ανεμογεννήτριας, παρουσιάζει Μέσο

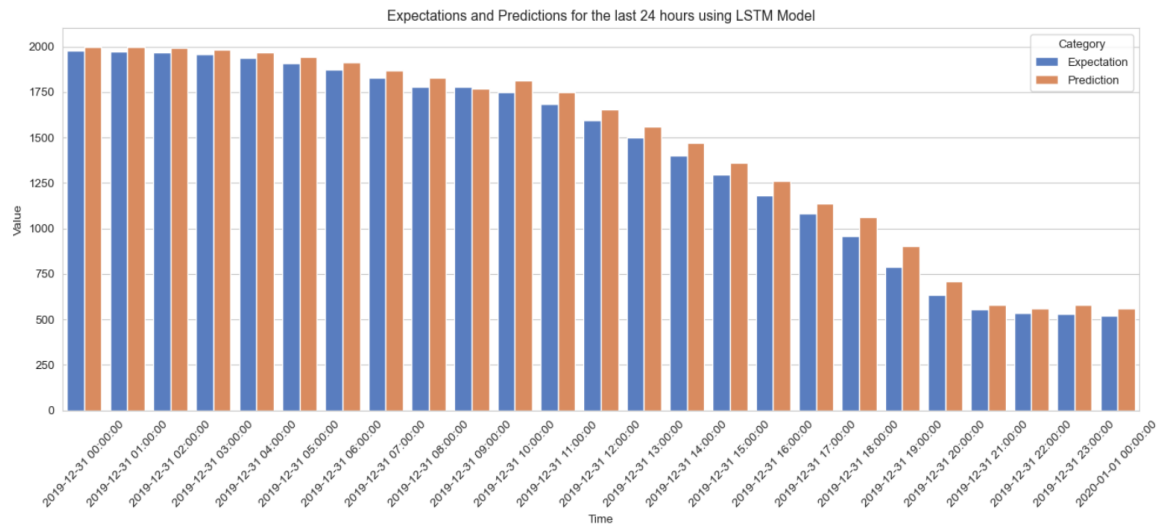


Απόλυτο Σφάλμα (MAE) 64.52KW και Τετραγωνικό Μέσο Σφάλμα (RMSE) 72.16KW, με ένα  $R^2$  score 0.9797. Αυτές οι τιμές δείχνουν ότι το μοντέλο αποδίδει καλά, με τις προβλέψεις του να είναι αρκετά κοντά στις πραγματικές τιμές. Το MLP μοντέλο χρησιμοποιεί στατικές εισόδους για να κάνει τις προβλέψεις του, και αυτό μπορεί να είναι περιοριστικό, καθώς δεν μπορεί να εκμεταλλευτεί πλήρως τις χρονικές εξαρτήσεις και τάσεις των δεδομένων. Αντίθετα, το LSTM μοντέλο, το οποίο εκπαιδεύτηκε μόνο με τη χρονοσειρά της πραγματικής παραγόμενης ισχύος από την ανεμογεννήτρια, παρουσιάζει σημαντικά χαμηλότερα σφάλματα: MAE 34.22 και RMSE 39.83, με ένα εντυπωσιακά υψηλό  $R^2$  score 99.4%. Αυτές οι τιμές υποδηλώνουν ότι το LSTM μοντέλο έχει καλύτερη ακρίβεια στις προβλέψεις του, καταφέρνοντας να εξηγήσει σχεδόν όλη τη διακύμανση στα δεδομένα της παραγόμενης ισχύος. Το LSTM μοντέλο, χάρη στην αρχιτεκτονική του, είναι ικανό να καταγράφει και να εκμεταλλεύεται τις χρονικές εξαρτήσεις και τα μοτίβα στα δεδομένα, κάτι που του δίνει ένα σαφές πλεονέκτημα στην πρόβλεψη χρονοσειρών.

Η διαφορά στην απόδοση των δύο μοντέλων μπορεί επίσης να αποδοθεί στην πολυπλοκότητα και την ικανότητα μάθησης κάθε μοντέλου. Το LSTM μοντέλο, ως μέρος της οικογένειας των αναδραστικών νευρωνικών δικτύων (RNN), έχει την ικανότητα να διατηρεί πληροφορίες για μεγαλύτερα χρονικά διαστήματα και να μαθαίνει πιο σύνθετες σχέσεις από τα δεδομένα χρονοσειρών. Επιπλέον, η χρήση διαφορετικών ειδών δεδομένων εισόδου παίζει επίσης ρόλο. Το MLP χρησιμοποιεί την ταχύτητα του ανέμου και τη θεωρητική απόδοση ισχύος, δεδομένα που είναι σημαντικά αλλά ενδέχεται να μην αποτυπώνουν πλήρως τις λεπτομέρειες της παραγόμενης ισχύος σε σχέση με την πραγματική παραγωγή ενέργειας. Από την άλλη, το LSTM μοντέλο βασίζεται αποκλειστικά στην πραγματική παραγόμενη ισχύ, αξιοποιώντας άμεσα τις προηγούμενες τιμές για να κάνει τις προβλέψεις του. Αν υπήρχαν στοιχεία σχετικά με τα ποσοστά αιολικού δυναμικού της περιοχής καθώς και τον προσανατολισμό των ρευμάτων αέρα θα μπορούσαν να δώσουν στο μοντέλο MLP τη δυνατότητα να κάνει καλύτερες προβλέψεις πιο κοντά στην ακρίβεια που πετυχαίνει το LSTM μοντέλο.



Διάγραμμα 8: τελευταίες 24 ώρες της αρχικής πρόβλεψη για το MLP μοντέλο.



Διάγραμμα 9:τελευταίες 24 ώρες της αρχικής πρόβλεψη για το LSTM μοντέλο.

Παραπάνω γίνεται μία έμφαση στις τελευταίες 24 ώρες του 48ωρου διαστήματος προβλέψεων του κάθε μοντέλου. Στα παραπάνω διαγράμματα φαίνονται καλύτερα οι διαφορές στις τιμές πρόβλεψης και στις πραγματικές τιμές του κάθε μοντέλου. Επιλέχθηκαν οι τελευταίες 24 ώρες επειδή η πτώση της παραγόμενης ενέργειας κάνει πιο δύσκολη την εκτίμηση τιμών λόγω της συνεχόμενης μεταβλητότητας της.

Συνολικά, τα αποτελέσματα δείχνουν ότι το LSTM μοντέλο υπερέχει σαφώς σε αυτή την περίπτωση χρήσης, παρέχοντας πιο ακριβείς και αξιόπιστες προβλέψεις της παραγόμενης ισχύος της ανεμογεννήτριας. Οι χαμηλότερες τιμές MAE και RMSE, σε

συνδυασμό με το υψηλότερο  $R^2$  score, υποδεικνύουν ότι το LSTM μοντέλο είναι πιο αποτελεσματικό και προσαρμοστικό στην πρόβλεψη χρονοσειρών, καθιστώντας το μια καλύτερη επιλογή.

## 4. Προτάσεις- Επόμενα βήματα

Τα δύο μοντέλα ανταποκρίθηκαν πολύ καλά στα δεδομένα που χρησιμοποιήθηκαν. Ωστόσο, η απόδοσή τους σε διαφορετικά δεδομένα είναι αβέβαιη, καθώς μπορεί να υπάρχουν διαφορές στον όγκο των δεδομένων, στη συχνότητα παρατήρησης των τιμών, κλπ. Επιπλέον, αν προστεθούν περισσότεροι τύποι δεδομένων, όπως αιολικό δυναμικό, διαστήματα συντήρησης ή περισσότερα συστήματα προς μελέτη, τα μοντέλα θα πρέπει να τροποποιηθούν και να εκπαιδευτούν εκ νέου. Σε αυτές τις περιπτώσεις, θα μπορούσε να χρησιμοποιηθεί η τεχνική της μεταφοράς μάθησης (transfer-learning), η οποία θα εξοικονομούσε σημαντικό χρόνο, επιτρέποντας τη μερική εκπαίδευση των μοντέλων πριν από την εφαρμογή τους στα νέα δεδομένα.

Μία βελτίωση που θα μπορούσε να γίνει στα υπάρχοντα μοντέλα είναι η μετατροπή του χρόνου σε γεωμετρικές συναρτήσεις ημιτόνου και συνημίτονου σε επίπεδο ημέρας, εβδομάδας και μήνα. Με αυτόν τον τρόπο, θα μπορούσε να γίνει πιο λεπτομερής ανάλυση της απόδοσης των μοντέλων. Για το LSTM μοντέλο, θα μπορούσε να προσαρμοστεί η μεταβλητή 'timesteps', η οποία επηρεάζει το εύρος των δεδομένων που λαμβάνει υπόψη το μοντέλο σε κάθε κύκλο εκπαίδευσης. Με αυτόν τον τρόπο, θα εξεταστεί η απόδοση του μοντέλου για κάθε τιμή του σετ δεδομένων στόχου. Εκτός από τις παραπάνω τεχνικές, υπάρχουν και άλλες στρατηγικές που μπορούν να συμβάλλουν στη βελτίωση των προβλέψεων και στη διαχείριση πιο πολύπλοκων δεδομένων. Μια τέτοια στρατηγική είναι η χρήση τεχνικών προεπεξεργασίας δεδομένων, όπως η κανονικοποίηση και η τυποποίηση, που μπορούν να βοηθήσουν στη σταθεροποίηση των τιμών και στη βελτίωση της απόδοσης των μοντέλων. Επίσης, η υιοθέτηση ενισχυτικής μάθησης (reinforcement learning) μπορεί να αποδειχθεί χρήσιμη σε περιπτώσεις όπου τα δεδομένα αλλάζουν δυναμικά και απαιτείται συνεχής προσαρμογή των μοντέλων.

## 5. Επίλογος

Η Ευρωπαϊκή Ένωση έχει θέσει ως στόχο για το 2030 ,το 35% της συνολικής ενέργειας που καταναλώνεται (και επομένως παράγεται) στην Ευρωπαϊκή Ένωση να

προέρχεται από ανανεώσιμες πηγές. Ορισμένες χώρες αναπτύσσουν ακόμα πιο επιθετικούς στόχους (όπως η Γερμανία που σχεδιάζει το 55% και η Ελλάδα που σχεδιάζει το 44% της ανανεώσιμης ενέργειας και συνολικής ισχύος 11 GW έως το 2030 ). Σε αυτό το πλαίσιο, η αιολική ενέργεια που παράγεται ,αποτελεί κρίσιμο παράγοντα για την επίτευξη αυτών των στόχων. Όπως αναφέρουν αρκετοί μελετητές και επιστήμονες σε δημοσιεύσεις τους [23,25,26], είναι πολύ σημαντικό να κατασκευαστούν τα απαραίτητα εργαλεία πρόβλεψης για μελέτες και έργα που σχετίζονται με την ένταξη όλο και περισσότερων μονάδων της αιολικής ενέργειας στο σύστημα ηλεκτροδότησης. Από την κατεύθυνση των μελετών και των νέων ανακαλύψεων στο κομμάτι της επιστήμης των υπολογιστών και της μηχανικής μάθησης φαίνεται ότι η χρήση τεχνικών βαθιάς μάθησης είναι κλειδί στον σχεδιασμό βέλτιστων συστημάτων για την πρόβλεψη παραγωγής ενέργειας από τον άνεμο.

Η πρόβλεψη του ποσού της ενέργειας που παράγεται από τον άνεμο και στη συνέχεια ενσωματώνεται στο δίκτυο, πρέπει να γίνεται με την μέγιστη δυνατή ακρίβεια. Η πρόβλεψη της ταχύτητας του ανέμου όμως όπως αναλύθηκε και σε αυτήν την διπλωματική αποτελεί πρόκληση , λόγω της μη γραμμικότητας και μη σταθερότητας των χρονοσειρών, οι οποίες αυξάνουν τη δυσκολία της εργασίας. Οι χρονοσειρές του ανέμου εμφανίζουν επίσης σημαντική μεταβλητότητα ανάλογα με τη γεωγραφική θέση, καθώς οι άνεμοι μπορεί να είναι γραμμικοί ή χασοτικοί ανάλογα με τις τοπικές συνθήκες του χώρου.

Για τον υπολογισμό μίας πρόβλεψης υπάρχουν πολλές προσεγγίσεις. Οι προσεγγίσεις αυτές έχουν μορφή από στατιστικές αναλύσεις ,χρήση αλγορίθμων παλινδρόμησης, μη γραμμικούς αλγορίθμους και πολλές άλλες μορφές. Μία οικογένεια αλγορίθμων βασίζεται σε προσεγγίσεις τεχνητής νοημοσύνης και ειδικότερα σε νευρωνικά δίκτυα. Στη βιβλιογραφία, μπορούν να βρεθούν πολλά παραδείγματα της χρήσης αυτών των τεχνικών, και μερικά από αυτά εμφανίζονται στην παρούσα διπλωματική εργασία.

Οι μέθοδοι έχουν ταξινομηθεί σε δύο ομάδες: παραδοσιακές μεθόδους ANN και RNN. Ενώ οι μέθοδοι ANN φαίνεται να έχουν σημαντική εξάρτηση από τα δεδομένα προς πρόβλεψη και υπάρχουν διαφορετικές μεθοδολογίες για τη βελτίωση της απόδοσής τους, προσφέρουν ελάχιστες βελτιώσεις στην ακρίβεια σε σχέση με πιο περίπλοκα γραμμικά μοντέλα σε συνδυασμό με μετασχηματισμούς σήματος και στατιστική ανάλυση. Ωστόσο,

στις περιορισμένες εμπειρίες χρήσης των προσεγγίσεων CNN και RNN, οι βελτιώσεις που επιτυγχάνονται είναι σημαντικές, πράγμα που δείχνει ότι αυτές οι μέθοδοι Deep Learning έχουν μεγάλη δυναμική στην εκμάθηση των εσωτερικών πολυπλοκοτήτων των χρονοσειρών του ανέμου.

Καθώς οι προσεγγίσεις της Βαθιάς Μάθησης (Deep Learning) ωριμάζουν, θα πρέπει να αναμένεται να εμφανιστούν νέες έρευνες και μελέτες που θα προσφέρουν καλύτερη προσαρμογή στο πρόβλημα πρόβλεψης του ανέμου και καλύτερη ικανότητα προσαρμογής στις διαφορές που εντοπίζονται μεταξύ των χρονοσειρών του ανέμου από διαφορετικά σημεία.

Η διαδικασία σύγκρισης της αποτελεσματικότητας και του δυναμικού διαφορετικών προσεγγίσεων είναι μερικές φορές αδύνατο να επιτευχθεί, καθώς η μεταβλητότητα των πειραμάτων στην περιγραφή του σφάλματος, των δεδομένων που χρησιμοποιούνται, του ορίου πρόβλεψης και άλλων παραγόντων καθιστά αδύνατη την αντικειμενική σύγκριση. Ωστόσο, είναι σαφές ότι κάθε προσέγγιση που εξετάστηκε εμφανίζει δυνατότητες για περαιτέρω έρευνα και πειράματα σε άλλα αιολικά πάρκα με διαφορετικά δεδομένα. Διαφορετικά ως προς όγκο δεδομένων και είδος (αιολικό δυναμικό, υψόμετρο, γεωγραφική θέση και άλλα πολλά).

Ένα τελικό σημείο που πρέπει να αναφερθεί για τον τομέα πρόβλεψης του ανέμου είναι η ανάγκη για την ανάπτυξη τυποποιημένων συνόλων από δεδομένα που θα επιτρέπουν εύκολα την ερμηνεία των αποτελεσμάτων από τις διαφορετικές προσεγγίσεις. Σε άλλους τομείς χρήσης της μηχανικής μάθησης, έχουν αναπτυχθεί τέτοια τυποποιημένα σύνολα που επιτρέπουν τη σύγκριση εναλλακτικών προσεγγίσεων. Ένα από τα πιο σημαντικά σύνολα δεδομένων που αξίζει να αναφερθεί είναι το σύνολο δεδομένων αναγνώρισης χειρόγραφων χαρακτήρων ή το σύνολο δεδομένων αναγνώρισης προσώπων. Παράδειγμα τέτοιου συνόλου θα μπορούσε να είναι το σύνολο δεδομένων ανέμου του NREL(National Renewable Energy Laboratory) των ΗΠΑ. Ένα τέτοιο σύνολο δεδομένων μεγαλύτερης κλίμακας θα επιτρέψει μια καλύτερη σύγκριση των διαφορετικών προσεγγίσεων και μια καλύτερη κατανόηση των νέων εξελίξεων στον τομέα.

Το σύνολο δεδομένων ανέμου του NREL, είναι ένα συνθετικό σύνολο δεδομένων που δημιουργήθηκε από μετεωρολογικά δεδομένα NWP, με περισσότερες από 126.000

τοποθεσίες στις Ηνωμένες Πολιτείες. Προς το παρόν, υπάρχει ένα σημαντικό έργο που διεξάγεται στην Ευρώπη, το έργο INDECIS, το οποίο είναι μια ευρωπαϊκή προσπάθεια που αναπτύσσει ένα συνεκτικό σύνολο δεδομένων, που δημιουργείται από πραγματικές παρατηρήσεις που προέρχονται από μετεωρολογικούς σταθμούς σε όλο τον κόσμο. Το σύνολο δεδομένων αυτό τυποποιείται προκειμένου να γίνει μια πηγή επιλογής για πειράματα που απαιτούν δεδομένα ανέμου.

Η πρόβλεψη και ανάλυση της ενέργειας που παράγεται από τον άνεμο απαιτεί ακόμα πολλές ώρες έρευνας και χιλιάδες αλγόριθμους που προσαρμόζονται σε κάθε κατάσταση. Αυτές οι προσπάθειες θα μειθούν δραστικά στο μέλλον μέσω της εκτεταμένης χρήσης εργαλείων μηχανικής μάθησης. Ο τελικός στόχος είναι η δημιουργία τεχνητής νοημοσύνης η οποία θα μπορεί να διαχειρίζεται σε επίπεδο χώρας το δίκτυο ηλεκτροδότησης. Να μπορεί να κάνει σωστή κατανομή των ποσών παραγόμενης ενέργειας σε εισαγόμενα ποσά στο δίκτυο και σε ποσά που θα πηγαίνουν για αποθήκευση ανάλογα τις εκάστοτε ανάγκες.

## Βιβλιογραφία

1. Rahman, A., Srikumar, V., Smith, A.D.: Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks. *Applied energy*. 212, 372-385 (2018)
2. Deb, C., Zhang, F., Yang, J., Lee, S.E., Shah, K.W.: A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*. 74, 902-924 (2017)
3. Janocha, S.; Baum, S.; Stadler, I. Cost minimization by optimization of electricity generation and demand side management. In *Proceedings of the 2016 International Energy and Sustainability Conference, Köln, Germany, 30 June–1 July 2016*; pp. 1–7
4. Rehman, S.; Al-Hadhrami, L.M.; Alam, M.M. Pumped hydro energy storage system: A technological review. *Renew. Sustain. Energy Rev.* 2015, 44, 586–598
5. Linnemann, C.; Echternacht, D.; Breuer, C.; Moser, A. Modeling optimal redispatch for the european transmission grid. In *Proceedings of the 2011 IEEE Trondheim PowerTech, Trondheim, Norway, 19–23 June 2011*; Sponsored by the IEEE Power & Energy Society. Organized by NTNU, Norwegian University of Science and Technology, Dept. of Electric Power Engineering.... IEEE: Piscataway, NJ, USA, 2011; pp. 1–8.
6. Sohoni, V.; Gupta, S.C.; Nema, R.K. A Critical Review on Wind Turbine Power Curve Modelling Techniques and Their Applications in Wind Based Energy Systems. *J. Energy* 2016, 18.
7. Xishuang Dong, L. Q. (2017). Short-Term Load Forecasting in Smart Grid: A Combined CNN and K-Means Clustering Approach. *BigComp*
8. Kulkarni, S. S. (2019). *Decision Support System for Smart Grid Using Demand Forecasting Models*. Singapore: Springer.

9. L. Suganthi, A.A. Samuel, Energy models for demand forecasting: A review, *Renew Sustain Energy Rev*, 16 (2012), pp. 1223-1240
10. A. A. Ewees, M. A.-q. (2022). HBO-LSTM: Optimized long short term memory with heap-based optimizer for wind power forecasting. *Energy Convers. Manag*
11. Bukhari Ayaz Hussain, Zahoor Raja Muhammad Asif, Sulaiman Muhammad, Islam Saeed, Shoaib Muhammad, Kumam Poom. Fractional neuro-sequential arfima-lstm for financial market forecasting. *IEEE Access* 2020;8:71326–38.
12. Petersen Niklas Christoffer, Rodrigues Filipe, Pereira Francisco Camara. Multioutput bus travel time prediction with convolutional lstm neural network. *Expert Syst Appl* 2019;120:426–35.
13. Zaki Masood, R. G. (2022). A Multi-Step Time-Series Clustering-Based Seq2Seq LSTM Learning for a Single Household Electricity Load Forecasting. *Energies*,
14. H. W. E. Company, “Wind energy statistics in greece for the 1st half of 2022,” Aug. 10 2022. [Online]. Available: <https://eletaen.gr/d-t-statistiki-eletaen-first-semester-2022/>
15. N. G. Society, “Wind energy,” Oct. 9 2012. [Online]. Available: <https://education.nationalgeographic.org/resource/wind-energy/>
16. M. Cheng and Y. Zhu, “The state of the art of wind energy conversion systems and technologies: A review,” 2014.
17. V. Sharma, S. Sharma, and G. Sharma, “Recent development in the field of wind turbine,” *Materials Today: Proceedings*, vol. 64, pp. 1512–1520, 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2214785322037798>



18. S. Cole, "Wind turbine power curve." [Online]. Available: <https://theroundup.org/wind-turbine-power-curve/>
19. H. Ashtari, "What is a neural network?definition,working,types and applications," Aug. 3 2022. [Online].Available: <https://www.spiceworks.com/tech/artificial-intelligence/articles/what-is-a-neural-network/>
20. K. Tertikas, "Implementation of dense sift as a convolutional neural network," 2017.
21. Marvin Minsky and Seymour A. Papert ,Perceptrons, Expanded EditionAn Introduction to Computational Geometry
22. J.Manero , J.Béjar, U. Cortés, Wind Energy Forecasting with Neural Networks: A Literature Review, Dec 2018.
23. Liu, H., qi Tian, H., fu Pan, D., & fei Li, Y.(2013). Forecasting models for wind speed using wavelet, wavelet packet, time series and artificial neural networks. Applied Energy, Vol. 107,
24. Saprionova, A., Meissner, C., & Mana, M. (2016).Short time ahead wind power production forecast.Journal of Physics: Conference Series, Vol. 749,No. 1, pp. 012006.
25. Shi, J., Guo, J., & Zheng, S. (2012). Evaluationof hybrid forecasting approaches for wind speedand power generation time series. Renewable and Sustainable Energy Reviews, Vol. 16, No. 5,pp. 3471 – 3480
26. Li, G. & Shi, J. (2010). On comparing three artificial neural networks for wind speed forecasting. Applied Energy, Vol. 87, No. 7, pp. 2313 – 2320.
27. Zhang, Y., et al. "Wind Speed Prediction with LSTM." \*Journal of Renewable Energy Studies\*, 2020.

28. Liu, X., et al. "Hybrid Wavelet-LSTM Approach for Wind Power Prediction." \*IEEE Transactions on Sustainable Energy\*, 2021.
29. Chen, H., et al. "Enhanced Wind Power Forecasting with External Weather Data Using LSTM." \*Energy Reports\*, 2022.
30. Feng, J., et al. "Hybrid CNN-LSTM Model for Wind Speed Prediction." \*Renewable Energy and Environment\*, 2019.
31. Wang, P., et al. "LSTM with Attention Mechanism for Wind Speed Forecasting." \*International Journal of Forecasting\*, 2021.
32. He, Z., et al. "Normalized LSTM for Wind Power Prediction with Weather Data." \*Applied Energy\*, 2023.
33. Yao, Y., et al. "Bidirectional LSTM for Wind Speed Prediction." \*Energy Conversion and Management\*, 2022.
34. Qiu, J., et al. "Feature Selection and LSTM for Wind Power Forecasting." \*Journal of Renewable and Sustainable Energy\*, 2021.
35. Gan, M., Li, H. X., Chen, C. L. P., & Chen, L. (2015). A potential method for determining nonlinearity in wind data. *IEEE Power and Energy Technology Systems Journal*, Vol. 2, No. 2, pp. 74–81.
36. Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning*. MIT press.
37. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.

38. Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 4, p. 12).
39. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
40. Glorot, X., Bordes, A., & Bengio, Y. (2011). Deep sparse rectifier neural networks. In Proceedings of the fourteenth international conference on artificial intelligence and statistics (pp. 315-323).
41. Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. arXiv preprint arXiv:1207.0580
42. Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980.
43. Prechelt, L. (1998). Early stopping-but when? In *Neural Networks: Tricks of the Trade* (pp. 55-69). Springer, Berlin, Heidelberg.
44. S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997.
45. N. Srivastava et al., "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," *J. Mach. Learn. Res.*, vol. 15, no. 1, pp. 1929–1958, Jan. 2014.

46. F. A. Gers, N. N. Schraudolph, and J. Schmidhuber, “Learning Precise Timing with LSTM Recurrent Networks,” *J. Mach. Learn. Res.*, vol. 3, pp.
47. S. Santurkar, D. Tsipras, A. Ilyas, and A. Madry, “How Does Batch Normalization Help Optimization?,” arXiv:1805.11604 [cs, stat], May 2018.
48. N. P. Jouppi et al., “In-Datacenter Performance Analysis of a Tensor Processing Unit,” 2017.
49. Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-Based Learning Applied to Document Recognition,” *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, Nov. 1998.
50. Dickey, D. A. & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, Vol. 74, No. 366, pp. 427–431