



ΕΘΝΙΚΟ ΚΑΙ ΚΑΠΟΔΙΣΤΡΙΑΚΟ ΠΑΝΕΠΙΣΤΗΜΙΟ ΑΘΗΝΩΝ

**ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ**

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

**Πρόβλεψη ταχύτητας ανέμου με τη χρήση παρελθοντικών
δεδομένων**

Δημήτριος Κ. Γούναρης

Επιβλέπων: Ιωάννης Εμίρης, Καθηγητής

ΑΘΗΝΑ

ΦΕΒΡΟΥΑΡΙΟΣ 2020

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

Πρόβλεψη ταχύτητας ανέμου με τη χρήση παρελθοντικών δεδομένων

Δημήτριος Κ. Γούναρης

A.M.: 1115201500032

ΕΠΙΒΛΕΠΟΝΤΕΣ: Ιωάννης Εμίρης, Καθηγητής

ΠΕΡΙΛΗΨΗ

Ο στόχος της συγκεκριμένης εργασίας είναι η υλοποίηση ενός μοντέλου νευρωνικών δικτύων, το οποίο μπορεί να χρησιμοποιηθεί για ημερήσιες προβλέψεις ταχύτητας ανέμου με βάση προηγούμενα πραγματικά δεδομένα. Ιδιαίτερη έμφαση δόθηκε στην ικανότητα του μοντέλου να προβλέπει επιτυχώς τη μέση τιμή του ανέμου σε βάθος μιας ημέρας μετά από βραχεία εκπαίδευση, τόσο όσον αφορά το χρόνο της όσο και τον αριθμό των διαθέσιμων δεδομένων. Επίσης, αναζητήθηκε ένα βέλτιστο σύνολο δεδομένων που θα βελτιστοποιούσε το αποτέλεσμα, χωρίς να αυξάνει το χρόνο εκπαίδευσης του δικτύου. Οι μετρικές που χρησιμοποιήθηκαν για την αξιολόγηση των μοντέλων ήταν το μέσο, το μέσο απόλυτο και το μέσο απόλυτο ποσοστιαίο σφάλμα. Τα αποτελέσματα έδειξαν πως ήταν εφικτό πολύ γρήγορα για ένα δίκτυο να προβλέψει με ακρίβεια τη μέση ταχύτητα του ανέμου σε βάθος μιας ημέρας, παρά τις ανακρίβειες σε μεμονωμένα μικρότερα διαστήματα.

ΘΕΜΑΤΙΚΗ ΠΕΡΙΟΧΗ: Νευρωνικά δίκτυα

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ: νευρωνικά δίκτυα, πρόβλεψη ταχύτητας ανέμου, χρονοσειρές, ανάλυση και επεξεργασία δεδομένων

ABSTRACT

The goal of this thesis is the implementation of a neural network model, able to be used for daily wind speed forecasts based on past real data. Emphasis was given on the model's ability to predict successfully the wind speed daily mean value after a short-term training, or having a training set lacking significant amounts of data. Moreover, an optimal training set was experimentally found, in order to improve the model results without hindering performance. The metrics that were used were mean, mean absolute and mean absolute percentage errors. The results demonstrate the model's ability to quickly forecast the mean wind speed of a day, despite some inaccuracies in single predictions.

SUBJECT AREA: Neural Networks

KEYWORDS: neural networks, wind speed forecast, time series, data analysis and processing

ΕΥΧΑΡΙΣΤΙΕΣ

Θα ήθελα να ευχαριστήσω τους κ. Ιωάννη Εμίρη και Μανώλη Χριστοφόρου, για την συνεχή στήριξή τους κατά τη διεκπεραίωση της παρούσας εργασίας.

ΠΕΡΙΕΧΟΜΕΝΑ

ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ	8
ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ	9
ΠΡΟΛΟΓΟΣ	10
1. ΕΙΣΑΓΩΓΗ	11
1.1 Προβλέψεις ταχύτητας ανέμου	11
1.2 Νευρωνικά δίκτυα	11
1.3 Προηγούμενο έργο	12
2. ΑΝΑΛΥΣΗ ΔΕΔΟΜΕΝΩΝ	16
2.1 Συλλογή δεδομένων	16
2.2 Επεξεργασία δεδομένων	16
3. ΕΠΙΛΟΓΗ ΜΟΝΤΕΛΟΥ	18
3.1 Διαδικασία επιλογής μοντέλου	18
3.2 Περιορισμοί μοντέλου	19
4. ΠΕΙΡΑΜΑΤΑ	20
4.1 Αξιολόγηση αποτελεσμάτων	20
4.2 Προσπάθειες ελάττωσης υπερπροσαρμογής	21
4.3 Ιδανικό σύνολο δεδομένων	22
4.4 Χρήση πολλαπλών δικτύων (ensemble network)	24
4.5 Ανάλυση αποτελεσμάτων	25
5. ΣΥΜΠΕΡΑΣΜΑΤΑ	27
5.1 Σύνοψη αποτελεσμάτων	27
5.2 Μελλοντικές επεκτάσεις	27
ΣΥΝΤΜΗΣΕΙΣ – ΑΡΚΤΙΚΟΛΕΞΑ – ΑΚΡΩΝΥΜΙΑ	28
ΑΝΑΦΟΡΕΣ	29

ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ

Εικόνα 1: Αναπαράσταση νευρωνικού δικτύου	σελ. 11
Εικόνα 2: Αναπαράσταση δικτύου RNN	σελ. 12
Εικόνα 3: Αναπαράσταση δικτύου LSTM	σελ. 12
Εικόνα 4: Σύγκριση αποτελεσμάτων διαφορετικών μοντέλων προγενέστερων εργασιών	σελ. 13
Εικόνα 5: Αναπαράσταση του προτεινόμενου σύνθετου μοντέλου	σελ. 14
Εικόνα 6: Αναπαράσταση της διαδικασίας κυλιόμενης πρόβλεψης	σελ. 15
Εικόνα 7: Στατιστικά στοιχεία ενδεικτικών τιμών των δεδομένων. Οι φορές που παρατηρήθηκε κάθε τιμή (στον κάθετο άξονα) ως προς τη μονάδα μέτρησης (στον οριζόντιο άξονα).	σελ. 16
Εικόνα 8: Αναπαράσταση του επιλεγμένου μοντέλου	σελ. 18
Εικόνα 9: Γραφική αναπαράσταση της συνάρτησης ενεργοποίησης ReLU	σελ. 19
Εικόνα 10: Συναρτήσεις των επιλεγμένων σφαλμάτων	σελ. 20
Εικόνα 11: Προβλέψεις (με πορτοκαλί) και πραγματικές τιμές (με μπλε) για μία ημέρα	σελ. 20
Εικόνα 12: Παρατηρούμενη υπερπροσαρμογή σε σύνολο δεδομένων της τάξης των 20000 εγγραφών (1 περιοχή, 3 έτη)	σελ. 21
Εικόνα 13: Παρατηρούμενη υπερπροσαρμογή σε σύνολο δεδομένων της τάξης των 120000 εγγραφών (7 γειτονικές περιοχές, 2 έτη)	σελ. 22
Εικόνα 14: Προβλέψεις (με πορτοκαλί) και πραγματικές τιμές (με μπλε) (MAPE: 97%, MAE: 3.5 m/s, ME: -0.59 m/s)	σελ. 23
Εικόνα 15: Προβλέψεις (με πορτοκαλί) και πραγματικές τιμές (με μπλε) (MAPE: 67,5%, MAE: 2.9 m/s, ME: 0.22 m/s)	σελ. 23
Εικόνα 16: Προβλέψεις (με πορτοκαλί) και πραγματικές τιμές (με μπλε) (MAPE: 73%, MAE: 2.2 m/s, ME: 0,007 m/s)	σελ. 24

ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ

Πίνακας 1: Αποτελέσματα μεμονωμένου μοντέλου ως προς το σύνολο δεδομένων εκπαίδευσης	σελ. 25
Πίνακας 2: Σύγκριση αποτελεσμάτων μεμονωμένου και συνόλου δικτύων	σελ. 26

ΠΡΟΛΟΓΟΣ

Η παρούσα πτυχιακή, με όνομα “Πρόβλεψη ταχύτητας ανέμου με τη χρήση παρελθοντικών δεδομένων”, υλοποιήθηκε στα πλαίσια του προπτυχιακού προγράμματος σπουδών του τμήματος Πληροφορικής και Τηλεπικοινωνιών του Εθνικού και Καποδιστριακού Πανεπιστημίου Αθηνών.


1. ΕΙΣΑΓΩΓΗ

1.1 Προβλέψεις ταχύτητας ανέμου

Λόγω του όλο και αυξανόμενου ρυθμού αξιοποίησης ανανεώσιμων πηγών ενέργειας, και ειδικότερα του ανέμου, η πρόβλεψη της ταχύτητάς του αποτελεί μια μείζονος σημασίας διεργασία. Ανά τα έτη, διάφορες τεχνικές έχουν υλοποιηθεί για το σκοπό αυτό, που είναι κυρίως βασισμένες σε δεδομένα από το περιβάλλον όπως η υγρασία, η ατμοσφαιρική πίεση και η θερμοκρασία. Για παράδειγμα, υπάρχουν μαθηματικά μοντέλα τα οποία υστερούν σε ταχύτητα, όπως επίσης και μοντέλα κυλιόμενου μέσου όρου (ARMA), των οποίων η σχετική ακρίβεια υποδεικνύει την συσχέτιση μεταξύ γειτονικών (γεωγραφικά) στιγμιότυπων και περιοχών. Ωστόσο, η πιο ευρέως χρησιμοποιούμενη τεχνική πρόβλεψης ταχύτητας ανέμου είναι η χρήση νευρωνικών δικτύων. Η τεχνική αυτή είναι κατάλληλη λόγω της μη γραμμικότητας του προβλήματος και της συνεχούς και απότομης μεταβολής της ταχύτητας του ανέμου.

1.2 Νευρωνικά δίκτυα

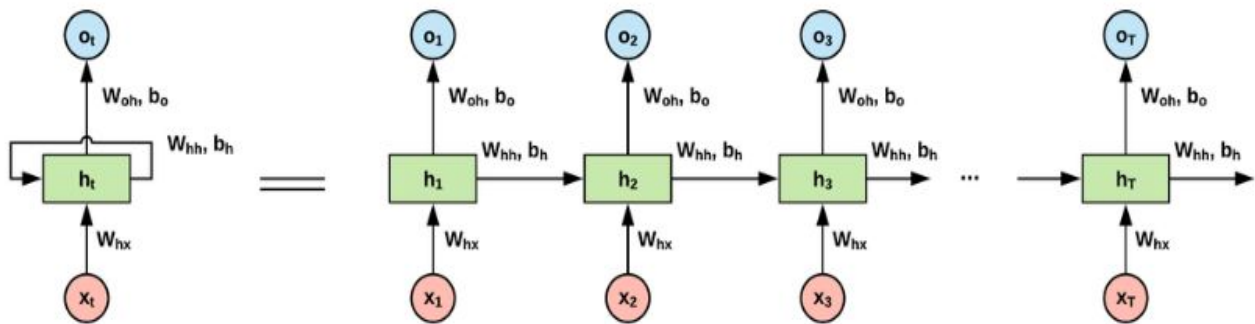
Τα νευρωνικά δίκτυα αποτελούν υπολογιστικά μοντέλα βασισμένα στους βιολογικούς νευρώνες. Δέχονται μια είσοδο και παράγουν μια έξοδο, όχι βασισμένα σε κάποιες εντολές, αλλά βασισμένα σε προηγούμενα παραδείγματα που έχουν αντιμετωπίσει. Αναλυτικότερα, η έξοδος βασίζεται στην είσοδο, στα βάρη μεταξύ των νευρώνων αλλά και στη συνάρτηση ενεργοποίησης. Έτσι, τα νευρωνικά δίκτυα μπορούν να αναπαρασταθούν ως γράφοι, με τους νευρώνες ως κορυφές και τα βάρη μεταξύ τους ως ακμές. Ο στόχος ενός νευρωνικού δικτύου είναι να βρει τις βέλτιστες δυνατές παραμέτρους σε μια μη γραμμική συνάρτηση προκειμένου για κάθε είσοδο, η έξοδος να είναι η αναμενόμενη. Όταν το δίκτυο τελειώσει την επεξεργασία, υπολογίζεται το σφάλμα σε σχέση με την αναμενόμενη έξοδο και, μέσω ανατροφοδότησης, υπολογίζεται η νέα τιμή για κάθε παράμετρο (δηλαδή για κάθε ακμή μεταξύ νευρώνων).



Εικόνα 1: Αναπαράσταση νευρωνικού δικτύου


Μια ειδική περίπτωση αποτελεί αυτή των ανατροφοδοτούμενων νευρωνικών δικτύων (recurrent neural networks, RNN). Σε αντίθεση με τα παραδοσιακά δίκτυα, οι τιμές των παραμέτρων εφαρμόζονται αναδρομικά σε όλες τις εισόδους, οι οποίες δίνονται στο δίκτυο με δομημένη μορφή, συνήθως ως χρονοσειρές. Έπειτα, το δίκτυο διορθώνει τις

παραμέτρους του με βάση το σύνολο εισόδων και εξόδων. Έτσι, τα δίκτυα μπορούν με αυτόν τον τρόπο να εντοπίσουν συσχετίσεις μεταξύ εισόδων και εξόδων από διαφορετικά χρονικά σημεία μέσα στο σύνολο των δεδομένων, κάνοντάς τα πολύ αποδοτικά σε προβλήματα χρονοσειρών. Αυτή η συμπεριφορά μπορεί να επεκταθεί και σε προβλήματα όπου η συσχέτιση μεταξύ εισόδων και εξόδων δεν είναι χρονική, αλλά νοηματική, όπως σε προβλήματα γραφής [1] και ομιλίας [2]. Ένα διάγραμμα του τρόπου λειτουργίας αυτών των δικτύων παρουσιάζεται παρακάτω.



Εικόνα 2: Αναπαράσταση δικτύου RNN

Υποκατηγορία αυτών αποτελούν τα LSTM, δίκτυα που προτάθηκαν από τους Hochreiter και Schmidhuber προκειμένου να αντιμετωπίσουν τις αδυναμίες σύγκλισης και την αργή ταχύτητα των παραδοσιακών RNN δικτύων απέναντι σε εκτεταμένες χρονοσειρές [10]. Εφαρμόζοντας την ίδια γενική αρχή, κάθε κελί ενός δικτύου LSTM κρύβει επιπλέον μέσα του μια σειρά από λογικές πύλες που επιτρέπουν τη ροή πληροφορίας από κελί σε κελί, καθώς και την αποθήκευση της τρέχουσας κατάστασης του κελιού με αποδοτικό τρόπο. Η τρέχουσα κατάσταση αφορά παραμέτρους όπως πόση πληροφορία θα πρέπει να προωθήσει το κελί στα επόμενα, πόσο θα πρέπει να μεταβάλει τις παραμέτρους του σε περίπτωση σφάλματος και άλλα.



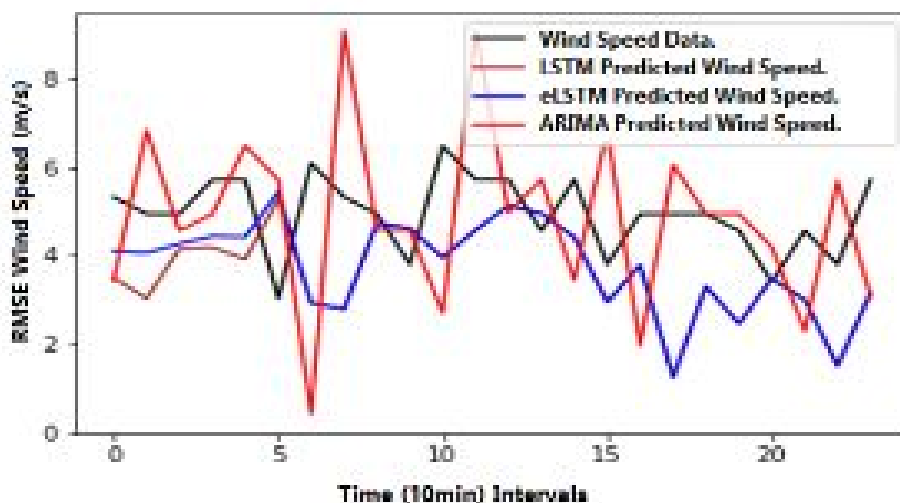
Εικόνα 3: Αναπαράσταση δικτύου LSTM

1.3 Προηγούμενο έργο

Ήδη, πολλές προσπάθειες έχουν γίνει για πρόβλεψη της ταχύτητας του ανέμου με χρήση RNN. Στην δημοσίευση [4], ένα τέτοιο δίκτυο, εκπαιδευμένο σε δεδομένα από 57 γειτονικά σημεία, πέτυχε μέσο απόλυτο σφάλμα της τάξης του 1.18, σε προβλέψεις των επόμενων 6 ωρών. Αντίστοιχα, στην [3], ένα μοντέλο με παρόμοια αρχιτεκτονική, εκπαιδευμένο σε πολλές παράκτιες περιοχές της βορειοδυτικής Ευρώπης για μεγάλη χρονική διάρκεια (ένα

σύνολο 100000 δειγμάτων) ταυτόχρονα, πέτυχε ένα μέσο απόλυτο σφάλμα κοντά στα 2.5 m/s όταν προέβλεπε τιμές για μία από αυτές. Φαίνεται έτσι πως απαιτούνται πιο στοχευμένες μέθοδοι επιλογής συνόλου εκπαίδευσης ή αρχιτεκτονικής για μια πολύ ισχυρή πρόβλεψη. Στην [5], δημοσιευμένη στο διεθνές συνέδριο ανανεώσιμης ενέργειας του 2018, οι συγγραφείς συνέκριναν προβλέψεις διαφορετικής χρονικής διάρκειας (από λίγα λεπτά έως 2 μέρες) και διαφορετικών μοντέλων (μεταξύ των οποίων ένα LSTM και ένα γραμμικό), και κατέληξαν πως το RNN δίκτυο είχε σταθερά μικρότερο σφάλμα πρόβλεψης. Συγκεκριμένα, το προτεινόμενο μοντέλο τους πέτυχε μέσο ποσοστιαίο σφάλμα (MSE) 0.05 στις σταθμισμένες τιμές του ανέμου στο εύρος τιμών (0,1). Ο τρόπος πρόβλεψης των χρονικών στιγμιότυπων ήταν παρόμοιος με αυτόν της παρούσας εργασίας, με κυλιόμενες προβλέψεις, όπως φαίνεται στην εικόνα 2.

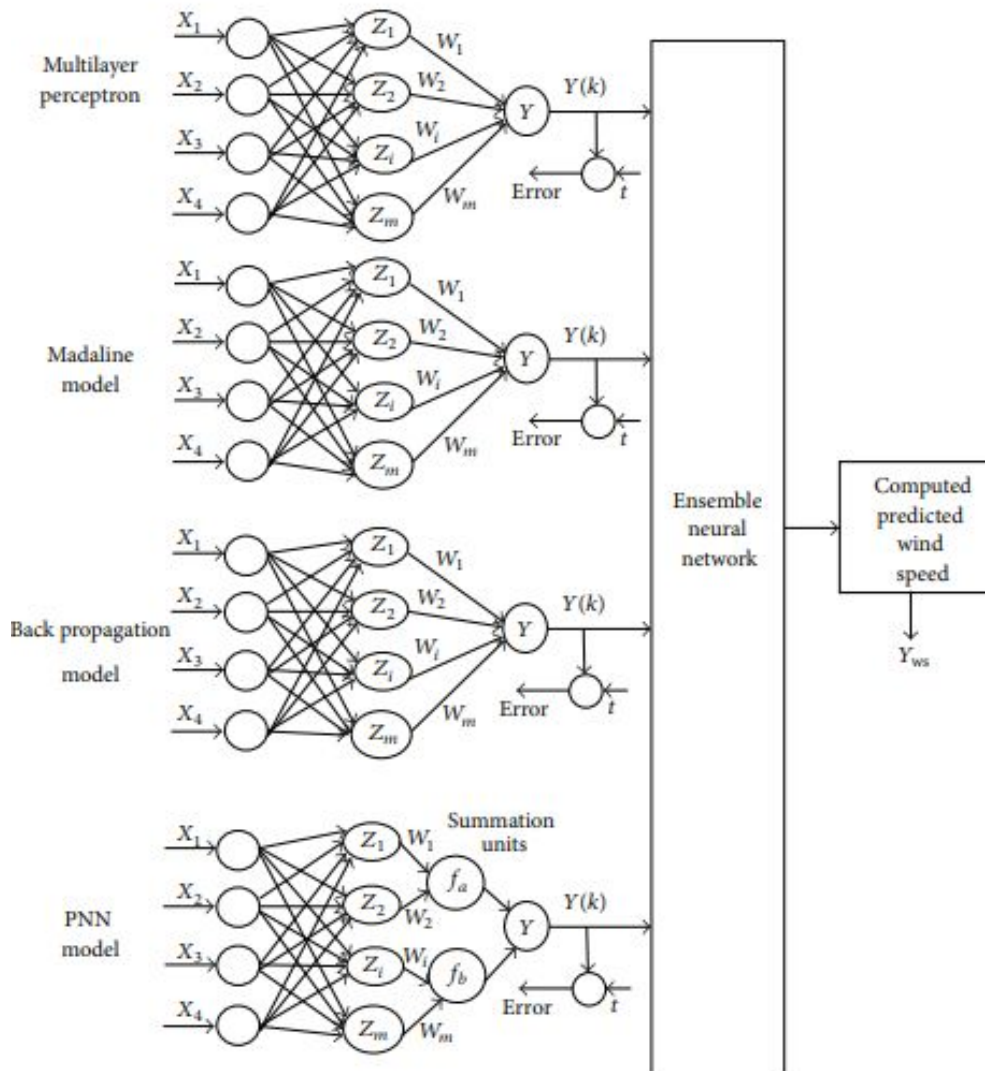
Στην [8], ένα ακόμα μοντέλο RNN παρουσιάζεται, με μια υλοποίηση τυχαιοποιημένης μεθόδου απόρριψης κόμβων του μοντέλου, ώστε να αποφευχθεί η υπερπροσαρμογή. Για τα πειράματά τους χρησιμοποιήθηκαν μετρήσεις ανά 10 λεπτά, χωρισμένες σε πενθήμερα. Από αυτά τα πενθήμερα, οι πρώτες 4 ημέρες αποτελούσαν το σύνολο εκπαίδευσης και η 5η ημέρα το σύνολο επαλήθευσης (validation set), μια τεχνική παρόμοια με αυτήν που εφαρμόζεται και στην παρούσα εργασία. Κατά τα όσα αναφέρουν οι συγγραφείς, το δίκτυο που παρουσίασαν (που αποτελεί μια παραλλαγή του δικτύου LSTM) μπόρεσε να πετύχει έως και 80% ακρίβεια, ξεπερνώντας πολλά άλλα αποτελεσματικά δίκτυα. Ενδεικτικά παρουσιάζεται το παρακάτω διάγραμμα από την συγκεκριμένη εργασία, που δείχνει την αποτελεσματικότητα του προτεινόμενου LSTM δικτύου έναντι ενός παραδοσιακού LSTM και άλλων συνηθισμένων μεθόδων.



Εικόνα 4: Σύγκριση αποτελεσμάτων διαφορετικών μοντέλων προγενέστερων εργασιών

Σε άλλες δημοσιεύσεις, όπως η [7], το μοντέλο που εξετάζεται αποτελεί ένα μοντέλο συνόλου δικτύων με προβλέψεις σημαντικά κοντά στις πραγματικές τιμές. Στη συγκεκριμένη δημοσίευση, λαμβάνονται υπόψη οι προβλέψεις πολλών διαφορετικού τύπου μοντέλων (συμπεριλαμβανομένων ενός RNN και ενός πιθανολογικού μοντέλου), με το αποτέλεσμα να είναι ο μέσος όρος αυτών των προβλέψεων. Εξετάζοντας παράλληλα και διάφορες τεχνικές απόρριψης κόμβων του δικτύου, το τελικό τους μοντέλο πέτυχε προβλέψεις πολύ κοντά στις πραγματικές τιμές, δείχνοντας πως τα μοντέλα συνόλου δικτύων μπορούν να είναι αποτελεσματικά σε τέτοιες περιπτώσεις. Για την ακρίβεια,

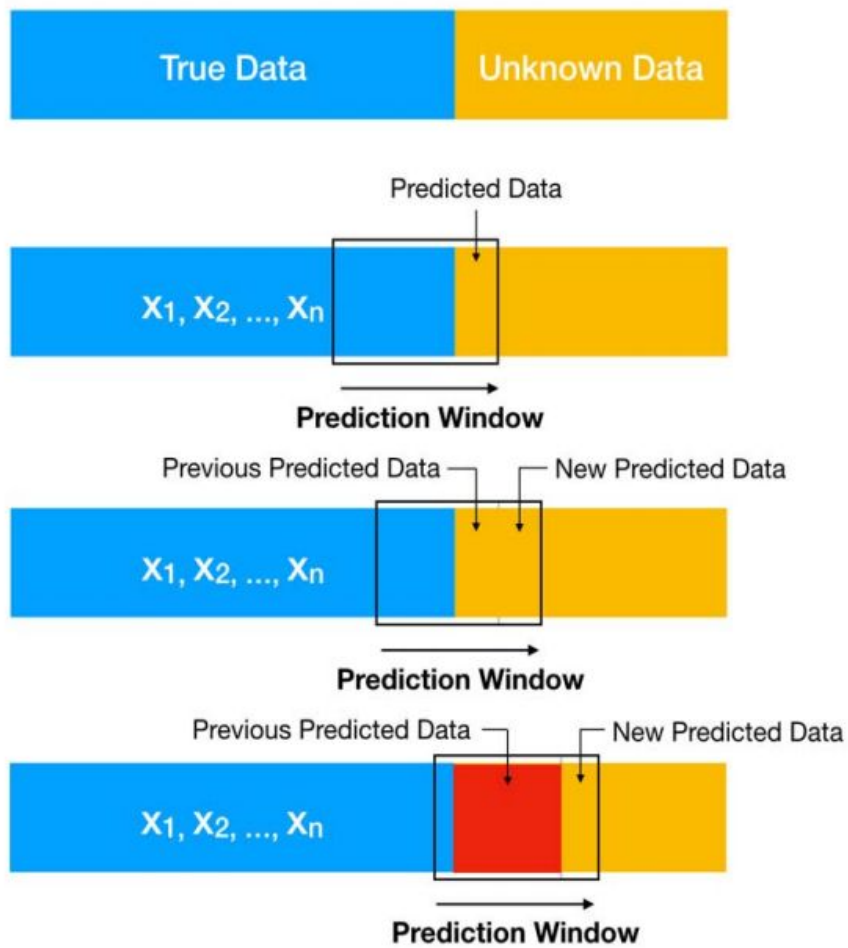
παρατήρησαν μέσο τετραγωνισμένο σφάλμα (MSE) έως και 0.015, εφόσον οι ιδανικές συναρτήσεις απόρριψης κόμβων χρησιμοποιούνταν. Αξίζει να αναφερθεί ωστόσο, πως το μέσο τετραγωνισμένο σφάλμα (MSE) έπεσε σε χαμηλότερα του 1 μόνο μετά από 1000 επαναλήψεις εκπαίδευσης κάτι το οποίο δεν είναι συμφέρον για γρήγορες, ευέλικτες προβλέψεις. Ενδεικτικά, η αρχιτεκτονική αυτού του σύνθετου μοντέλου παρουσιάζεται παρακάτω.



Εικόνα 5: Αναπαράσταση του προτεινόμενου σύνθετου μοντέλου

Τέλος, δημοσιεύσεις όπως η [6], του Χ. Τζάμου, βελτιστοποιούν σημαντικά τις προβλέψεις υπαρκτών μοντέλων πρόβλεψης, χρησιμοποιώντας RNN δίκτυα. Για την ακρίβεια, παίρνοντας ως είσοδο μία μίξη πραγματικών και προβλεπόμενων δεδομένων, είναι ικανά να βελτιώσουν τα αποτελέσματα, διορθώνοντας αστοχίες των αρχικών προβλέψεων, πετυχαίνοντας τελικά μέσο απόλυτο σφάλμα της τάξης του 1.65.

Σε αντίθεση με αυτές τις μελέτες, οι οποίες δίνουν έμφαση στην βελτιστοποίηση του νευρωνικού δικτύου, στόχος της παρούσας εργασίας είναι η πρόταση ενός απλούστερου δικτύου και η προσαρμογή του συνόλου δεδομένων γύρω από τις ανάγκες του, ώστε να επιτευχθεί μια ακριβής ημερήσια πρόβλεψη.



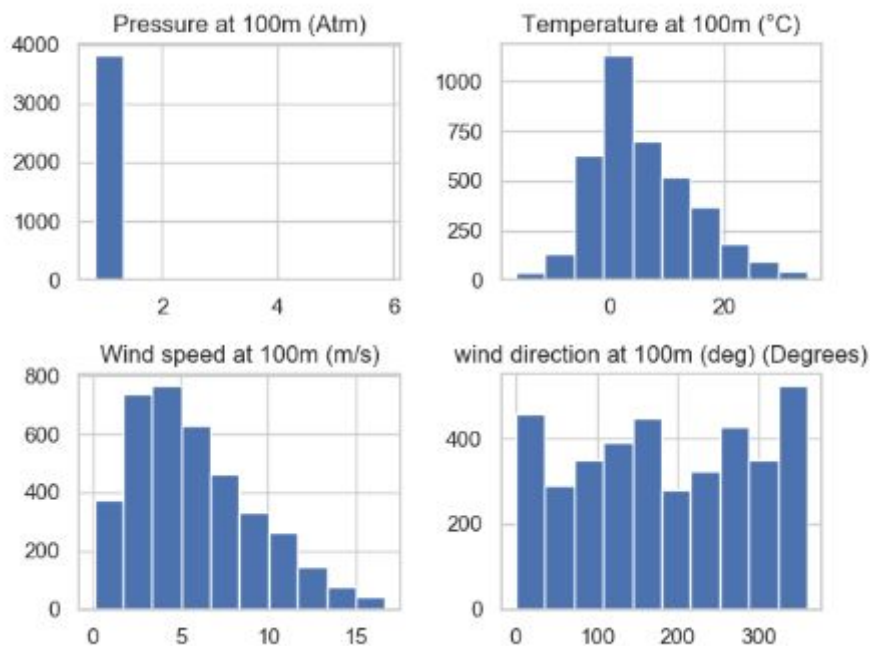
Εικόνα 6: Αναπαράσταση της διαδικασίας κυλιόμενης πρόβλεψης

2. ΑΝΑΛΥΣΗ ΔΕΔΟΜΕΝΩΝ

2.1 Συλλογή δεδομένων

Για τις ανάγκες αυτής της πτυχιακής εργασίας χρησιμοποιήθηκαν πραγματικές μετρήσεις στο εύρος των ετών 2007 - 2013. Συγκεκριμένα, αξιοποιήθηκαν τα διαθέσιμα δεδομένα του NREL σε περιοχές των κεντρικών Ηνωμένων Πολιτειών της Αμερικής, αποτελούμενα από μετρήσεις υγρασίας, θερμοκρασίας, ταχύτητας ανέμου, κατεύθυνσης ανέμου και ατμοσφαιρικής πίεσης. Όπως και σε άλλες παρόμοιες έρευνες, τα δεδομένα αυτά φαίνεται να επαρκούν για την παραγωγή αξιόπιστων προβλέψεων. Στα πειράματα που αξιοποιήθηκαν μετρήσεις από πολλά γειτονικά γεωγραφικά σημεία, αυτά βρίσκονταν εντός 1 μονάδας γεωγραφικού πλάτους και μήκους από το κεντρικότερο σημείο.

Για να γίνει κατανοητό το μέγεθος των σφαλμάτων (και ειδικότερα των μη ποσοστιαίων), είναι σημαντικό να αναγνωριστούν τα χαρακτηριστικά του συνόλου δεδομένων που επιλέχθηκαν. Στις περιοχές που επλέχθηκαν, η ταχύτητα του ανέμου παρέμενε σταθερά σχετικά χαμηλή, χωρίς να ξεπερνάει τα 15 μέτρα/δευτερόλεπτο, αν και η κατεύθυνση του ανέμου παρουσίαζε συχνές αλλαγές. Η θερμοκρασία και η πίεση επίσης ήταν αρκετά σταθερές όλο το χρόνο. Παρακάτω παρατείνεται ένα παράδειγμα από τα στατιστικά των τιμών των δεδομένων σε μια από αυτές τις περιοχές για ένα χρόνο.



Εικόνα 7: Στατιστικά στοιχεία ενδεικτικών τιμών των δεδομένων. Οι φορές που παρατηρήθηκε κάθε τιμή (στον κάθετο άξονα) ως προς τη μονάδα μέτρησης (στον οριζόντιο άξονα).

2.2 Επεξεργασία δεδομένων

Ένα πρώτο βήμα στην επεξεργασία των δεδομένων ήταν η απομάκρυνση ακραίων τιμών από τα δεδομένα, οι οποίες πιθανώς θα δυσκόλευαν τη σύγκλιση του νευρωνικού δικτύου. Αν και οι περισσότερες τιμές κυμαίνονταν κοντά στον μέσο όρο, τιμές της ταχύτητας του ανέμου που απείχαν κατά πολύ (συγκεκριμένα κατά τουλάχιστον 3 φορές την τυπική απόκλιση από τον μέσο όρο) εξαιρέθηκαν από τα πειράματα. Τέτοιες τιμές μπορεί να

αφορούσαν ξαφνικές και βραχυχρόνιες ριπές ανέμου, ή σφάλματα στις μετρήσεις των σχετικών αισθητήρων. Στη συνέχεια, όλες οι τιμές μετασχηματίστηκαν έτσι ώστε να βρίσκονται εντός του εύρους τιμών $[0, 1]$, λαμβάνοντας υπόψη την μέγιστη και την ελάχιστη τιμή για κάθε κατηγορία. Με τον τρόπο αυτόν, επιτυγχάνεται η διευκόλυνση και επιτάχυνση του μοντέλου όσον αφορά την εύρεση των ιδανικών συντελεστών, καθώς όλες οι σχετικές πράξεις αποτελούνται από μικρότερους αριθμούς που είναι πιο εύκολα διαχειρίσιμοι.

Προκειμένου τα δεδομένα να αποτελέσουν μια βάση για την εκπαίδευση του δικτύου, τα δεδομένα έπειτα ομαδοποιούνταν σε χρονοσειρές αποτελούμενες από ένα σύνολο ωριαίων μετρήσεων για 4 συνεχόμενες ημέρες. Από αυτές, οι 3 πρώτες αποτελούσαν τα δεδομένα για μια πρόβλεψη του δικτύου ενώ η 4η δεν δινόταν εξ αρχής στο δίκτυο και αποτελούσε το ζητούμενο. Αυτός ο αριθμός ημερών ήταν αποτέλεσμα δοκιμών με διαφόρου πλήθους ημέρες δεδομένων, και είναι συνεπής με άλλες σχετικές εργασίες.

Επιπλέον, για να αξιολογηθεί η απόδοση του μοντέλου σε περιπτώσεις στις οποίες δεν έχει εκπαιδευτεί, τα δεδομένα διαχωρίζονταν σε δύο κατηγορίες. Η πρώτη κατηγορία, το σύνολο εκπαίδευσης, αποτελούσε το 80% των παραπάνω τετραημέρων, επιλέγοντας τυχαία δείγματα από το σύνολο αυτών, ενώ η δεύτερη κατηγορία, το σύνολο επαλήθευσης (validation set), αποτελούσε το υπόλοιπο 20%. Το μοντέλο, γνωρίζοντας τις τρεις πρώτες ημέρες από αυτά τα τετραήμερα, έπρεπε να προβλέψει την τέταρτη ημέρα. Και στις δύο περιπτώσεις η τέταρτη ημέρα ήταν άγνωστη, αλλά στην περίπτωση της εκπαίδευσης δίνονταν οι τιμές της τέταρτης ημέρας στο μοντέλο, αφού είχε κάνει την πρόβλεψή του. Κατά την εκπαίδευση, τα υποψήφια μοντέλα εκπαιδεύονταν μόνο στα πρώτα, και έπειτα αξιολογούταν η απόδοσή τους στα δεύτερα, για να φανεί κατά πόσο εμφάνιζαν υπερπροσαρμογή.


3. ΕΠΙΛΟΓΗ ΜΟΝΤΕΛΟΥ

3.1 Διαδικασία επιλογής μοντέλου

Αρχικός στόχος ήταν η εύρεση ενός μοντέλου, βασισμένο στην προϋπάρχουσα υλοποίηση της βιβλιοθήκης Keras για τα δίκτυα LSTM και Dense, ικανού να αναγνωρίσει τα ιδιαίτερα χαρακτηριστικά της μεταβολής της κίνησης του ανέμου στα δεδομένα εκπαίδευσης, χωρίς όμως να υποκύπτει σε υπερπροσαρμογή όταν αντιμετωπίζει νέα δεδομένα της ίδιας περιοχής.

Έπειτα από σταδιακές αυξήσεις του συνόλου δεδομένων και της πολυπλοκότητας του δικτύου, ένα δίκτυο με 4 εσωτερικές δομές LSTM των 60 κόμβων έκαστη και μία Dense δομή με 24 κόμβους (από την οποία θα προέκυπτε η έξοδος του μοντέλου) φάνηκε να δίνει τα βέλτιστα δυνατά αποτελέσματα έναντι τόσο του σετ εκπαίδευσης (training set) όσο και του σετ επαλήθευσης (validation set), με μέσο ποσοστιαίο σφάλμα 19% και 36% αντίστοιχα.


Το μοντέλο υλοποιήθηκε σε Python, χρησιμοποιώντας το Tensorflow backend και τα δίκτυα που παρείχε η βιβλιοθήκη Keras, με τυχόν τροποποιήσεις στις παραμέτρους τους. Μια γραφική αναπαράσταση του τελικού μοντέλου φαίνεται παρακάτω.



Εικόνα 8: Αναπαράσταση του επιλεγμένου μοντέλου

Όσον αφορά τα διανύσματα εισόδου και εξόδου, το μοντέλο για την εκτέλεσή του δέχεται τις ωριαίες τιμές 4 μεταβλητών για 3 ημέρες, συνολικής διάστασης 72, ως είσοδο και παράγει τις ωριαίες τιμές της ταχύτητας του ανέμου για το επόμενο 24ωρο, συνολικής διάστασης 24.

Αναλυτικότερα, για τα εσωτερικά δίκτυα χρησιμοποιήθηκε η συνάρτηση ενεργοποίησης ReLU, της οποίας η γραφική παράσταση φαίνεται παρακάτω. Συνολικά για το μοντέλο, η loss function ήταν το μέσο απόλυτο σφάλμα (MAE), ενώ χρησιμοποιήθηκε και ο αλγόριθμος βελτιστοποίησης Adam [9] για την βελτίωση της σύγκλισης του μοντέλου. Η αλλαγή του μεγέθους παρτίδας (batch size), δηλαδή το ανά πόσα δείγματα εκπαίδευσης το δίκτυο θα διορθώσει τα βάρη του, δεν φάνηκε να παίζει κάποιον καθοριστικό ρόλο στην επιτυχή εκπαίδευση. Ωστόσο, επιλέχθηκε η τιμή 64 τόσο λόγω των ελαφρώς καλύτερων αποτελεσμάτων όσο και του μικρού υπολογιστικού κόστους που είχε σε σχέση με μεγαλύτερες τιμές. Το δίκτυο είχε έναν προκαθορισμένο αριθμό από 300 επαναλήψεις εκπαίδευσης (epochs), αριθμός που φάνηκε να είναι αρκετός για να συγκλίνει όσο ήταν εφικτό. Στην περίπτωση που το δίκτυο δεν είχε βελτιώσει το μέσο απόλυτο σφάλμα του σε 20 επαναλήψεις, η εκπαίδευση διακοπτόταν πρόωρα, για εξοικονόμηση χρόνου και αποφυγή υπερπροσαρμογής στο σύνολο εκπαίδευσης. Το τελευταίο ειδικά αποτελούσε συχνό πρόβλημα όσο αυξανόταν ο αριθμός επαναλήψεων, όπως φαίνεται στο κεφάλαιο 4.2.



Εικόνα 9: Γραφική αναπαράσταση της συνάρτησης ενεργοποίησης ReLU

3.2 Περιορισμοί μοντέλου

Παρά την υψηλή ακρίβεια στα παραπάνω σύνολα, το μοντέλο δεν ήταν ικανό να προβλέψει με ακρίβεια περιόδους διαφορετικών ετών από αυτά στα οποία εκπαιδεύτηκε. Αυτό μπορεί να ερμηνευθεί μόνο αν εξεταστεί η αστάθεια των καιρικών φαινομένων από έτος σε έτος, η οποία όμως δεν φαίνεται να αποκτά σημαντικά μεγέθη. Σε κάθε περίπτωση, το γεγονός αυτό διορθώνεται άμεσα με την επανεκπαίδευση του δικτύου στο έτος ενδιαφέροντος, κάτι το οποίο και εφαρμόστηκε με θετικά αποτελέσματα. Επίσης, η χρήση περισσότερων δεδομένων δεν ήταν πάντα βοηθητική για το μοντέλο. Συνήθως, τα μοντέλα νευρωνικών δικτύων πετυχαίνουν βέλτιστα αποτελέσματα όταν τους παρέχονται πολυπληθή δεδομένα. Αντιθέτως, στο συγκεκριμένο μοντέλο, ένα σύνολο στοχευμένων (χρονικά) δεδομένων φάνηκε να λειτουργεί καλύτερα. Περισσότερες πληροφορίες για τα παραπάνω παρέχονται στο κεφάλαιο 4.

4. ΠΕΙΡΑΜΑΤΑ

4.1 Αξιολόγηση αποτελεσμάτων

Για την αξιολόγηση των αποτελεσμάτων των πειραμάτων, χρησιμοποιήθηκαν 3 κύριες μετρικές. Αυτές ήταν η μέση απόλυτη ποσοστιαία απόκλιση των προβλέψεων από τις πραγματικές τιμές (MAPE), η μέση απόλυτη απόκλιση των προβλέψεων από τις πραγματικές τιμές (MAE) και η μέση απόκλιση των προβλέψεων από τις πραγματικές τιμές (ME).


$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{a_t - x_t}{a_t} \right|$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |a_t - x_t|$$

$$ME = \frac{1}{n} \sum_{t=1}^n a_t - x_t$$

Εικόνα 10: Συναρτήσεις των επιλεγμένων σφαλμάτων

Συνήθως, η τελευταία δεν αποτελεί μια αξιόπιστη μετρική, ωστόσο στην περίπτωση που εξετάζουμε η ακρίβεια της μέσης τιμής του ανέμου στη διάρκεια της ημέρας είναι εξίσου σημαντική σε σχέση με την ακρίβεια για κάθε μεμονωμένη ώρα. Παρατηρήθηκε συχνά το φαινόμενο ένα μοντέλο να προβλέπει σωστά τις διακυμάνσεις του ανέμου, αλλά με μια μικρή διαφορά φάσης σε σχέση με τις πραγματικές τιμές. Σε τέτοιες περιπτώσεις, που εμφανίζονταν συχνά, η μέση ταχύτητα στο εύρος της ημέρας ήταν πολύ ακριβής αλλά η απόλυτη μέση απόκλιση απείχε σημαντικά. Στην παρακάτω εικόνα (εικόνα 3) φαίνεται πως το μοντέλο προέβλεψε την αυξομείωση του ανέμου, αλλά είχε διαφορά φάσης σε σχέση με την πραγματικότητα.




Εικόνα 11: Προβλέψεις (με πορτοκαλί) και πραγματικές τιμές (με μπλε) για μια ημέρα

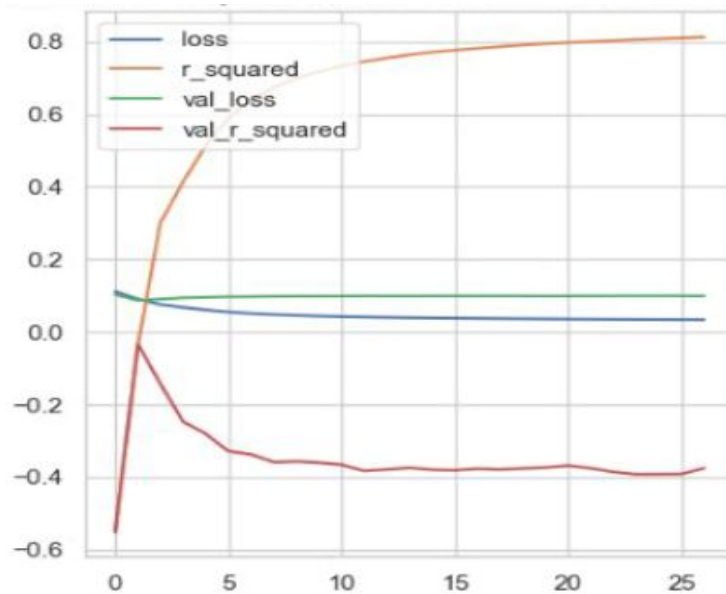
4.2 Προσπάθειες ελάττωσης υπερπροσαρμογής

Από τις πρώτες δοκιμές, έγινε αντιληπτή μια αισθητή υπερπροσαρμογή του δικτύου υπέρ των δεδομένων στα οποία είχε εκπαιδευτεί. Ακόμα και κατά την επιλογή του μοντέλου, υπήρχε μια σημαντική διαφορά 10% μεταξύ των δύο ανεξάρτητων συνόλων δεδομένων όπως περιγράφεται παραπάνω. Ιδιαίτερο ενδιαφέρον παρουσίαζε το γεγονός πως η εκπαίδευση με μεγαλύτερο σετ δεδομένων, είτε αυτό προέκυπτε από περισσότερα προηγούμενα έτη είτε από προσθήκη γειτονικών γεωγραφικών περιοχών, δεν αποθάρρυνε την υπερπροσαρμογή, όπως θα ήταν αναμενόμενο. Έτσι, προτιμήθηκε η εκπαίδευση του μοντέλου σε περιόδους πιο κοντινές στην ζητούμενη, και μόνο για την περιοχή ενδιαφέροντος.

Στις παρακάτω εικόνες φαίνεται το γεγονός αυτό. Στον οριζόντιο άξονα είναι οι επαναλήψεις εκπαίδευσης του μοντέλου, ενώ στον κατακόρυφο άξονα είναι οι μετρήσεις των τιμών του υπομνήματος. Οι τιμές με το πρόθεμα `val` αποτελούν τις τιμές του συνόλου επαλήθευσης (validation set), ενώ οι άλλες τις τιμές του συνόλου εκπαίδευσης. Για τις τιμές `loss` και `val_loss` το 0 είναι το βέλτιστο, ενώ για τις τιμές `r_squared` και `val_r_squared` το 1 είναι το βέλτιστο. Παρατηρούμε πως μετά τις πρώτες επαναλήψεις, οι τιμές αρχίζουν να αποκλίνουν σημαντικά, και οι τιμές του συνόλου επαλήθευσης συγκλίνουν σημαντικά πιο αργά από αυτές του συνόλου εκπαίδευσης.



Εικόνα 12: Παρατηρούμενη υπερπροσαρμογή σε σύνολο δεδομένων της τάξης των 20000 εγγραφών (1 περιοχή, έτη 2010, 2011, 2012)




Εικόνα 13: Παρατηρούμενη υπερπροσαρμογή σε σύνολο δεδομένων της τάξης των 120000 εγγραφών (7 γειτονικές περιοχές, έτη 2011, 2012)

4.3 Ιδανικό σύνολο δεδομένων


Συγκεκριμένα, τα καλύτερα αποτελέσματα μετά από έναν κύκλο εκπαίδευσης συστηματικά προέκυπταν μετά από εκπαίδευση στην ίδια χρονική περίοδο με τη ζητούμενη, το ακριβώς προηγούμενο έτος. Φαίνεται πως η μεμονωμένη περίπτωση για την οποία εκπαιδεύονταν το μοντέλο, ελάττωνε τη “σύγχυση” του και οδηγούσε σε πιο ειδικευμένη βελτιστοποίηση των παραμέτρων του, οδηγώντας και σε καλύτερες προβλέψεις. Αυτό είναι κάτι που παρατηρήθηκε χρησιμοποιώντας τα δεδομένα από τον Μάιο των ετών 2011 και 2012 για το συγκεκριμένο πείραμα. Παραδόξως, η χρήση πολλών γειτονικών γεωγραφικών περιοχών για μεγαλύτερο πλήθος δεδομένων δεν έδινε καλύτερα αποτελέσματα (βλ. εικόνα 14).

Τα αποτελέσματα αυτά ήταν ακόμα καλύτερα όταν το, ήδη εκπαιδευμένο κατ’αυτόν τον τρόπο, μοντέλο επανεκπαιδεύονταν στις μετρήσεις του έτους για το οποίο γινόταν η πρόβλεψη (βλ. εικόνα 16). Δηλαδή, το προηγούμενο μοντέλο εκπαιδεύονταν στους μήνες Ιανουάριο - Μάρτιο του έτους 2012 πριν προβλέψει τον Μάιο του 2012. Παραδόξως, αντίστοιχη βελτίωση δεν παρατηρήθηκε όταν το μοντέλο εκπαιδεύονταν σε όλα τα δεδομένα ταυτόχρονα (βλ. εικόνα 15).


Έτσι, φαίνεται πως ήταν σημαντικό για το μοντέλο να έχει προσαρμόσει τις παραμέτρους του στις συνθήκες της συγκεκριμένης περιοχής, και έπειτα να κάνει “διορθωτικές” αλλαγές με βάση την τάση του τωρινού έτους.



Εικόνα 14: Προβλέψεις (με πορτοκαλί) και πραγματικές τιμές (με μπλε) (MAPE: 97%, MAE: 3.5 m/s, ME: -0.59 m/s)



Εικόνα 15: Προβλέψεις (με πορτοκαλί) και πραγματικές τιμές (με μπλε) (MAPE: 67,5%, MAE: 2.9 m/s, ME: 0.22 m/s)



Εικόνα 16: Προβλέψεις (με πορτοκαλί) και πραγματικές τιμές (με μπλε) (MAPE: 73%, MAE: 2.2 m/s, ME: 0,007 m/s)

Συνοψίζοντας, ο ιδανικότερος τρόπος εκπαίδευσης από αυτούς που εξετάστηκαν, έχοντας ως ζητούμενο τον Μάιο του έτους 2012 για μια γεωγραφική περιοχή, ήταν η εκπαίδευση στα δεδομένα όλου του έτους 2011 για την περιοχή αυτή, με επανεκπαίδευση στα δεδομένα Ιανουαρίου - Μαρτίου του έτους 2012.

4.4 Χρήση πολλαπλών δικτύων (ensemble network)

Μία ακόμα τεχνική που χρησιμοποιήθηκε για την βελτιστοποίηση του μοντέλου, ήταν η χρήση πολλών παρεμφερών μοντέλων, με τυχαίες αρχικές τιμές παραμέτρων. Αναλυτικότερα, τα μοντέλα εκπαιδεύονταν στο ίδιο σύνολο δεδομένων, και έπειτα χρησιμοποιούνταν για την πρόβλεψη. Η τελική πρόβλεψη που λαμβανόταν υπ'όψη ήταν ο μέσος όρος των επιμέρους προβλέψεων όλων των δικτύων.

Αυτή είναι μια τεχνική που έχει ήδη χρησιμοποιηθεί με επιτυχία με δίκτυα διαφορετικής αρχιτεκτονικής, και φάνηκε να βελτιώνει την πρόβλεψη ακόμα και με την ίδια αρχιτεκτονική μεταξύ των δικτύων. Καθώς τα μοντέλα νευρωνικών δικτύων τείνουν να “παγιδεύονται” σε κάποια τοπικά βέλτιστα σημεία όσον αφορά τις τιμές των παραμέτρων τους, η χρήση πολλών μοντέλων βοηθάει στην εύρεση όσο το δυνατόν περισσότερων τέτοιων σημείων οδηγώντας συνήθως σε καλύτερες συνολικές προβλέψεις.

Συγκεκριμένα, στη συγκεκριμένη εργασία χρησιμοποιήθηκε ένα σύνολο από 20 όμοιας αρχιτεκτονικής μοντέλα, με τυχαίες (και διαφορετικές) αρχικές παραμέτρους. Παρ'ότι μικρή, υπήρξε βελτίωση 10% στο μέσο απόλυτο σφάλμα και σχεδόν 40% στο μέσο όρο ταχύτητας ανέμου για όλη την ημέρα κατ'αυτόν τον τρόπο. Ειδικά εφ'όσον το κόστος για τη χρήση αυτού του δικτύου ήταν ελάχιστο, δεδομένου ότι τα επιμέρους δίκτυα είχαν την ίδια αρχιτεκτονική και η εκπαίδευσή τους έχει μικρή χρονική διάρκεια, η βελτίωση αυτή είναι σαφώς ωφέλιμη.

Τα πειράματα περιορίστηκαν σε εκπαίδευση στο προηγούμενο και το τρέχον έτος χωρίς επανεκπαίδευση, καθώς το πλήθος των μοντέλων ήταν αρκετά υψηλό ώστε να κάνει την επανεκπαίδευσή τους ασύμφορη χρονικά.

4.5 Ανάλυση αποτελεσμάτων

Τα αποτελέσματα των πειραμάτων έδειξαν πως είναι εφικτό να προβλεφθεί με πολύ μεγάλη ακρίβεια η μέση ταχύτητα του ανέμου σε βάθος 24 ωρών, παρά την πολύ υψηλή αστάθεια που παρουσίαζε η ταχύτητα του ανέμου στη συγκεκριμένη περιοχή. Ειδικά με τη χρήση μεταγενέστερης εκπαίδευσης, η ακρίβεια είναι πολύ υψηλή, ακόμα και σε προβλέψεις που περιλαμβάνουν πολλές συνεχόμενες ημέρες.

Παρά το υψηλό μέσο σφάλμα σε μεμονωμένες προβλέψεις, ειδικά κατά τις περιόδους μεγάλης αστάθειας του ανέμου, το μοντέλο ήταν ικανό να προβλέψει το γενικό μοτίβο της αυξομειώσης της ταχύτητας του ανέμου με σημαντική ακρίβεια, δίνοντας μια καλή εικόνα της πιθανής αστάθειας του ανέμου της περιοχής.

Συγκεκριμένα, παρακάτω παρουσιάζεται ένας πίνακας με τις τιμές των σφαλμάτων και των συνόλων δεδομένων που χρησιμοποιήθηκαν, για το προτεινόμενο μοντέλο, κατά την πρόβλεψη του Μαΐου του 2012 (συνολικά 30 διανύσματα εισόδου προς πρόβλεψη), σε σχέση με το σύνολο δεδομένων που αξιοποιήθηκαν για την εκπαίδευση του δικτύου. Υπενθυμίζεται πως κάθε διάνυσμα εισόδου αποτελείται από τις 4 μετρικές που συλλέχθηκαν για κάθε χρονικό στιγμιότυπο, για όλες τις ώρες τριών συνεχόμενων ημερών, με βάση τα όσα περιγράφονται και στο κεφάλαιο 2. Επίσης, παρουσιάζεται ένας πίνακας που δείχνει πιο αναλυτικά τα αποτελέσματα που επιτεύχθηκαν με τη χρήση συνόλου δικτύων.

Πίνακας 1: Αποτελέσματα μεμονωμένου μοντέλου ως προς το σύνολο δεδομένων εκπαίδευσης

Σύνολο δεδομένων από μία περιοχή	MAPE	MAE	ME
360 διανύσματα του προηγούμενου έτους + επανεκπαίδευση σε 60 διανύσματα του έτους πρόβλεψης	73%	2.2 m/s	0.007 m/s
420 διανύσματα του προηγούμενου και του έτους πρόβλεψης σε ενιαία εκπαίδευση	67.5%	2.9 m/s	0.22 m/s
360 διανύσματα του προηγούμενου έτους	77%	3.1 m/s	0.42 m/s
Σύνολο δεδομένων από 7 γειτονικές γεωγραφικές περιοχές	MAPE	MAE	ME
360 διανύσματα του προηγούμενου έτους + επανεκπαίδευση σε 60 διανύσματα του έτους πρόβλεψης	82%	3 m/s	-0.47 m/s

Πρόβλεψη ταχύτητας ανέμου με τη χρήση παρελθοντικών δεδομένων

420 διανύσματα του προηγούμενου και του έτους πρόβλεψης σε ενιαία εκπαίδευση	97%	3.5 m/s	-0.59 m/s
360 διανύσματα του προηγούμενου έτους	93%	3.3 m/s	0.62 m/s

Πίνακας 2: Σύγκριση αποτελεσμάτων μεμονωμένου και συνόλου δικτύων

Είδος δικτύου	MAPE	MAE	ME
Μεμονωμένο	67.5%	2.9 m/s	0.22 m/s
Συνδιασμός 5 δικτύων	69.1%	2.8 m/s	0.19 m/s
Συνδιασμός 20 δικτύων	67.3%	2.6 m/s	0.14 m/s

5. ΣΥΜΠΕΡΑΣΜΑΤΑ

5.1 Σύνοψη αποτελεσμάτων

Η ακριβής πρόβλεψη της ταχύτητας του ανέμου αποτελούσε και αποτελεί ένα δύσκολο έργο, παρά την εξέλιξη των διαθέσιμων τεχνολογικών μέσων. Πάρ' αυτά, ειδικά με τη χρήση ιδανικότερων συνόλων δεδομένων και επανεκπαίδευσης των σχεδιασμένων μοντέλων, φάνηκε πως η μέση ταχύτητα στη διάρκεια της ημέρας μπορεί να προβλεφθεί με πολύ ικανοποιητική ακρίβεια, ακόμα και αν οι προβλέψεις σε μεμονωμένες τιμές απείχαν από την πραγματική τιμή. Επίσης, καθώς το προτεινόμενο μοντέλο απαιτεί ελάχιστο χρόνο για την εκπαίδευσή του, είναι ιδιαίτερα ευέλικτο και μπορεί άμεσα να χρησιμοποιηθεί και σε άλλες γεωγραφικές περιοχές.

5.2 Μελλοντικές επεκτάσεις

Στην παρούσα εργασία παρουσιάστηκε ένα μοντέλο βασισμένο σε νευρωνικά δίκτυα το οποίο παρέχει σημαντική ευελιξία και ικανοποιητικά αποτελέσματα για τις ανάγκες μας, εφόσον αξιοποιηθεί κατάλληλα το σύνολο δεδομένων. Στο μέλλον, είναι δυνατόν να επιβεβαιωθεί η ευελιξία του μοντέλου με τη χρήση του σε άλλες περιοχές με διαφορετικό κλίμα. Ακόμα, ενδιαφέρον θα μπορούσε να παρουσιάσει η χρήση των ειδικευμένων συνόλων δεδομένων που έδωσαν τα βέλτιστα αποτελέσματα στην παρούσα εργασία και σε άλλα, πιο σύνθετα μοντέλα πρόβλεψης. Συνήθως ένα μεγαλύτερο σύνολο δεδομένων τείνει να βελτιστοποιεί την απόδοση των νευρωνικών δικτύων, όμως το γεγονός ότι δεν έγινε αυτό στην συγκεκριμένη περίπτωση ίσως είναι ένα δείγμα για την σημασία της προσαρμογής του συνόλου εκπαίδευσης στις ανάγκες της πρόβλεψης.

ΣΥΝΤΜΗΣΕΙΣ – ΑΡΚΤΙΚΟΛΕΞΑ – ΑΚΡΩΝΥΜΙΑ

RNN	Recurrent Neural Network
NREL	National Renewable Energy Laboratory
MAPE	Mean Absolute Percentage Error
MAE	Mean Absolute Error
ME	Mean Error

ΑΝΑΦΟΡΕΣ

- [1] Schmidhuber, Jürgen (January 2015). "Deep Learning in Neural Networks: An Overview". *Neural Networks*. 61: 85–117. arXiv:1404.7828. doi:10.1016/j.neunet.2014.09.003. PMID 25462637.
- [2] Fernández, Santiago; Graves, Alex; Schmidhuber, Jürgen (2007). An Application of Recurrent Neural Networks to Discriminative Keyword Spotting. *Proceedings of the 17th International Conference on Artificial Neural Networks. ICANN'07. Berlin, Heidelberg: Springer-Verlag.* pp. 220–229. ISBN 978-3-540-74693-5.
- [3] Balluff, S., Bendfeld, J., & Krauter, S. Short term wind and energy prediction for offshore wind farms using neural networks. *2015 Int. Conf. on Renewable Energy Research and Applications (ICRERA)*, pp. 379–382, 2015.
- [4] Ghaderi, A., Sanandaji, B. M., & Ghaderi, F. Deep forecast: Deep learning-based spatiotemporal forecasting. *CoRR*, Vol. abs/1707.08110, 2017
- [5] D. Dong, Z. Sheng, T. Yang, Wind Power Prediction Based on Recurrent Neural Network with Long Short-Term Memory Units
- [6] Tzamos Charalambos, VentusNet: Deep Learning for Wind Speed prediction, 2019
- [7] Velusamy, Ranganayaki & Deepa, S N. (2016). An Intelligent Ensemble Neural Network Model for Wind Speed Prediction in Renewable Energy Systems. *The Scientific World Journal*. 2016. 1-14. 10.1155/2016/9293529
- [8] Eze, E. C., & Chatwin, C. R. (2019). Enhanced Recurrent Neural Network for Short-term Wind Farm Power Output Prediction. *IJRDO - Journal of Applied Science (ISSN: 2455-6653)*, 5(2), 28-35.
- [9] Kingma, Diederik & Ba, Jimmy. (2014). Adam: A Method for Stochastic Optimization. *International Conference on Learning Representations*.
- [10] S. Hochreiter - J. Schmidhuber (1997). Long Short-Term Memory. *Neural Computation*, vol. 9, nr. 8, pp. 1735-1780, 1997