

ΕΥΣΤΑΘΟΠΟΥΛΟΣ ΝΙΚΟΛΑΟΣ

**Μεσοπρόθεσμη Πρόβλεψη Ηλιακής Ακτινοβολίας και Ταχύτητας Ανέμου
βασισμένη σε Δεδομένα Ωριαίων Χρονοσειρών Μικρής Κλίμακας**

ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ
ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΕΝΕΡΓΕΙΑΣ



**Μεσοπρόθεσμη Πρόβλεψη Ηλιακής Ακτινοβολίας και Ταχύτητας Ανέμου
βασισμένη σε Δεδομένα Ωριαίων Χρονοσειρών Μικρής Κλίμακας**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
του φοιτητή

ΝΙΚΟΛΑΟΥ ΕΥΣΤΑΘΟΠΟΥΛΟΥ

Μέλη εξεταστικής επιτροπής:

Γεώργιος Σταυρακάκης: Καθηγητής Πολυτεχνείου Κρήτης, Σχολή Ηλεκτρολόγων
Μηχανικών και Μηχανικών Υπολογιστών (επιβλέπων)

Ευτύχιος Κουτρούλης: Αναπληρωτής Καθηγητής Πολυτεχνείου Κρήτης, Σχολή
Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών (μέλος)

Ιωάννης Κατσίγιαννης: Επίκουρος Καθηγητής Ελληνικού Μεσογειακού
Πανεπιστημίου (μέλος)

ΧΑΝΙΑ,ΕΛΛΑΔΑ
Ιούλιος 2020

Περίληψη

Είναι γεγονός ότι τα τελευταία χρόνια η ζήτηση για ηλεκτρική ενέργεια αυξάνει συνεχώς, ενώ ταυτόχρονα τα αποθέματα σε ορυκτά καύσιμα μειώνονται σταδιακά. Συνεπώς, η ενσωμάτωση των ανανεώσιμων πηγών ενέργειας σε μεγάλη κλίμακα στα Συστήματα Ηλεκτρικής Ενέργειας καθώς και η αναδιάρθρωση των αγορών ηλεκτρικής ενέργειας αποτελούν βασικό μέλημα της ενεργειακής πολιτικής σε παγκόσμιο επίπεδο. Επίσης αν συνυπολογιστεί το γεγονός ότι είναι φιλικές προς το περιβάλλον, σε αντίθεση με τις συμβατικές πηγές ενέργειας, τότε γίνεται φανερό ότι οι ανανεώσιμες πηγές ενέργειας θα διαδραματίσουν καθοριστικό ρόλο στην κάλυψη των ενεργειακών απαιτήσεων στο άμεσο μέλλον. Τόσο η αιολική όσο και η ηλιακή ενέργεια είναι απ' τις πιο ευρέως χρησιμοποιούμενες εναλλακτικές μορφές ενέργειας, πράγμα που επαληθεύεται από την ολοένα και περισσότερο αυξανόμενη εγκατεστημένη ισχύ τους παγκοσμίως. Ωστόσο τόσο στην ηλιακή αλλά ακόμα περισσότερο στην αιολική, παρατηρείται έντονη μεταβλητότητα, πράγμα που καθιστά δύσκολη την διείσδυση τους στα δίκτυα ηλεκτρισμού. Συνεπώς η πρόβλεψη της αιολικής και ηλιακής ισχύος αποτελούν υψηλής σημασίας ζητήματα, τόσο για την ασφαλή λειτουργία του συστήματος και τη διαχείριση των ΑΠΕ, όσο και για την παροχή υψηλής ποιότητας ισχύος με το μικρότερο δυνατό κόστος.

Δεδομένης της σχέσης μεταξύ ηλιακής ακτινοβολίας-ηλιακής ενέργειας, καθώς και ταχύτητας του ανέμου και της ισχύος που παράγουν οι ανεμογεννήτριες, καθίσταται αναγκαίο να δημιουργηθούν μοντέλα τα οποία θα μπορούν να προβλέψουν με την καλύτερη ακρίβεια τις παραπάνω ατμοσφαιρικές μεταβλητές.

Απόρροια όλων όσων αναφέρθηκαν, στα πλαίσια της παρούσας διπλωματικής εργασίας κατασκευάστηκαν μοντέλα μεσοπρόθεσμης πρόβλεψης ταχύτητας ανέμου και ηλιακής ακτινοβολίας. Τα μοντέλα αυτά υπάγονται τόσο στην κατηγορία της τεχνητής νοημοσύνης και μηχανικής μάθησης, όσο και σε προηγμένες μαθηματικές μεθόδους πρόβλεψης. Συγκεκριμένα κατασκευάστηκαν δέντρα απόφασης, νευρωνικά δίκτυα, βαθιά νευρωνικά δίκτυα και αναδρομικά μοντέλα πρόβλεψης με ARMA σφάλματα. Τα δεδομένα που χρησιμοποιήθηκαν σαν είσοδο στα μοντέλα, είναι δεδομένα που έχουν καταγραφεί απ' το νησί Ντία βόρεια του Ηρακλείου Κρήτης (ακατοίκητη περιοχή). Τα δεδομένα αυτά χωρίστηκαν ανά μήνα και στην συνέχεια ακολούθησε η διαδικασία της εκπαίδευσης των μοντέλων και της μεσοπρόθεσμης πρόβλεψης. Η μεσοπρόθεσμη πρόβλεψη έγινε κατά βάση με τη μέθοδο της αναδρομικής πρόβλεψης πολλαπλών βημάτων, σ' όλα τα μοντέλα επιμέρους. Ωστόσο δοκιμάστηκε και η στρατηγική πολλαπλής πρόβλεψης και έγινε σύγκριση με τη βασική μέθοδο πρόβλεψης που εφαρμόστηκε και αναφέρθηκε πιο πάνω. Επιπλέον, χρησιμοποιήθηκαν και δεδομένα τα οποία καταγράφηκαν εντός της περιοχής των Χανίων και συγκεκριμένα απ' τη Χαλέπα. Αυτό έγινε προκειμένου να αναδειχθεί η αξία των δεδομένων στη διαδικασία της εκπαίδευσης και κατ' επέκταση στην πρόβλεψη των χρονοσειρών. Τέλος γίνεται μια αξιολόγηση των σφαλμάτων απ' την εφαρμογή των μοντέλων, καθώς επίσης καταγράφονται συμπεράσματα και ιδέες για μελλοντική έρευνα.

Abstract

It is a fact that in recent years the demand for electricity has been steadily increasing, while at the same time reserves of fossil fuels are gradually declining. Therefore, the integration of renewable energy sources (RES) on a large scale in the Electricity Systems as well as the restructuring of electricity markets are of a major concern to global energy policy. Also, if we take into account the fact that they are environmentally friendly, in contrast to conventional energy sources, then it is obvious that renewable energy sources will play a decisive role in meeting energy requirements in the near future. Both wind and solar energy are among the most widely used alternative forms of energy, as evidenced by their growing global power. However, there is intense variability both in solar and even more in wind energy, which makes it difficult for them to be introduced in electricity networks. Therefore, the forecasting of wind and solar power are very important issues, both for the safe operation of the system and the management of RES, as well as for the provision of high quality power at the lowest possible cost.

Given the relationship between solar radiation and solar energy, as well as wind speed and power generated by wind turbines, it is necessary to create models that can better predict the above atmospheric variables.

As a result of all the above, in the framework of the present dissertation, models of medium-term wind speed and solar radiation prediction were constructed. These models fall into both the category of artificial intelligence and machine learning, as well as advanced mathematical prediction methods. Specifically, regression trees, neural networks, deep neural networks and regression models with ARMA errors were made. The data which were used as input to the models, were recorded from the island Dia (uninhabited area), which is located north of Heraklion, Crete. These data were divided by month and then followed by the process of training the models and the medium-term forecast. The medium-term forecast was basically done using the Recursive Multi-step Forecast method, in all individual models. However, the Multiple Output Forecast Strategy was tested and compared with the basic prediction method mentioned above. In addition, data were used, which were recorded within the area of Chania, specifically in Chalepa. This was done in order to highlight the value of data in the training process and consequently in the forecasting of time series. Finally, the errors from the application of the models are evaluated, as well as conclusions and ideas for future research are recorded.

Ευχαριστίες

Πρώτα απ' όλα θα ήθελα να ευχαριστήσω την οικογένειά μου και τους γονείς μου για την αγάπη, την εμπιστοσύνη και την πολύτιμη προσφορά τους σ' αυτό που είμαι και σ' ό,τι έχω πετύχει μέχρι τώρα. Θα ήθελα επίσης να ευχαριστήσω το κορίτσι μου, για την αγάπη και τη στήριξη της σε κάθε βήμα που κάνω.

Επιπλέον, θα ήθελα να εκφράσω θερμές ευχαριστίες στους καθηγητές Γεώργιο Σταυρακάκη και Ιωάννη Κατσίγιαννη για την πολύτιμη προσφορά τους στην εκπόνηση της διπλωματικής μου εργασίας, καθώς και στον κύριο Ευτύχιο Κουτρούλη που συμμετείχε στην επιτροπή.

Θα ήθελα επίσης να ευχαριστήσω τους φίλους μου αλλά και συνάδελφους, Αργύρη και Μάκη για όλες τις στιγμές που περάσαμε μαζί και τους εύχομαι καλή επιτυχία σ' ό,τι ακολουθήσουν. Τέλος θα ήθελα να ευχαριστήσω και το φίλο μου το Νικόλα, για την καλή παρέα αλλά και την πολύτιμη βοήθεια του στο κομμάτι της μετάφρασης της διπλωματικής εργασίας.

Πίνακας περιεχομένων

Περίληψη.....	5
Abstract.....	6
Ευχαριστίες.....	7
Λίστα Εικόνων.....	10
Λίστα Πινάκων.....	11
Λίστα Συντομογραφιών.....	12
Κεφάλαιο 1: Εισαγωγή.....	13
Κεφάλαιο 2: Θεωρητικό Υπόβαθρο.....	15
2.1: Τεχνητή Νοημοσύνη.....	15
2.1.1: Μηχανική Μάθηση (Machine Learning)-Βαθιά Μηχανική Μάθηση (Deep Machine Learning).....	15
2.1.1.1: Τεχνητά Νευρωνικά Δίκτυα & «Βαθιά» Νευρωνικά Δίκτυα.....	17
2.2: Προηγμένες μαθηματικές μέθοδοι πρόβλεψης.....	19
2.2.1: Μοντέλα AR,MA,ARMA,ARIMA.....	19
2.2.2: Αναδρομικά μοντέλα πρόβλεψης με ARMA,ARIMA Σφάλματα.....	20
Κεφάλαιο 3: Μοντέλα Πρόβλεψης.....	21
3.1: Γενική Περιγραφή των Μοντέλων Πρόβλεψης.....	21
3.2: Δέντρα Απόφασης (Decision Trees).....	21
3.2.1: Κλασικοί Αλγόριθμοι Μάθησης.....	22
3.2.1.1: Bootstrapping.....	22
3.2.1.2: Bagging (Bootstrap Aggregating).....	23
3.2.1.3: Η Μέθοδος των Τυχαίων Δασών (Random forests).....	24
3.3: Μη-γραμμικό αυτό-ρυθμιζόμενο εξωγενές μοντέλο (NARX).....	25
3.4: Βαθιά Νευρωνικά Δίκτυα Μακράς-Βραχείας Διάρκειας Μνήμης (LSTM).....	26
3.5: Αναδρομικά μοντέλα πρόβλεψης με ARIMA/ARMA Σφάλματα (Regression model with ARIMA/ARMA time series errors).....	32
Κεφάλαιο 4: Σχεδιασμός μοντέλων & Μεσοπρόθεσμη πρόβλεψη.....	34
4.1: Παρουσίαση των δεδομένων και προεπεξεργασία.....	34
4.2: Κατασκευή και Προγραμματισμός Μοντέλων.....	34
4.2.1: Μοντέλα Πρόβλεψης Ταχύτητας Ανέμου.....	35
4.2.2: Μοντέλα Πρόβλεψης Ηλιακής Ακτινοβολίας.....	42
4.3: Εκπαίδευση Μοντέλων και Πρόβλεψη.....	45
4.4: Μέθοδοι Μεσοπρόθεσμης Πρόβλεψης.....	50
Κεφάλαιο 5: Αποτελέσματα μεσοπρόθεσμης πρόβλεψης.....	52
5.1: Αποτελέσματα μεσοπρόθεσμης πρόβλεψης ταχύτητας ανέμου συγκεντρωτικά ανά μήνα.....	52
5.2: Αποτελέσματα μεσοπρόθεσμης πρόβλεψης ηλιακής ακτινοβολίας συγκεντρωτικά ανά μήνα.....	59
Κεφάλαιο 6: Σύγκριση αποτελεσμάτων μεσοπρόθεσμης πρόβλεψης μεταξύ διαφορετικών μεθόδων πρόβλεψης.....	65

Κεφάλαιο 7: Σύγκριση αποτελεσμάτων μεσοπρόθεσμης πρόβλεψης μεταξύ καταγεγραμμένων δεδομένων αστικού περιβάλλοντος & βραχονησίδας	70
Κεφάλαιο 8: Αξιολόγηση αποτελεσμάτων βάσει των σχέσεων μέτρησης σφάλματος.....	74
Κεφάλαιο 9: Παράθεση αποτελεσμάτων των σχέσεων μέτρησης σφάλματος	80
9.1: Αποτελέσματα Πρόβλεψης Ταχύτητας Ανέμου	80
9.2: Αποτελέσματα Πρόβλεψης Ηλιακής Ακτινοβολίας	82
Κεφάλαιο 10: Παρατηρήσεις & Συμπεράσματα	84
Ιδέες για Μελλοντική Έρευνα.....	87
Βιβλιογραφία.....	88

Λίστα Εικόνων

Εικόνα 1: Αντιστοίχιση τεχνητού - βιολογικού νευρώνα.....	17
Εικόνα 2: Τεχνητός νευρώνας.....	18
Εικόνα 3: Δίκτυο νευρώνων ανθρώπινου εγκεφάλου - Δίκτυο τεχνητής νοημοσύνης.....	18
Εικόνα 4: Μέθοδος Bootstrap.....	23
Εικόνα 5: Μέθοδος Bagging.....	24
Εικόνα 6: Δομή μοντέλου NARX.....	26
Εικόνα 7: Τμήμα επαναλαμβανόμενου νευρωνικού δικτύου.....	26
Εικόνα 8: Αποδομημένο επαναλαμβανόμενο νευρωνικό δίκτυο.....	27
Εικόνα 9: Παράδειγμα 1.....	27
Εικόνα 10: Παράδειγμα 2.....	28
Εικόνα 11: Το επαναλαμβανόμενο τμήμα σε ένα τυπικό ΕΝΔ περιέχει ένα στρώμα.....	28
Εικόνα 12: 4 επίπεδα ενός ΝΔΜΒΜ που αλληλεπιδρούν.....	29
Εικόνα 13: Σύμβολα που περιέχονται στο ΝΔΜΒΜ.....	29
Εικόνα 14: Οριζόντια γραμμή της κυψελικής κατάστασης του ΝΔΜΒΜ.....	29
Εικόνα 15: Πύλη ΝΔΜΒΜ.....	30
Εικόνα 16: Κυψέλη ΝΔΜΒΜ-Πρώτο βήμα.....	30
Εικόνα 17: Κυψέλη ΝΔΜΒΜ-Δεύτερο βήμα.....	31
Εικόνα 18: Κυψέλη ΝΔΜΒΜ-Τρίτο βήμα.....	31
Εικόνα 19: Κυψέλη ΝΔΜΒΜ-Τέταρτο βήμα.....	32
Εικόνα 20: Εύρεση βέλτιστου ελάχιστου μεγέθους φύλλων του μοντέλου για την πρόβλεψη ταχύτητας ανέμου.....	35
Εικόνα 21: Σημασία/Βαρύτητα κάθε μεταβλητής εισόδου του μοντέλου για την πρόβλεψη ταχύτητας ανέμου.....	36
Εικόνα 22: Στιγμιότυπο δέντρου απόφασης για την πρόβλεψη ταχύτητας ανέμου.....	36
Εικόνα 23: Στιγμιότυπο δέντρου απόφασης με ετικέτες στους κόμβους για την πρόβλεψη ταχύτητας ανέμου.....	37
Εικόνα 24: Αρχιτεκτονική παράλληλης σειράς για την πρόβλεψη ταχύτητας ανέμου.....	37
Εικόνα 25: Παράλληλη Αρχιτεκτονική για μεσοπρόθεσμη πρόβλεψη ταχύτητας ανέμου.....	38
Εικόνα 26: Βήματα για την πρόβλεψη με το μοντέλο NARX.....	39
Εικόνα 27: Παράμετροι αναδρομικού μοντέλου με ARMA σφάλματα για την πρόβλεψη ταχύτητας ανέμου.....	40
Εικόνα 28: Μορφή DNN.....	41
Εικόνα 29: Εύρεση βέλτιστου ελάχιστου μεγέθους φύλλων για την πρόβλεψη ηλιακής ακτινοβολίας.....	42
Εικόνα 30: Σημασία/Βαρύτητα κάθε μεταβλητής εισόδου για την πρόβλεψη ηλιακής ακτινοβολίας.....	43
Εικόνα 31: Στιγμιότυπο δέντρου απόφασης για την πρόβλεψη ηλιακής ακτινοβολίας.....	43
Εικόνα 32: Στιγμιότυπο δέντρου απόφασης με ετικέτες στους κόμβους για την πρόβλεψη ηλιακής ακτινοβολίας.....	44
Εικόνα 33: Αρχιτεκτονική παράλληλης σειράς του μοντέλου NARX για την πρόβλεψη ηλιακής ακτινοβολίας.....	44
Εικόνα 34: Παράλληλη Αρχιτεκτονική για μεσοπρόθεσμη πρόβλεψη ηλιακής ακτινοβολίας.....	45
Εικόνα 35: Δεδομένα ανέμου του Training-set.....	47
Εικόνα 36: Δεδομένα ανέμου του Test-set.....	48
Εικόνα 37: Ηλιακή Ακτινοβολία- Training Set.....	49
Εικόνα 38: Ηλιακή Ακτινοβολία - Test Set.....	49
Εικόνα 39: Συμπεράσματα εξισώσεων μέτρησης σφάλματος.....	76

Λίστα Πινάκων

Πίνακας 1: Αποτελέσματα σχέσεων μέτρησης σφάλματος, πρόβλεψης ταχύτητας ανέμου μοντέλου NARX, μεταξύ δεδομένων αστικού περιβάλλοντος και βραχονησίδας.....	71
Πίνακας 2: Αποτελέσματα σχέσεων μέτρησης σφάλματος, πρόβλεψης ταχύτητας ανέμου μοντέλου LSTM, μεταξύ δεδομένων αστικού περιβάλλοντος και βραχονησίδας.....	72
Πίνακας 3: Αποτελέσματα σχέσεων μέτρησης σφάλματος, πρόβλεψης ηλιακής ακτινοβολίας μοντέλου NARX, μεταξύ δεδομένων αστικού περιβάλλοντος και βραχονησίδας.....	73
Πίνακας 4: Παραδείγματα υπολογισμού RMSE	77
Πίνακας 5: Αποτελέσματα σχέσεων μέτρησης σφάλματος – Πρόβλεψη Ταχύτητας Ανέμου Χρυσό: BDT, Κόκκινο: NARX, Μπλε: RegARMA, Μαύρο: LSTM.....	80
Πίνακας 6: Μέσες Τιμές Αποτελεσμάτων σχέσεων μέτρησης σφάλματος, – Πρόβλεψη Ταχύτητας Ανέμου – Χρυσό: BDT, Κόκκινο: NARX, Μπλε: RegARMA, Μαύρο: LSTM.....	81
Πίνακας 7: Αποτελέσματα σχέσεων μέτρησης σφάλματος – Πρόβλεψη Ηλιακής Ακτινοβολίας – Χρυσό: BDT, Κόκκινο: NARX, Μπλε: RegARMA.....	82
Πίνακας 8: Μέσες Τιμές Αποτελεσμάτων σχέσεων μέτρησης σφάλματος – Πρόβλεψη Ηλιακής Ακτινοβολίας – Χρυσό: BDT, Κόκκινο: NARX, Μπλε: RegARMA.....	83

Λίστα Συντομογραφιών

TNΔ: Τεχνητά Νευρωνικά Δίκτυα

BNΔ: Βαθιά Νευρωνικά Δίκτυα

ΕΝΔ: Επαναλαμβανόμενα Νευρωνικά Δίκτυα

NΔMBM: Νευρωνικά Δίκτυα Μακράς-Βραχείας διάρκειας Μνήμης

ANNs: Artificial neural networks

DNN: Deep neural network

ARMA: Autoregressive moving average

AR: Autoregressive

MA: Moving average

ARIMA: Autoregressive integrated moving average

Bagging: Bootstrap Aggregating

NARX: Nonlinear Autoregressive Exogenous model

BDT: Bagged Decision Trees

LSTM: Long- Short Term Memory

Regarma: Regression model with Arma Errors

MSE: Mean Squared Error

RMSE: Root Mean Squared Error

MAPE: Mean Absolute Percentage Error

MAE: Mean Absolute Error

SMAPE: Symmetric Mean Absolute Percentage Error

NRMSE: Normalized Root Mean Squared Error

NMSE: Normalized Mean Squared Error

NMAE: Normalized Mean Absolute Error

Κεφάλαιο 1: Εισαγωγή

Ένα αρκετά μεγάλο μέρος της παγκόσμιας και της εγχώριας ενεργειακής ανάγκης καλύπτεται μέσω της καύσης ορυκτών καυσίμων. Ωστόσο όπως είναι γνωστό, η καύση ορυκτών καυσίμων όπως ο άνθρακας, το πετρέλαιο και το φυσικό αέριο για την παραγωγή ενέργειας απελευθερώνει μεγάλη ποσότητα αερίων θερμοκηπίου, τα οποία αποτελούν βασική μέριμνα για το περιβάλλον. Η παραγωγή μιας πιο “καθαρής” και χωρίς άνθρακα ενέργειας, επιτυγχάνεται μέσω της χρήσης ανανεώσιμων πηγών ενέργειας, όπως η αιολική και η ηλιακή ενέργεια για την κάλυψη των ολοένα και περισσότερο ενεργειακών απαιτήσεων. Η απελευθέρωση της αγοράς της ηλεκτρικής ενέργειας σε συνδυασμό με την όλο και μεγαλύτερη ανάγκη για αειφόρο ενέργεια, έχουν στρέψει το πολιτικό και επενδυτικό ενδιαφέρον τεχνολογικά ανεπτυγμένων χωρών στην περεταίρω αξιοποίηση των παραπάνω ανανεώσιμων μορφών ενέργειας για την κάλυψη της ενεργειακής τους ζήτησης. Η ενέργεια που παράγεται τόσο απ’ τον άνεμο όσο και απ’ τον ήλιο, εξαρτάται σε μεγάλο βαθμό από τις καιρικές συνθήκες όπως η θερμοκρασία του αέρα, η ταχύτητα του ανέμου, η ηλιακή ακτινοβολία κλπ. Έτσι λοιπόν η ενέργεια που παράγεται κυρίως απ’ τον άνεμο αλλά και απ’ τον ήλιο είναι αρκετές φορές δύσκολο να ελεγχθεί και να προβλεφτεί, καθώς οι καιρικές συνθήκες μεταβάλλονται συνεχώς. Αυτό καθιστά την ενσωμάτωση της αιολικής και ηλιακής ενέργειας στο δίκτυο σημαντική πρόκληση. [\[33\]](#)

Για την αντιμετώπιση του παραπάνω ζητήματος, είναι σημαντικό να γίνουν ακριβείς προβλέψεις για την αιολική και την ηλιακή ενέργεια, προκειμένου να μειωθεί η αβεβαιότητα σχετικά με την ποσότητα ενέργειας που πρόκειται να παραχθεί στο μέλλον. Δεδομένης της σχέσης μεταξύ ηλιακής ακτινοβολίας-ηλιακής ενέργειας, καθώς και ταχύτητας του ανέμου και της ισχύος που παράγουν οι ανεμογεννήτριες, είναι απαραίτητο να δημιουργηθούν μοντέλα τα οποία θα προβλέπουν με την καλύτερη δυνατή ακρίβεια την ηλιακή ακτινοβολία και την ταχύτητα του ανέμου.

Με την πάροδο των χρόνων έχουν αναπτυχθεί διάφορα εργαλεία για την πρόβλεψη αιολικής και ηλιακής ενέργειας. Στατιστικά μοντέλα καθώς και μοντέλα μηχανικής μάθησης που υπάγονται στον τομέα της τεχνητής νοημοσύνης, είναι τα επικρατέστερα για την πρόβλεψη τέτοιου είδους χρονοσειρών.

Στόχος της παρούσας διπλωματικής εργασίας είναι η ανάπτυξη μοντέλων μεσοπρόθεσμης πρόβλεψης (του επόμενου 24-ωρου) ηλιακής ακτινοβολίας και ταχύτητας ανέμου που θα βασίζεται σε δεδομένα που έχουν καταγραφεί στη βραχονησίδα Ντία, η οποία βρίσκεται βόρεια του Ηρακλείου της Κρήτης.

Η δομή της παρούσας Διπλωματικής Εργασίας είναι η ακόλουθη: Στο Κεφάλαιο 2 παρατίθεται το θεωρητικό υπόβαθρο, που σχετίζεται με τις τεχνικές και τα μοντέλα που εφαρμόστηκαν για τη μεσοπρόθεσμη πρόβλεψη ηλιακής ακτινοβολίας και ταχύτητας ανέμου. Στο Κεφάλαιο 3 καταγράφονται τα μοντέλα που δημιουργήθηκαν καθώς και γενικά ο τρόπος λειτουργίας τους. Στο Κεφάλαιο 4 παρουσιάζεται η διαδικασία του σχεδιασμού των μοντέλων καθώς και της εκπαίδευσης και πρόβλεψης τόσο για την ηλιακή ακτινοβολία όσο και την ταχύτητα

ανέμου. Συγκεκριμένα παρατίθενται αναλυτικά οι παράμετροι των μοντέλων, καθώς επίσης αναλύεται η διαδικασία της εκπαίδευσης και η στρατηγική πρόβλεψης που ακολουθήθηκε. Στο Κεφάλαιο 5 παρουσιάζονται τα αποτελέσματα μεσοπρόθεσμης πρόβλεψης ταχύτητας ανέμου και ηλιακής ακτινοβολίας σχηματικά. Στο Κεφάλαιο 6 βρίσκεται η σύγκριση των αποτελεσμάτων μεταξύ διαφορετικών στρατηγικών πρόβλεψης που ακολουθήθηκαν. Στο Κεφάλαιο 7 συγκρίνονται αποτελέσματα μεσοπρόθεσμης πρόβλεψης ταχύτητας ανέμου και ηλιακής ακτινοβολίας χρησιμοποιώντας σύνολα δεδομένων από κατοικημένη περιοχή (αστικό περιβάλλον) και ακατοίκητη. Στο Κεφάλαιο 8 καταγράφονται οι σχέσεις μέτρησης σφάλματος βάσει των οποίων θα αξιολογηθούν τα αποτελέσματα των μοντέλων. Στο Κεφάλαιο 9 παρατίθενται τα αποτελέσματα των σχέσεων μέτρησης σφάλματος. Στο Κεφάλαιο 10 καταγράφονται τα συμπεράσματα και οι παρατηρήσεις της μεσοπρόθεσμης πρόβλεψης ταχύτητας ανέμου και ηλιακής ακτινοβολίας και τέλος παρατίθενται ιδέες για μελλοντική έρευνα.

Κεφάλαιο 2: Θεωρητικό Υπόβαθρο

2.1: Τεχνητή Νοημοσύνη

Ο όρος τεχνητή νοημοσύνη αναφέρεται στον τομέα της πληροφορικής, ο οποίος ασχολείται με το σχεδιασμό και την υλοποίηση υπολογιστικών συστημάτων που αντιγράφουν στοιχεία της ανθρώπινης συμπεριφοράς, τα οποία υπονοούν έστω και στοιχειώδη ευφυΐα: μάθηση, προσαρμοστικότητα, εξαγωγή συμπερασμάτων, επίλυση προβλημάτων, κατανόηση από συμφραζόμενα κλπ. [34]

2.1.1: Μηχανική Μάθηση (Machine Learning)-Βαθιά Μηχανική Μάθηση (Deep Machine Learning)

Μηχανική Μάθηση

Η μηχανική μάθηση είναι υποσύνολο της τεχνητής νοημοσύνης. Ο όρος μηχανική μάθηση σχετίζεται με τη μελέτη και την ανάπτυξη αλγορίθμων, οι οποίοι θα μπορούν να εκτελούν διαδικασίες, βασισμένοι στην 'εμπειρία' που έχουν αναπτύξει, χρησιμοποιώντας υπάρχοντα δεδομένα. Σε μια πιο ελεύθερη περιγραφή, η μηχανική μάθηση αποτελεί ένα είδος προγραμματισμού που στηρίζεται σε παραδείγματα. Ένα υπολογιστικό σύστημα μαθαίνει, χωρίς απαραίτητα να είναι λεπτομερειακά προγραμματισμένο.

Μέσω των αλγορίθμων που χρησιμοποιούνται στόχος είναι οι υπολογιστές να μαθαίνουν δυναμικά και να είναι σε θέση να προβλέπουν αυτόνομα, χωρίς να παρεμβάλλεται ο ανθρώπινος παράγοντας, καθοδηγώντας τους αλγόριθμους.

Σε αντίθεση με τον άνθρωπο, ένας υπολογιστής έχει τη δυνατότητα να επεξεργαστεί ένα τεράστιο όγκο δεδομένων. Γι' αυτό το λόγο και η μάθηση θα πρέπει να βασίζεται σε όσο το δυνατό περισσότερα δεδομένα, προκειμένου τα αποτελέσματα των προβλέψεων να είναι καλύτερα. Η Μηχανική Μάθηση χωρίζεται σε δυο βασικές κατηγορίες:

1. **Επιβλεπόμενη Μάθηση (Supervised Learning).** Είναι ένας τύπος αλγορίθμου εκμάθησης που χρησιμοποιεί ένα γνωστό σύνολο δεδομένων, που ονομάζεται σύνολο δεδομένων εκπαίδευσης (training dataset) για να κάνει προβλέψεις. Το σύνολο δεδομένων εκπαίδευσης περιλαμβάνει δεδομένα εισόδου και τιμές απόκρισης (αποτέλεσμα των εκάστοτε εισόδων). Από αυτό, ο αλγόριθμος επιβλεπόμενης μάθησης επιδιώκει να δημιουργήσει ένα μοντέλο, που μπορεί να κάνει προβλέψεις των τιμών απόκρισης για ένα νέο σύνολο δεδομένων.
2. **Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning).** Δεν υπάρχουν οι επιθυμητές αποκρίσεις στα δεδομένα που χρησιμοποιούνται, συνεπώς ο αλγόριθμος προσπαθεί να βρει συσχετίσεις και να γενικεύσει (κατηγοριοποιήσει) τα δεδομένα εισόδου.

Η Επιβλεπόμενη Μάθηση περιλαμβάνει δυο βασικές κατηγορίες αλγορίθμων

- Κατηγοριοποίηση (Classification): Για τιμές απόκρισης όπου τα δεδομένα μπορούν να διαχωριστούν σε συγκεκριμένες "κλάσεις".
- Προσέγγιση – Πρόβλεψη (Regression): Για συνεχείς τιμές απόκρισης (continuous-response values).

Κατηγοριοποίηση (Classification)

Στην κατηγορία αυτή υπάρχουν διακριτά δεδομένα, αντί για συνεχή. Οι τιμές εξόδου, αντιστοιχούν σε κατηγορίες στις οποίες κατατάσσονται τα διανύσματα εισόδου. Συνεπώς, παρουσιάζοντας νέα δεδομένα, δεν προσπαθούμε να προσεγγίσουμε την τιμή μιας συνάρτησης, αλλά να κατατάξουμε την είσοδό μας σε κάποια από τις κατηγορίες που είναι γνωστές. Οι κατηγορίες αυτές συνήθως ονομάζονται κλάσεις και μπορεί να έχουν αριθμητικές τιμές, να είναι σύμβολα κλπ. Γενικά ανάλογα με την φύση του προβλήματος που μελετάται, καθορίζονται και οι κλάσεις στις οποίες ομαδοποιούνται τα δεδομένα. Οι μεθοδολογίες που εφαρμόζονται στα προβλήματα κατηγοριοποίησης διαφέρουν αρκετά μεταξύ τους, σε ότι αφορά τον τρόπο με τον οποίο προσπαθούν να ομαδοποιήσουν τα στοιχεία που τους παρέχονται. Στην γενική τους όμως μορφή, εκείνο που προσπαθούν να κάνουν είναι να υπολογίσουν τα όρια μεταξύ των κατηγοριών - κλάσεων (decision boundaries).

Προσέγγιση – Πρόβλεψη (Regression)

Στην περίπτωση της πρόβλεψης, υπάρχουν συνεχή δεδομένα. Θεωρούμε ότι οι έξοδοι των δεδομένων, είναι αποτελέσματα μιας συνάρτησης που εφαρμόζεται πάνω στις εισόδους, η αναλυτική μορφή της οποίας δεν είναι γνωστή.

Χρησιμοποιώντας λοιπόν τα γνωστά δεδομένα, (inputs, outputs), εκπαιδεύεται ένας αλγόριθμος έτσι ώστε η συμπεριφορά του να προσεγγίζει την άγνωστη σε εμάς συνάρτηση. Όταν του εισάγονται οι γνωστές τιμές να δίνει τις σωστές εξόδους και όταν εισάγονται νέες τιμές με άγνωστες τιμές εξόδου, αυτός να μπορεί να προβλέψει την τιμή που θα έδινε σαν έξοδο η άγνωστη συνάρτηση. [\[1\]](#)

Βαθιά Μηχανική Μάθηση

Όπως η μηχανική έτσι και η «βαθιά μάθηση» είναι υποσύνολο της τεχνητής νοημοσύνης, ωστόσο η τελευταία δεν είναι παρά η εξέλιξη της πρώτης. Η βαθιά μάθηση αποτελεί μια επαναστατική προσέγγιση μηχανικής μάθησης, που συνιστά μια ειδική κατηγορία τεχνικών μηχανικής μάθησης, κατά την οποία πολλά επίπεδα επεξεργασίας πληροφοριών σε συστήματα ιεραρχικά εποπτευόμενων τεχνικών, αξιοποιούνται για τη μη εποπτευόμενη εκμάθηση χαρακτηριστικών, καθώς για ανάλυση προτύπων ή κατηγοριοποίηση. Οι καταβολές και τα κίνητρα της βαθιάς μάθησης εντοπίζονται κυρίως στα τεχνητά νευρωνικά δίκτυα, καθώς και σε άλλους συναφείς επιστημονικούς τομείς, όπως η τεχνητή νοημοσύνη, η γνωσιακή νευροεπιστήμη και η επεξεργασία σήματος μεταξύ άλλων. Τα τελευταία χρόνια, τα συστήματα που βασίζονται σε τεχνικές και αλγόριθμους βαθιάς μάθησης έχουν

γίνει ιδιαίτερως δημοφιλής τόσο στην ακαδημαϊκή κοινότητα όσο και σε πολλούς κλάδους της βιομηχανίας, λόγω των εξαιρετικών επιδόσεων των μεθόδων αυτών σε πληθώρα προβλημάτων μηχανικής μάθησης.


2.1.1.1: Τεχνητά Νευρωνικά Δίκτυα & «Βαθιά» Νευρωνικά Δίκτυα

Τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ) είναι συστήματα που τρέχουν αλγόριθμους που βασίζονται σε βιολογικά νευρωνικά δίκτυα. Η αρχική ιδέα ήταν εμπνευσμένη από τις διαδικασίες των εγκεφάλων των ζώων, αλλά αργότερα, στόχος ήταν η δημιουργία αλγορίθμων και η επίλυση προβλημάτων σύμφωνα με τον τρόπο που σκέφτεται ο ανθρώπινος εγκέφαλος. [35]

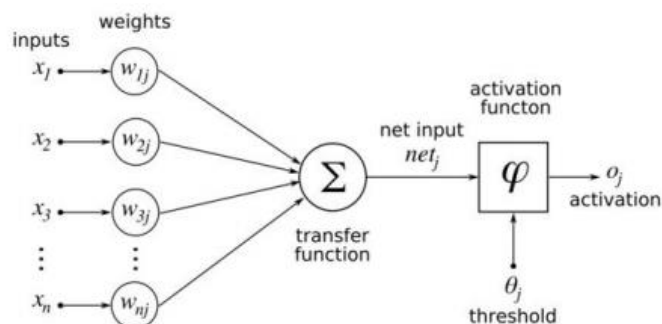
Σε αυτά τα συστήματα, οι έξοδοι και οι παλαιότερες διαδικασίες, αποτελούν πρότερη γνώση που θα χρησιμοποιηθεί τις επόμενες φορές όπου είναι απαραίτητο. Τα ΤΝΔ είναι σε θέση να συγχωνεύσουν, να συνδυάσουν, να συνθέσουν νέα δεδομένα και νέες διαδικασίες με παλαιότερες και να τα επεξεργαστούν με πολλούς τρόπους. Αυτό περιλαμβάνει τη μετάδοση πληροφοριών προς την αντίθετη κατεύθυνση (back-propagation algorithms), προκειμένου όχι μόνο να δώσουν τις ζητούμενες πληροφορίες, αλλά και να εκπαιδευτούν.

Οι νευρώνες (κόμβοι) μεταδίδουν σήματα μεταξύ τους μέσω συνάψεων (συνδέσεων). Οι νευρώνες, οργανώνονται σε στρώματα, το καθένα εκ' των οποίων έχει τη δική του αξία για τη διεξαγωγή της διαδικασίας. Μπορούν επίσης να έχουν ένα «βάρος» που αντιπροσωπεύει την ένταση της σύνδεσης η οποία αυξάνεται ή μειώνεται ενώ η εκμάθηση προχωράει, ρυθμίζοντας το σήμα που στέλνουν στους άλλους νευρώνες. [2]

Επιπλέον ένα σύνολο από νευρώνες με κοινά χαρακτηριστικά, ονομάζεται επίπεδο νευρώνων και μεταξύ της εισόδου και της εξόδου ενός ΤΝΔ, μπορεί να υπάρχουν περισσότερα του ενός επίπεδα, τα λεγόμενα “κρυφά επίπεδα” υπολογισμού ή αλλιώς “hidden layers”, αλλά και αναδρομικά στοιχεία (με τουλάχιστον ένα βρόχο ανάδρασης).



Εικόνα 1: Αντιστοίχιση τεχνητού - βιολογικού νευρώνα



Εικόνα 2: Τεχνητός νευρώνας



Εικόνα 3: Δίκτυο νευρώνων ανθρώπινου εγκεφάλου - Δίκτυο τεχνητής νοημοσύνης

«Βαθιά» Νευρωνικά Δίκτυα (Deep Neural Networks)

Ένα βαθύ νευρωνικό δίκτυο (BND) είναι ένα τεχνητό νευρωνικό δίκτυο (ΤΝΔ), με πολλαπλά στρώματα μεταξύ των επιπέδων εισόδου και εξόδου. Το BND βρίσκει το σωστό μαθηματικό χειρισμό για να μετατρέψει την είσοδο στην έξοδο, είτε πρόκειται για μια γραμμική σχέση, είτε για μια μη γραμμική σχέση. Έτσι είναι σε θέση να εκτελούν τόσο γραμμικές, όσο και μη γραμμικές και εξαιρετικά ποικίλες λειτουργίες.

Συμπερασματικά, τα ΤΝΔ και τα BND αποτελούνται από ένα σύνολο νευρώνων, δηλαδή μιας μονάδας αποθήκευσης και επεξεργασίας πληροφορίας, τα τρία στοιχεία των οποίων είναι ένας αριθμός συνάψεων, ένας αθροιστής και μια συνάρτηση μεταφοράς (ενεργοποίησης) του νευρώνα. Ένας νευρώνας, μπορεί να έχει ένα μεγάλο αριθμό εισόδων αλλά η έξοδός του θα είναι πάντοτε μια, η οποία είναι δυνατό να αποτελεί είσοδο σε κάποιο άλλο νευρώνα, δημιουργώντας έτσι ένα δίκτυο από νευρώνες. Η σημαντικότητα των συνάψεων (βάρη) διαφέρουν σε κάθε νευρώνα, ενώ η συνάρτηση ενεργοποίησης καθορίζει την έξοδο σχετικά με τις σταθμισμένες εισόδους του νευρώνα. Στις εικόνες 1,2 και 3 παρατηρούνται σχηματικά όσα αναφέρθηκαν πιο πάνω.

2.2: Προηγμένες μαθηματικές μέθοδοι πρόβλεψης

2.2.1: Μοντέλα AR,MA,ARMA,ARIMA

Μοντέλο του αυτορρυθμιζόμενου κινούμενου μέσου (ARMA)

Το μοντέλο (autoregressive moving average), **ARMA** είναι ένας συνδυασμός των μοντέλων **AR** και **MA**. Το μοντέλο **AR** είναι το λεγόμενο αυτορρυθμιζόμενο μοντέλο (Autoregressive Model) το οποίο ορίζεται ως (Engineering Statistics Handbook):

$$X_t = \delta + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + A_t$$

Όπου:

X_t :είναι η χρονοσειρά,

A_t :είναι ο λευκός θόρυβος,

$\delta = (1 - \sum_{i=1}^p \phi_i) \mu$, με το μ να δηλώνει τη μέση τιμή της διαδικασίας,

$\phi_1, \phi_2, \dots, \phi_p$ είναι συντελεστές του μοντέλου και p είναι η τελευταία στιγμή της χρονοσειράς $X_{t-1}, X_{t-2}, \dots, X_{t-p}$ η οποία καθορίζει και την τάξη του μοντέλου $AR(p)$

Το μοντέλο **MA** είναι το λεγόμενο μοντέλο του κινούμενου μέσου (Moving Average) και ορίζεται ως εξής:

$$X_t = \mu + A_t - \theta_1 A_{t-1} - \theta_2 A_{t-2} - \dots - \theta_q A_{t-q}$$

Όπου:

X_t :είναι η χρονοσειρά τη χρονική στιγμή t , μ η μέση τιμή της σειράς,

A_t, \dots, A_{t-q} : είναι οι τιμές του λευκού θορύβου,

$\theta_1, \dots, \theta_q$: είναι οι παράμετροι του μοντέλου και η τιμή του q είναι η τάξη του μοντέλου $MA(q)$.

Έχοντας υπόψη τα ανωτέρω, η μέθοδος **ARMA** ορίζεται ως εξής (Engineering Statistics Handbook) :

$$X_t = \delta + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + A_t - \theta_1 A_{t-1} - \theta_2 A_{t-2} - \dots - \theta_q A_{t-q}$$

Το μοντέλο συμβολίζεται ως $ARMA(p,q)$.

Το μοντέλο του αυτορρυθμιζόμενου ολοκληρωμένου κινούμενου μέσου (ARIMA)

Στην περίπτωση που οι χρονοσειρές δεν είναι στάσιμες, συνίσταται η εφαρμογή του μοντέλου **ARIMA**, για την ενσωμάτωση των διαφορών, ώστε η χρονοσειρά να γίνει στάσιμη. Όταν δεν υπάρχει στασιμότητα (μέσος όρος και η διασπορά της αλλάζουν συστηματικά κατά τη διάρκεια του χρόνου), ένα $ARMA(p,q)$

μοντέλο γίνεται $ARIMA(p,d,q)$, όπου το d υποδηλώνει τον αριθμό των διαφορίσεων που απαιτούνται ώστε η χρονοσειρά να γίνει στάσιμη (Moosa, 2016, p. 83). [\[2\]](#)

2.2.2: Αναδρομικά μοντέλα πρόβλεψης με ARMA,ARIMA Σφάλματα

Όταν γίνονται προβλέψεις χρονοσειρών, συχνά τα λάθη (αποκλίσεις) ακολουθούν μια συγκεκριμένη δομή χρονοσειρών. Αν αγνοηθεί η δομή των χρονοσειρών των σφαλμάτων, τότε οι εκτιμήσεις των συντελεστών και τα τυπικά τους σφάλματα θα είναι λανθασμένα. Ωστόσο, είναι δυνατό να προσαρμόσουμε τους εκτιμώμενους συντελεστές πρόβλεψης (regression coefficients) και τα τυπικά σφάλματα (standard errors), όταν τα σφάλματα έχουν δομή AR και κατ' επέκταση θα είμαστε σε θέση να κάνουμε προσαρμογές όταν τα σφάλματα έχουν μια γενική δομή ARIMA.

Κεφάλαιο 3: Μοντέλα Πρόβλεψης

3.1: Γενική Περιγραφή των Μοντέλων Πρόβλεψης

Παρακάτω ακολουθεί η παρουσίαση των μοντέλων πρόβλεψης που αναπτύχθηκαν στην παρούσα διπλωματική εργασία. Είναι μοντέλα που ανήκουν στην κατηγορία της επιβλεπόμενης μηχανικής μάθησης, αλλά και μαθηματικά μοντέλα πρόβλεψης. Συγκεκριμένα είναι αναδρομικά δέντρα απόφασης, νευρωνικά δίκτυα, βαθιά νευρωνικά δίκτυα και αναδρομικά μοντέλα με σφάλματα αυτορυθμιζόμενου κινούμενου μέσου (ARMA)/ αυτορυθμιζόμενου ολοκληρωμένου κινούμενου μέσου (ARIMA).

3.2: Δέντρα Απόφασης (Decision Trees)

Από τους πιο γνωστούς αλγόριθμους μηχανικής μάθησης με επίβλεψη είναι τα δέντρα απόφασης (decision trees). Το παραγόμενο αποτέλεσμα είναι μια δενδροειδής μορφή, η οποία περιγράφει τα δεδομένα και τους κανόνες που χρησιμοποιήθηκαν για την κατασκευή του δέντρου.

Κάθε εσωτερικός κόμβος του δέντρου, αντιστοιχεί σε μια συνθήκη ελέγχου της τιμής ενός χαρακτηριστικού (attribute), των περιπτώσεων (instances) που χρησιμοποιήθηκαν στην κατασκευή του δέντρου. Κάθε κλαδί που εξέρχεται από έναν κόμβο, αντιστοιχεί σε διαφορετική τιμή του χαρακτηριστικού που ελέγχθηκε στον κόμβο αυτό. Στους εξωτερικούς κόμβους του δέντρου αντιστοιχούν οι τιμές εξόδου (classes) των δεδομένων μας.

Το σημαντικότερο πλεονέκτημα των δέντρων ταξινόμησης είναι η ευκολία που προσφέρουν για την ερμηνεία των αποτελεσμάτων που παίρνουμε. Οι δεντρικές δομές είναι πολύ απλές στην χρήση τους, στην κατανόησή τους, αλλά και στην κατασκευή τους, καθώς το υπολογιστικό κόστος είναι της τάξης του $O(\log n)$ στην περίπτωση των δυαδικών δέντρων, τα οποία είναι και τα πιο συνηθισμένα. Αντίστοιχο είναι το κόστος το οποίο υπάρχει και στις περιπτώσεις ανεύρεσης και ταξινόμησης δεδομένων που βρίσκονται σε μορφή δέντρων. Η κατασκευή του δέντρου γίνεται με την χρήση αναδρομικών μεθόδων, από πάνω προς τα κάτω (top down) και αποτελείται από τέσσερα στάδια:

1. Εύρεση του χαρακτηριστικού (attribute) το οποίο χρησιμοποιώντας το σαν κριτήριο διαχωρισμού των δεδομένων (instances), μπορεί να οδηγήσει σε διαφορετικούς κόμβους σε σχέση με την αναζητούμενη τιμή (class).
2. Δημιουργία του κόμβου και προσθήκη στο δέντρο.
3. Διαχωρισμός των δεδομένων.
4. Επανάληψη της προηγούμενης διαδικασίας μέχρις ότου καταλήξουμε σε μη διαχωριζόμενους κόμβους (φύλλα).

Όπως είναι φανερό, το σημαντικότερο σημείο της διαδικασίας είναι η εύρεση του χαρακτηριστικού που θα χρησιμοποιηθεί για την κατασκευή του κόμβου και τον διαχωρισμό. Οι μέθοδοι που εφαρμόζονται είναι στατιστικές και υπολογίζουν μεταβλητές οι οποίες μας δίνουν ένα μέτρο του “βέλτιστου” χαρακτηριστικού. Η επιλογή του βέλτιστου χαρακτηριστικού γίνεται σε κάθε βήμα (κόμβο) που πρέπει να υπολογίσουμε. Στην επιλογή συμμετέχουν μόνο τα δεδομένα που ανήκουν σε αυτό τον κόμβο και όχι το σύνολο των δεδομένων μας.

Η όλη διαδικασία κατασκευής του δέντρου φτάνει στο τέλος, όταν ο κόμβος που υπολογίζουμε γίνει φύλλο (leaf). Για να χαρακτηριστεί κάποιος κόμβος ως φύλλο, θα πρέπει όλα τα δεδομένα που ανήκουν σε αυτό τον κόμβο, να ανήκουν και στην ίδια κατηγορία (κλάση). Η τιμή της κλάσης αυτής είναι και η τιμή του αντίστοιχου κόμβου. [\[1\]](#)

3.2.1: Κλασικοί Αλγόριθμοι Μάθησης

Οι αλγόριθμοι δέντρων αποφάσεων εμφανίζονται αρχικά από τον Quinlan, ο οποίος παρουσίασε τον αλγόριθμο ID3 το 1986. Ο ίδιος εξέλιξε τον ID3, παρουσιάζοντας τον C4.5 το 1996. Ο C4.5 παραμένει ως τώρα ένας από τους πλέον δημοφιλείς αλγόριθμους δέντρων απόφασης, κυρίως μπορεί να χειριστεί συνεχή και διακριτά δεδομένα καθώς και σύνολα δεδομένων με ελλιπή στοιχεία (σύνολα που δεν έχουν τιμές σε όλα τα χαρακτηριστικά τους). Ο ίδιος έχει παρουσιάσει και μια νεότερη έκδοση αυτού του αλγόριθμου, τον C5.0, ο οποίος όμως είναι εμπορικός και όχι ανοικτού κώδικα.

Όλοι οι αλγόριθμοι της κατηγορίας αυτής δέχονται τα δεδομένα εισόδου και παράγουν ένα δέντρο απόφασης (κατηγοριοποίησης ή πρόβλεψης). Νεότεροι αλγόριθμοι χρησιμοποιούν τεχνικές της στατιστικής, ώστε να επεξεργαστούν με διάφορους τρόπους τα δεδομένα εκπαίδευσης παράγοντας ένα ή περισσότερα σύνολα δεδομένων εκπαίδευσης, και κατόπιν εισάγουν τα νέα σύνολα σε κάποιον από τους παραπάνω αλγόριθμους οι οποίοι παράγουν ένα δέντρο για κάθε σύνολο εκπαίδευσης. Κατόπιν, χρησιμοποιώντας πάλι στατιστικές μεθόδους, τα αποτελέσματα που έχουν παραχθεί συγκρίνονται μεταξύ τους, και τέλος επιλέγεται το καλύτερο δέντρο ή τα παραχθέντα δέντρα συνδυάζονται μεταξύ τους για να προκύψει το καλύτερο δυνατό αποτέλεσμα.

Οι αλγόριθμοι αυτής της μορφής ονομάζονται meta ή ensemble αλγόριθμοι. Χαρακτηριστικά παραδείγματα αυτών των μεθόδων είναι ο Adaboost, Bagging, Random Forest κλπ.

3.2.1.1: Bootstrapping

Η αξιοπιστία μιας μεθόδου θα μπορούσε να βελτιωθεί, αν υπήρχε η δυνατότητα να εφαρμοστεί πάνω σε πολλά διαφορετικά σύνολα δεδομένων, τα οποία να είναι και ασυσχέτιστα μεταξύ τους.

Επειδή όμως αυτό είναι δύσκολο, ενώ πολλές φορές έχουμε όχι απλά μόνο ένα σύνολο δεδομένων, αλλά και με ελάχιστα στοιχεία, εφαρμόζουμε τη μέθοδο

bootstrapping, η οποία προέρχεται από την στατιστική και η οποία προσπαθεί να εξομοιώσει το ζητούμενο αποτέλεσμα.

Κατά την εκτέλεση της μεθόδου bootstrapping, ξεκινώντας από ένα αρχικό σύνολο δεδομένων 'S' το οποίο περιέχει 'n' γραμμές (instances), κατασκευάζουμε πολλά νέα σύνολα S_1, S_2, \dots, S_m , τα οποία περιέχουν επίσης 'n' γραμμές.

Τα νέα σύνολα κατασκευάζονται, επιλέγοντας από το αρχικό τυχαίες γραμμές, έως ότου το νέο σύνολο να αποκτήσει και αυτό 'n' στοιχεία. Κάθε γραμμή μπορεί να επιλεγεί μια ή και περισσότερες φορές.

Τα τελικά σύνολα δεδομένων που προκύπτουν δεν είναι πλήρως ασυσχέτιστα μεταξύ τους, μπορούμε όμως να θεωρήσουμε ότι είναι μια αρκετά καλή προσέγγιση.

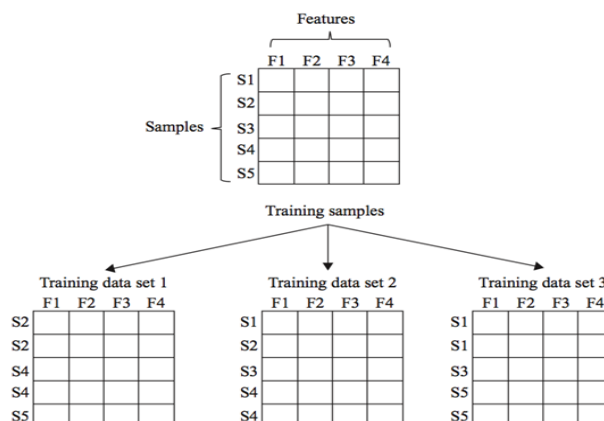
Αρχικό Σύνολο Εκπαίδευσης		Νέα Σύνολα Εκπαίδευσης μετά από Bootstrap		
Instance 1		Instance 1	Instance 3	Instance 1
Instance 2		Instance 2	Instance 3	Instance 5
Instance 3		Instance e 1	Instance 3	Instance 4
Instance 4		Instance 4	Instance 1	Instance 3
Instance 5		Instance 5	Instance 4	Instance 5

Εικόνα 4: Μέθοδος Bootstrap

3.2.1.2: Bagging (Bootstrap Aggregating)

Χρησιμοποιώντας την μέθοδο bootstrapping, μπορούμε να ξεκινήσουμε από ένα σύνολο δεδομένων και με βάση αυτό να δημιουργήσουμε 'm' νέα σύνολα εκπαίδευσης.

Τώρα έχουμε την δυνατότητα να εφαρμόσουμε σε κάθε ένα από αυτά τα σύνολα, τον αλγόριθμο που θέλουμε και να πάρουμε 'm' διαφορετικά αποτελέσματα (δέντρα στην περίπτωση μας). Ο αλγόριθμος που χρησιμοποιείται για την εκπαίδευση ονομάζεται βασικός ταξινομητής (base classifier). Αυτά τα αποτελέσματα θα πρέπει στο επόμενο βήμα να συγκριθούν μεταξύ τους και να αξιολογηθούν, έτσι ώστε να επιλεγεί το καλύτερο. Αν πρόκειται για πρόβλημα προσέγγισης – πρόβλεψης (regression) τότε υπολογίζεται συνήθως ο μέσος όρος. Η μέθοδος αυτή ονομάστηκε Bagging από τα αρχικά των λέξεων Bootstrap Aggregating και δίνει καλύτερα αποτελέσματα από το να εφαρμόσουμε μόνο τον βασικό ταξινομητή στο αρχικό σύνολο δεδομένων.[\[1\]](#)



Εικόνα 5: Μέθοδος Bagging

3.2.1.3: Η Μέθοδος των Τυχαίων Δασών (Random forests)

Η μέθοδος αυτή δημιουργεί τυχαία δάση που αποτελούνται από πολλά δέντρα αποφάσεων. Ο αλγόριθμος που εφαρμόζεται για τη δημιουργία ενός τυχαίου δάσους, είναι ο εξής (Cutler):

1. Δημιουργία κάθε δένδρου από ένα ανεξάρτητο δείγμα εκκίνησης (bootstrap sample), το οποίο επιλέγεται από τα δεδομένα εκπαίδευσης (training data) με τη μέθοδο της αντικατάστασης. Σε κάθε κόμβο γίνεται:
 - α) Επιλογή m μεταβλητών (περιπτώσεων) τυχαία από όλες τις δυνατές M μεταβλητές
 - β) Εύρεση βέλτιστου διαχωρισμού των m μεταβλητών.
2. Ανάπτυξη των δένδρων κατηγοριοποιώντας (ταξινομώντας) τα δεδομένα στο μέγιστο βαθμό.
3. Κατάταξη των δένδρων ώστε να προβλεφθεί η συμπεριφορά των καινούργιων δεδομένων.
4. Κατάταξη των εναπομείναντων ($M-m$) δεδομένων, τα οποία ονομάζονται “out of bag” ή “oob”, σε κλάσεις των δένδρων του δάσους.
5. Εξετάζεται αν η κλάση που υπερέχει ως επιλογή από τα περισσότερα δένδρα απόφασης, είναι η πραγματική κλάση του κάθε δεδομένου εισαγωγής. Ο ρυθμός σφάλματος αυτής της κατηγοριοποίησης (oob error rate) (Cutler, 2010) συνιστά το ρυθμό σφάλματος πρόγνωσης του δάσους.

Υπάρχουν περιπτώσεις όπου ένα χαρακτηριστικό j μιας μεταβλητής χρήζει ειδικότερης εκτίμησης της συμπεριφοράς του, σε σχέση με τις τιμές των υπόλοιπων χαρακτηριστικών της υπό εισαγωγή μεταβλητής (variable importance). Σε αυτή την περίπτωση, ζητείται από το δάσος να πραγματοποιήσει μία επιπλέον κατάταξη μετά από τις παρακάτω μεταβολές:

1. Εντοπισμός των oob δεδομένων σε κάθε δένδρο.
2. Τυχαία μετάθεση των τιμών της μεταβλητής j (variable importance) μεταξύ των oob δεδομένων.
3. Εκ νέου κατάταξη σε κλάσεις.

4. Υπολογισμός του ρυθμού σφάλματος αυτής της κατηγοριοποίησης (oob error rate permuted) για κάθε δένδρο.
5. Υπολογισμός της διαφοράς του προηγούμενου σφάλματος χωρίς τη μετάθεση από το σφάλμα μετά τη μετάθεση (error rate permuted-error rate) για κάθε δένδρο.
6. Εφαρμογή της παραπάνω διαδικασίας σε όλα τα δένδρα.
7. Εύρεση του μέσου όρου των αποκλίσεων.
8. Εκτίμηση σφάλματος.

Για την κατάταξη των καινούργιων δεδομένων σε μία κλάση, γίνονται τα εξής βήματα:

1. Εισαγωγή του δεδομένου σε όλα τα δένδρα του δάσους.
2. Κατάταξη σε κλάση από το κάθε δένδρο.
3. Επικρατούσα κλάση είναι αυτή που κατέχει την πλειοψηφία. [\[2\]](#)


3.3: Μη-γραμμικό αυτό-ρυθμιζόμενο εξωγενές μοντέλο (NARX)

Όταν γίνεται αναφορά σε πρόβλεψη χρονοσειρών ένα μη-γραμμικό αυτό-ρυθμιζόμενο εξωγενές μοντέλο, είναι ένα μη-γραμμικό αυτό-ρυθμιζόμενο μοντέλο το οποίο έχει εξωγενείς εισόδους και ανήκει στην ευρύτερη κατηγορία των νευρωνικών δικτύων. Το συγκεκριμένο μοντέλο συσχετίζει την τρέχουσα τιμή μιας χρονοσειράς τόσο με προηγούμενες τιμές της ίδιας σειράς, όσο και με τις τρέχουσες και προηγούμενες τιμές της εξωγενούς σειράς (σειράς οδήγησης)-δηλαδή της εξωτερικά καθορισμένης σειράς που επηρεάζει τις σειρές ενδιαφέροντος. Επιπλέον το μοντέλο περιέχει έναν όρο σφάλματος, που σχετίζεται με το γεγονός ότι η γνώση άλλων όρων δεν θα επιτρέψει την ακριβή πρόβλεψη της τρέχουσας τιμής των χρονοσειρών. Το μοντέλο αναπαριστάται αλγεβρικά ως εξής:

$$Y_t = F(Y_{t-1}, Y_{t-2}, Y_{t-3}, \dots, U_t, U_{t-1}, U_{t-2}, U_{t-3}, \dots) + \varepsilon_t$$

Όπου:

y είναι η μεταβλητή ενδιαφέροντος και u είναι η εξωτερικά καθορισμένη μεταβλητή. Οι πληροφορίες για το u βοηθούν στην πρόβλεψη του y , όπως και οι προηγούμενες τιμές του ίδιου του y . Το ε είναι ο όρος σφάλματος (μερικές φορές ονομάζεται θόρυβος). Για παράδειγμα, y μπορεί να είναι η θερμοκρασία του αέρα το μεσημέρι, και u μπορεί να είναι η ημέρα του έτους (ημέρα-αριθμός εντός του έτους). Η συνάρτηση F είναι κάποια μη γραμμική συνάρτηση, όπως ένα πολυώνυμο. Το F μπορεί να είναι ένα νευρωνικό δίκτυο, ένα δίκτυο wavelet, ένα sigmoid δίκτυο και ούτω καθεξής. Όπως έχει ήδη αναφερθεί, στην περίπτωση μας θα είναι νευρωνικό δίκτυο. [\[4\]](#)




Εικόνα 6: Δομή μοντέλου NARX

(www.intechopen.com)

3.4: Βαθιά Νευρωνικά Δίκτυα Μακράς-Βραχείας Διάρκειας Μνήμης (LSTM)


Επαναλαμβανόμενα νευρωνικά δίκτυα

Όπως είναι γνωστό, οι άνθρωποι δεν ξεκινούν τη σκέψη τους από το μηδέν κάθε δευτερόλεπτο. Καθώς διαβάζετε αυτό το κείμενο, καταλαβαίνετε κάθε λέξη με βάση την κατανόηση των προηγούμενων λέξεων. Δεν ξεχνάτε τα πάντα και αρχίζετε να σκέφτεστε εκ νέου ξανά. Οι σκέψεις σας έχουν μια αλληλουχία. Τα παραδοσιακά νευρωνικά δίκτυα δεν μπορούν να το κάνουν αυτό, κάτι που αποτελεί ένα μεγάλο θέμα. Αντίθετα, τα επαναλαμβανόμενα νευρωνικά δίκτυα αντιμετωπίζουν αυτό το ζήτημα. Είναι δίκτυα που περιέχουν βρόχους, επιτρέποντας να διατηρούνται οι πληροφορίες.



Εικόνα 7: Τμήμα επαναλαμβανόμενου νευρωνικού δικτύου

Στο παραπάνω διάγραμμα, το A δέχεται μια είσοδο x_t και εξάγει μια τιμή h_t . Ένας βρόχος επιτρέπει τη μετάδοση πληροφοριών από ένα βήμα του δικτύου στο επόμενο. Αυτοί οι βρόχοι κάνουν τα επαναλαμβανόμενα νευρωνικά δίκτυα να φαίνονται κάπως περίεργα. Ωστόσο, παρατηρώντας λίγο περισσότερο, αποδεικνύεται ότι δεν είναι όλα διαφορετικά από ένα κανονικό νευρωνικό δίκτυο. Ένα επαναλαμβανόμενο νευρωνικό δίκτυο, μπορεί να θεωρηθεί ως πολλαπλά αντίγραφα του ίδιου δικτύου, το καθένα από τα οποία διαβιβάζει ένα μήνυμα στο επόμενο. Ξετυλίγοντας το βρόχο προκύπτει:




Εικόνα 8: Αποδομημένο επαναλαμβανόμενο νευρωνικό δίκτυο

Αυτή η μορφή που μοιάζει με αλυσίδα αποκαλύπτει ότι τα επαναλαμβανόμενα νευρωνικά δίκτυα σχετίζονται στενά με αλληλουχίες και λίστες. Ένα πολύ ιδιαίτερο είδος επαναλαμβανόμενου νευρωνικού δικτύου το οποίο λειτουργεί για πολλές εφαρμογές πολύ καλύτερα από την κανονική έκδοση, είναι τα Βαθιά Νευρωνικά Δίκτυα Μακράς-Βραχείας Διάρκειας Μνήμης.

Το πρόβλημα των μακροπρόθεσμων εξαρτήσεων


Μερικές φορές, πρέπει να εξεταστούν μόνο οι πρόσφατες πληροφορίες για την εκτέλεση της παρούσας εργασίας. Για παράδειγμα, ένα μοντέλο γλώσσας που προσπαθεί να προβλέψει την επόμενη λέξη με βάση τις προηγούμενες. Εάν γίνεται προσπάθεια να προβλεφτεί η τελευταία λέξη απ' τη φράση "τα σύννεφα είναι στον ουρανό" (παράδειγμα 1), δεν είναι απαραίτητο κανένα άλλο πλαίσιο - είναι προφανές ότι η επόμενη λέξη θα είναι "ουρανό". Σε τέτοιες περιπτώσεις, όπου το χάσμα μεταξύ των σχετικών πληροφοριών και αυτού που θέλουμε να προβλέψουμε είναι μικρό, τα ΕΝΔ μπορούν να μάθουν να χρησιμοποιούν τις προηγούμενες πληροφορίες.



Εικόνα 9: Παράδειγμα 1

Υπάρχουν όμως και περιπτώσεις όπου χρειαζόμαστε περισσότερο περιεχόμενο. Παραδείγματος χάριν αν προσπαθούμε να προβλέψουμε την τελευταία λέξη στο κείμενο "Έχω μεγαλώσει στην Ελλάδα ... μιλώ άπταιστα Ελληνικά" (παράδειγμα 2). Πρόσφατες πληροφορίες δείχνουν ότι η επόμενη λέξη είναι ίσως το όνομα μιας γλώσσας, αλλά για να περιοριστεί το ποια γλώσσα, είναι απαραίτητο το πλαίσιο της Ελλάδας, από πιο πίσω. Είναι κατανοητό ότι το χάσμα μεταξύ των σχετικών πληροφοριών και της πληροφορίας που θέλουμε να

προβλέψουμε είναι πολύ μεγάλο. Δυστυχώς, καθώς αυτό το χάσμα μεγαλώνει, τα ΕΝΔ δεν μπορούν να μάθουν να συνδέουν τις πληροφορίες.



Εικόνα 10: Παράδειγμα 2


Θεωρητικά, τα ΕΝΔ είναι απολύτως σε θέση να χειριστούν τέτοιες "μακροχρόνιες εξαρτήσεις". Ένας άνθρωπος θα μπορούσε να επιλέξει προσεκτικά παραμέτρους για να λύσει προβλήματα αυτής της μορφής. Δυστυχώς, στην πράξη, τα ΕΝΔ δεν φαίνεται να είναι σε θέση να τα μάθουν. Ευτυχώς όμως, τα ΝΔΜΒΜ δεν έχουν αυτό το πρόβλημα.

Βαθιά Νευρωνικά Δίκτυα Μακράς-Βραχείας Διάρκειας Μνήμης (ΝΔΜΒΜ)

Τα δίκτυα μακράς βραχείας διάρκειας μνήμης είναι ένα ειδικό είδος ΕΝΔ, ικανό να μαθαίνει μακροπρόθεσμες εξαρτήσεις. Εισήχθησαν από τον Hochreiter & Schmidhuber το 1997. Εφαρμόζονται εξαιρετικά καλά σε μια μεγάλη ποικιλία προβλημάτων και τώρα χρησιμοποιούνται ευρέως.


Τα ΝΔΜΒΜ έχουν σχεδιαστεί ειδικά για να αποφευχθεί το πρόβλημα μακροχρόνιας εξάρτησης. Η συγκράτηση των πληροφοριών για μεγάλες χρονικές περιόδους είναι πρακτικά η προεπιλεγμένη συμπεριφορά τους, όχι κάτι που αγωνίζονται να μάθουν.

Όλα τα ΕΝΔ έχουν τη μορφή μίας αλυσίδας επαναλαμβανόμενων τμημάτων του νευρωνικού δικτύου. Στα πρότυπα ΕΝΔ, αυτό το επαναλαμβανόμενο τμήμα θα έχει μια πολύ απλή δομή, όπως ένα μονό στρώμα (layer) tanh.




Εικόνα 11: Το επαναλαμβανόμενο τμήμα σε ένα τυπικό ΕΝΔ περιέχει ένα στρώμα

Τα ΝΔΜΒΜ έχουν επίσης αυτήν την αλυσιδωτή δομή, αλλά το επαναλαμβανόμενο τμήμα έχει διαφορετική δομή. Αντί να υπάρχει ένα ενιαίο στρώμα νευρωνικού δικτύου, υπάρχουν τέσσερα, που αλληλεπιδρούν με πολύ ειδικό τρόπο.



Εικόνα 12: 4 επίπεδα ενός ΝΔΜΒΜ που αλληλεπιδρούν




Εικόνα 13: Σύμβολα που περιέχονται στο ΝΔΜΒΜ

Στην παραπάνω εικόνα, κάθε γραμμή μεταφέρει ένα ολόκληρο διάνυσμα, από την έξοδο ενός κόμβου στις εισόδους άλλων. Οι ροζ κύκλοι αντιπροσωπεύουν σημειακές λειτουργίες, όπως την προσθήκη διανυσμάτων, ενώ τα κίτρινα πλαίσια είναι μαθηματικά επίπεδα νευρωνικού δικτύου. Οι γραμμές συγχώνευσης υποδηλώνουν την αλληλοσύνδεση, ενώ η διακλαδισμένη γραμμή υποδηλώνει ότι το περιεχόμενό της αντιγράφεται και τα αντίγραφα πηγαίνουν σε διαφορετικές θέσεις.


Η βασική ιδέα πίσω απ' τα ΝΔΜΒΜ

Το κλειδί για τα ΝΔΜΒΜ είναι η οριζόντια γραμμή της κυψελικής κατάστασης (cell state), που τρέχει από την κορυφή του διαγράμματος. Η κυψελική κατάσταση είναι κάτι σαν γραμμή μεταφοράς. Λειτουργεί κατευθείαν σε ολόκληρη την αλυσίδα, με μερικές μόνο μικρές γραμμικές αλληλεπιδράσεις.



Εικόνα 14: Οριζόντια γραμμή της κυψελικής κατάστασης του ΝΔΜΒΜ

Το ΝΔΜΒΜ έχει τη δυνατότητα να αφαιρέσει ή να προσθέσει πληροφορίες στην κυψελική κατάσταση, μέσω συγκεκριμένων δομών που ονομάζονται πύλες. Οι πύλες είναι ένας τρόπος να διαχειρίζονται οι πληροφορίες. Αποτελούνται από στρώμα σιγμοειδούς νευρωνικού δικτύου και από μια σημειακή λειτουργία πολλαπλασιασμού.




Εικόνα 15: Πύλη ΝΔΜΒΜ

Το σιγμοειδές στρώμα εξάγει αριθμούς μεταξύ μηδέν και ένα, περιγράφοντας πόσο μέρος κάθε συστατικού πρέπει να μεταφερθεί. Μια τιμή μηδέν σημαίνει "δεν μένει τίποτα μέσα", ενώ η αξία του ενός σημαίνει "μένουν τα πάντα μέσα!". Ένα LSTM έχει τρεις από αυτές τις πύλες, για να προστατεύει και να ελέγχει την κυψελική κατάσταση.

Αναλυτική ματιά ενός ΝΔΜΒΜ

Το πρώτο βήμα στο ΝΔΜΒΜ είναι να αποφασίσουμε ποιες πληροφορίες πρόκειται να πετάξουμε από την κυψελική κατάσταση. Η απόφαση αυτή γίνεται από ένα σιγμοειδές στρώμα που ονομάζεται "forget gate layer". Εξετάζει τα h_{t-1} και x_t και εξάγει έναν αριθμό μεταξύ 0 και 1 για κάθε αριθμό στην κυψελική κατάσταση C_{t-1} . Το 1 αντιπροσωπεύει "κρατάμε εντελώς αυτό" ενώ το 0 αντιπροσωπεύει "απαλασσόμαστε εντελώς από αυτό".


Ας επιστρέψουμε στο παράδειγμα μας για ένα γλωσσικό μοντέλο που προσπαθεί να προβλέψει την επόμενη λέξη με βάση όλες τις προηγούμενες. Σε ένα τέτοιο πρόβλημα, η κυψελική κατάσταση μπορεί να περιλαμβάνει το φύλο του παρόντος θέματος, έτσι ώστε να μπορούν να χρησιμοποιηθούν οι σωστές αντωνυμίες. Όταν εισάγεται ένα νέο θέμα, πρέπει να ξεχαστεί το φύλο του παλιού θέματος.



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

Εικόνα 16: Κυψέλη ΝΔΜΒΜ-Πρώτο βήμα

Το επόμενο βήμα είναι η απόφαση σχετικά με το ποιες νέες πληροφορίες πρόκειται να αποθηκευτούν στην κυψελική κατάσταση. Αυτό έχει δύο μέρη. Κατ' αρχάς, ένα στρώμα σιγμοειδές (sigmoid) που ονομάζεται "input gate layer", που αποφασίζει ποιες τιμές θα ενημερωθούν. Στη συνέχεια, ένα στρώμα tanh δημιουργεί ένα διάνυσμα νέων υποψήφίων τιμών, C_t , που θα μπορούσε να προστεθεί στην κατάσταση. Στο επόμενο βήμα, θα συνδυαστούν αυτά τα δύο για να δημιουργηθεί μια ενημέρωση για την κατάσταση. Στο παράδειγμα του γλωσσικού μοντέλου, θα θέλαμε να προσθέσουμε το φύλο του νέου θέματος στην κυψελική κατάσταση, για να αντικαταστήσουμε το παλιό που ξεχνάμε.



$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$


$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

Εικόνα 17: Κυψέλη NDMBM-Δεύτερο βήμα

Τώρα θα ενημερωθεί η κατάσταση της παλιάς κυψέλης, C_{t-1} , στη νέα κατάσταση κυψέλης C_t . Τα προηγούμενα βήματα έχουν ήδη αποφασίσει τι πρέπει να γίνει. Το μόνο που μένει είναι να το γίνει στην πράξη.

Πολλαπλασιάζεται η παλιά κατάσταση με f_t , παραμερίζοντας τα πράγματα που αποφασίσαμε να ξεχάσουμε νωρίτερα. Στη συνέχεια προσθέτουμε $i_t * C_t$. Αυτές είναι οι νέες υποψήφιες τιμές, κλιμακούμενες από το πόσο αποφασίσαμε να ενημερώσουμε την κάθε κατάσταση.

Στην περίπτωση του γλωσσικού μοντέλου, εδώ είχαμε αφήσει τις πληροφορίες σχετικά με το φύλο του παλαιού υποκειμένου και προσθέσαμε τις νέες πληροφορίες, όπως αποφασίσαμε στα προηγούμενα βήματα.




$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

Εικόνα 18: Κυψέλη NDMBM-Τρίτο βήμα

Τέλος, πρέπει να αποφασίσουμε τι θα βγάλουμε στην έξοδο. Αυτή η έξοδος θα βασίζεται στην κυψελική κατάστασή μας, αλλά θα είναι μια φιλτραρισμένη έκδοση. Αρχικά, τρέχουμε ένα στρώμα sigmoid που αποφασίζει ποια τμήματα της κυψελικής κατάστασης θα προωθήσουμε στην έξοδο. Στη συνέχεια, θέτουμε την κυψελική κατάσταση μέσω tanh (για να ωθήσουμε τις τιμές να είναι μεταξύ -1 και 1) και την πολλαπλασιάζουμε επί την έξοδο της σιγμοειδούς πύλης, έτσι ώστε να εξάγουμε μόνο τα μέρη που αποφασίσαμε.

Για το παράδειγμα γλωσσικού μοντέλου, δεδομένου ότι είδε ακριβώς ένα θέμα, μπορεί να θέλει να παράγει πληροφορίες σχετικές με ένα ρήμα, σε περίπτωση που αυτό είναι που έρχεται στη συνέχεια. Για παράδειγμα, θα μπορούσε να εξάγει εάν το θέμα είναι στον ενικό ή στον πληθυντικό, έτσι ώστε να γνωρίζουμε σε ποια μορφή θα πρέπει να συσχετιστεί ένα ρήμα, αν αυτό ακολουθεί. [5]



Εικόνα 19: Κυψέλη ΝΔΜΒΜ-Τέταρτο βήμα

3.5: Αναδρομικά μοντέλα πρόβλεψης με ARIMA/ARMA Σφάλματα (Regression model with ARIMA/ARMA time series errors)

Η προσέγγιση μοντελοποίησης ARIMA μπορεί να εφαρμοστεί στην εξίσωση πολλαπλής παλινδρόμησης για να μοντελοποιήσει την πληροφορία που βρίσκεται στους όρους σφάλματος. Υποθέτουμε ένα μοντέλο με μια μεταβλητή που δηλώνεται ως: $Y_t = \beta_0 + \beta_1 X_{1,t} + N_t$. Επίσης υποθέτουμε ότι οι όροι σφάλματος είναι αυτοσυσχετιζόμενοι και μπορούν να περιγραφούν κατάλληλα από ένα ARMA (1,1). Αυτό το μοντέλο μπορεί να γραφτεί ως: $Y_t = \beta_0 + \beta_1 X_{1,t} + N_t$, όπου: $(1 - \phi_1 B)N_t = (1 - \theta_1 B)a_t$, όπου a_t λευκός θόρυβος. Αντικαθιστώντας τη διόρθωση του όρου σφάλματος στην αναδρομική εξίσωση παίρνουμε:

$$Y_t = \beta_0 + \beta_1 X_{1,t} + [(1 - \theta_1 B) / (1 - \phi_1 B)] a_t$$

Λόγω της συγκεκριμένης μορφής στους όρους σφάλματος, οι κλασικές μέθοδοι ελαχίστων τετραγώνων δεν είναι κατάλληλες για την εκτίμηση των παραμέτρων αυτής της εξίσωσης. Αντ' αυτού, η SAS-ARIMA διαδικασία για την εκτίμηση της μέγιστης πιθανότητας χρησιμοποιείται για τη ρύθμιση των μοντέλων. Η συνάρτηση πιθανότητας μεγιστοποιείται χρησιμοποιώντας τη μέθοδο του Marquardt μέσω της εκτίμησης μη γραμμικών ελαχίστων τετραγώνων. Εάν εφαρμοστεί διαφόριση στα σφάλματα σε μια πολλαπλή παλινδρόμηση, τότε όλες οι

αντίστοιχες σειρές (όλες οι μεταβλητές) πρέπει να διαφοριστούν. Αυτό φαίνεται και στο παρακάτω παράδειγμα αναδρομής. Διαφορίζοντας δυο φορές τους όρους σφάλματος, οδηγούμαστε στην ακόλουθη σχέση κάνοντας εφαρμογή του μοντέλου ARMA(1,1) στους όρους σφάλματος που έχουν διαφοριστεί:

$$\nabla_{12} \nabla N_t = \frac{(1 - \theta_1 B)}{(1 - \phi_1 B)} a_t \Leftrightarrow N_t = \frac{(1 - \theta_1 B)}{\nabla_{12} \nabla (1 - \phi_1 B)} a_t$$

Αντικαθιστώντας την έκφραση στην αναδρομική εξίσωση παίρνουμε:

$$Y_t = \beta_0 + \beta_1 X_{1,t} + \frac{(1 - \theta_1 B)}{\nabla_{12} \nabla (1 - \phi_1 B)} a_t \Leftrightarrow \nabla_{12} \nabla Y_t = \beta_0' + \beta_1 \nabla_{12} \nabla X_{1,t} + \frac{(1 - \theta_1 B)}{(1 - \phi_1 B)} a_t$$

Η σχέση φαίνεται λίγο διαφοροποιημένη, αλλά ο (θεωρητικός) αναδρομικός συντελεστής β_1 δεν επηρεάζεται από τη διαφόριση. Η εκτιμώμενη τιμή του μπορεί να διαφέρει ελαφρώς, δεδομένου ότι η εκτίμηση γίνεται με διαφορετικές (αν και σχετικές) χρονοσειρές. [\[6\]](#)

Κεφάλαιο 4: Σχεδιασμός μοντέλων & Μεσοπρόθεσμη πρόβλεψη

4.1: Παρουσίαση των δεδομένων και προεπεξεργασία

Παρακάτω ακολουθεί μια εκτενής περιγραφή σχετικά με το σχεδιασμό και τον προγραμματισμό μοντέλων μεσοπρόθεσμης πρόβλεψης βασισμένης σε δεδομένα Ωριαίων Χρονοσειρών. Η πρόβλεψη είναι μεσοπρόθεσμη γιατί ο χρονικός ορίζοντας πρόβλεψης είναι το επόμενο 24ωρο. Τα δεδομένα, όπως έχει ήδη προαναφερθεί, που χρησιμοποιούνται είναι απ' το νησί Ντία.

Έχουν καταγραφεί από ύψος 10 μέτρων απ' το έδαφος τα εξής:

- Θερμοκρασία αέρα (°C)
- Σχετική Υγρασία (%)
- Ταχύτητα Ανέμου (m/s)
- Διεύθυνση Ανέμου (°)
- Ατμοσφαιρική Πίεση (hPa)
- Ηλιακή Ακτινοβολία (W/m^2)
- Μέση Βροχόπτωση (mm)

Αξίζει να σημειωθεί ότι οι παραπάνω μετρήσεις είναι ωριαίες καταγραφές καθημερινής βάσης για τις χρονιές 2007, 2008 και 2009. Μετά την συλλογή των δεδομένων ακολούθησε η επεξεργασία των δεδομένων πριν τη χρήση τους στα μοντέλα. Δυο είναι τα βασικά μέρη της προ-επεξεργασίας: 1) Επίλυση του προβλήματος δεδομένων που λείπουν, 2) Διαδικασία κανονικοποίησης. Όσο αφορά το πρώτο, δεν αντιμετωπίσαμε πρόβλημα με δεδομένα που έλειπαν. Αλλά και να συνέβαινε αυτό, η ενδεδειγμένη λύση είναι η αντικατάσταση δεδομένων απ' το μέσο όρο των γειτονικών τιμών κατά την ίδια εβδομάδα. Όσο αφορά το δεύτερο μέρος της προεπεξεργασίας δεδομένων, έγινε μια κανονικοποίηση των δεδομένων πριν απ' την εισαγωγή τους στα μοντέλα, δεδομένου ότι η ανάμειξη μεταβλητών με μεγάλα και μικρά μεγέθη θα συγχέει τον αλγόριθμο μάθησης, σχετικά με τη βαρύτητα που παίρνει κάθε μεταβλητή. Αυτό μπορεί να οδηγήσει στην απόρριψη της μεταβλητής με το μικρότερο μέγεθος.

4.2: Κατασκευή και Προγραμματισμός Μοντέλων

Σ' αυτό το σημείο θα παρουσιαστούν τα ειδικά χαρακτηριστικά κάθε μοντέλου, που αναπτύχτηκε τόσο για τη μεσοπρόθεσμη πρόβλεψη της ηλιακής ακτινοβολίας όσο και της ταχύτητας ανέμου. Τα εργαλεία που χρησιμοποιήθηκαν για την κατασκευή όλων των μοντέλων, εκτός του NΔMBM, είναι οι βιβλιοθήκες και τα εργαλεία μηχανικής μάθησης αλλά και στατιστικής της Matlab. Το NΔMBM κατασκευάστηκε με χρήση των βιβλιοθηκών μηχανικής μάθησης και των εργαλείων της Python.

4.2.1: Μοντέλα Πρόβλεψης Ταχύτητας Ανέμου


Οι είσοδοι που χρησιμοποιήθηκαν στα μοντέλα πρόβλεψης ταχύτητας ανέμου είναι:

- θερμοκρασία αέρα
- σχετική υγρασία
- ατμοσφαιρική πίεση
- ώρα μέτρησης
- ώρα έτους
- ταχύτητα ανέμου προηγούμενου 24ωρου
- ηλιακή ακτινοβολία.

Είναι καλό να τονιστεί ότι η ώρα μέτρησης παίρνει διακριτές τιμές στο διάστημα [1,24], με το 1 να αντιπροσωπεύει την πρώτη ώρα της ημέρας και το 24 την τελευταία.

1) Αναδρομικά Δέντρα Απόφασης


Το μοντέλο που αναπτύχθηκε βασισμένο στα δέντρα απόφασης είναι ένα υποσύνολο του συνόλου των δέντρων απόφασης και ονομάζεται Bagged DecisionTree. Ένα βασικό πράγμα που έπρεπε να καθοριστεί είναι το βέλτιστο ελάχιστο μέγεθος των φύλλων (leaf size). Χρησιμοποιώντας ενδεικτικά 5 προτεινόμενα leaf sizes (5,10,20,50,100) για 50 δέντρα, συγκρίνοντας τα μέσα τετραγωνικά σφάλματα που προέκυψαν μετά την εφαρμογή του μοντέλου και τη πρόβλεψη για τα ενδεικτικά μεγέθη φύλλων, εξήχθηκε τελικά το βέλτιστο μέγεθος φύλλου, το οποίο ισούται με 5 όπως φαίνεται στην παρακάτω εικόνα.



Εικόνα 20: Εύρεση βέλτιστου ελάχιστου μεγέθους φύλλων του μοντέλου για την πρόβλεψη ταχύτητας ανέμου


Στη συνέχεια καθορίστηκαν οι μεταβλητές που θα έπρεπε να χρησιμοποιηθούν στο διάνυσμα εισόδου για να γίνει η πρόβλεψη. Οι μεταβλητές οι οποίες χρησιμοποιήθηκαν είναι αυτές που αναφέρθηκαν παραπάνω. Στην εικόνα

που ακολουθεί, φαίνεται ενδεικτικά η σημασία και η βαρύτητα της καθεμιάς για τον μήνα Ιούλιο.

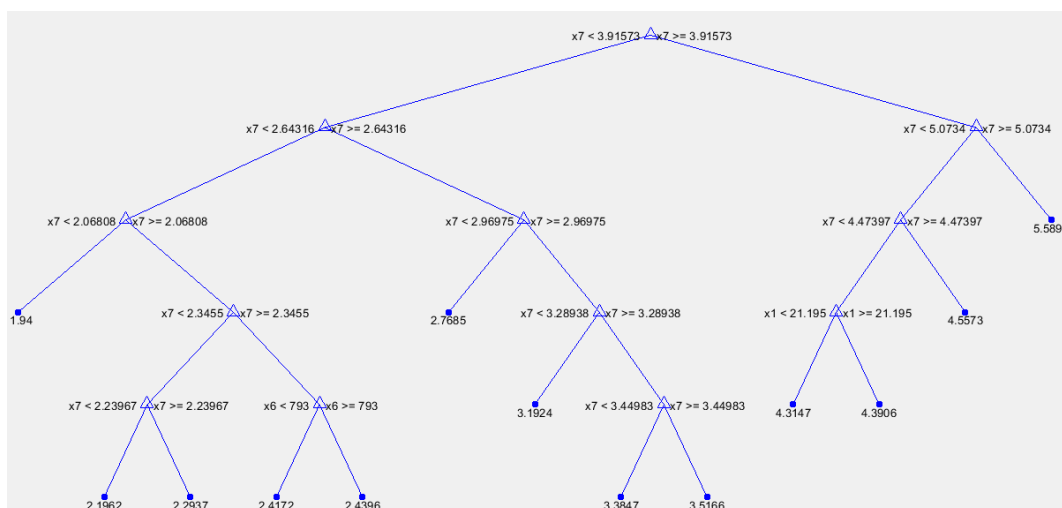


Εικόνα 21: Σημασία/Βαρύτητα κάθε μεταβλητής εισόδου του μοντέλου για την πρόβλεψη ταχύτητας ανέμου

Με βάση τα παραπάνω δημιουργήθηκε το μοντέλο με χρήση της συνάρτησης του Matlab, **TreeBagger**. Στο μοντέλο αναπτύχθηκαν 200 δέντρα (κατά την εκπαίδευση), με minLeafsize 5, έχοντας ως διάνυσμα εισόδου: θερμοκρασία αέρα, σχετική υγρασία, ατμοσφαιρική πίεση, ώρα μέτρησης, ώρα έτους, ταχύτητα ανέμου προηγούμενου 24ωρου, ηλιακή ακτινοβολία και έξοδο την ταχύτητα του ανέμου.



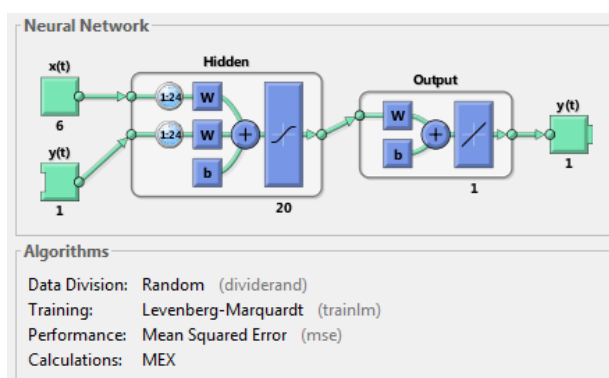
Εικόνα 22: Στιγμιότυπο δέντρου απόφασης για την πρόβλεψη ταχύτητας ανέμου



Εικόνα 23: Στιγμιότυπο δέντρου απόφασης με ετικέτες στους κόμβους για την πρόβλεψη ταχύτητας ανέμου


2) Μη-γραμμικό αυτό-ρυθμιζόμενο εξωγενές μοντέλο (NARX)

Η αρχιτεκτονική που αναπτύχθηκε έχοντας ως βάση το NARX είναι η αρχιτεκτονική παράλληλης σειράς (Series parallel architecture). Αυτή χρησιμοποιείται όταν η έξοδος του δικτύου NARX θεωρείται ότι αποτελεί εκτίμηση της εξόδου κάποιου μη γραμμικού δυναμικού συστήματος. Η έξοδος τροφοδοτείται πίσω στην είσοδο του νευρωνικού δικτύου, σα να είναι μέρος της τυπικής αρχιτεκτονικής NARX. Εφόσον η έξοδος είναι διαθέσιμη κατά τη διάρκεια εκπαίδευσης, θα μπορούσε να δημιουργηθεί μια παράλληλη αρχιτεκτονική σειράς, στην οποία επανατροφοδοτείται η έξοδος πίσω στην είσοδο. Στην παρακάτω εικόνα φαίνεται η αρχιτεκτονική παράλληλης σειράς που αναπτύχθηκε για την μεσοπρόθεσμη πρόβλεψη ταχύτητας ανέμου.



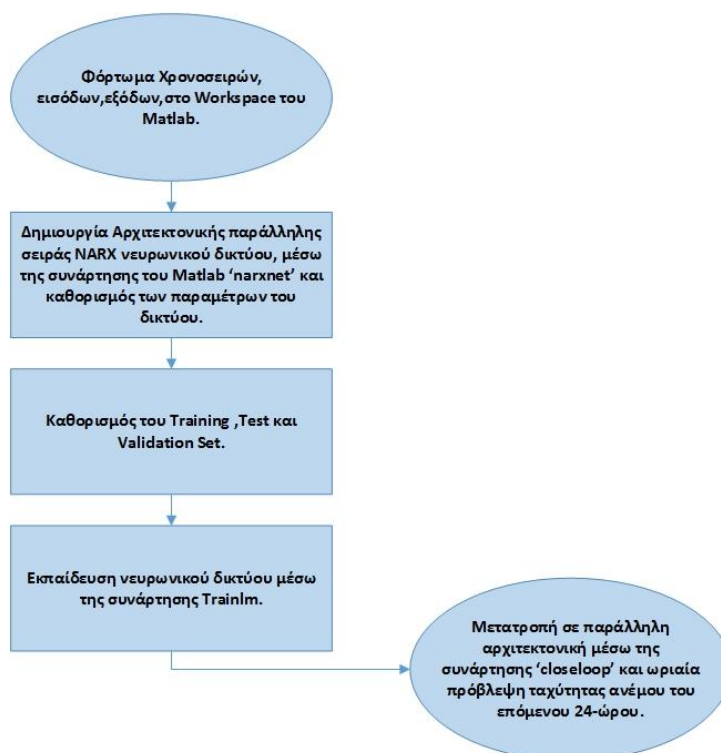
Εικόνα 24: Αρχιτεκτονική παράλληλης σειράς για την πρόβλεψη ταχύτητας ανέμου

Στη συνέχεια η παραπάνω αρχιτεκτονική μετατρέπεται σε παράλληλη αρχιτεκτονική για την πρόβλεψη 24 ωρών εκ' των προτέρων. Η πρόβλεψη της επόμενης τιμής εξαρτάται από τις εισόδους και τις προηγούμενες εξόδους στο δίκτυο. Η εξάρτηση από την προηγούμενη έξοδο μπορεί να ρυθμιστεί χρησιμοποιώντας καθυστερήσεις, καθυστερήσεις εισόδου και καθυστερήσεις ανάδρασης (input/feedback delays).



Εικόνα 25: Παράλληλη Αρχιτεκτονική για μεσοπρόθεσμη πρόβλεψη ταχύτητας ανέμου

Απ' τα παραπάνω σχήματα είναι φανερές και οι μεταβλητές που χρησιμοποιήθηκαν για τη δημιουργία του δικτύου. Συγκεκριμένα το μοντέλο φτιάχτηκε μέσω της συνάρτησης του Matlab "**narxnet**" με παραμέτρους: **inputDelays**=[1:24], **feedbackDelays**=[1:24], **hiddenLayerSize**=20, **trainFcn** = 'trainlm'(Levenberg-Marquardt backpropagation). Οι εισοδοί που χρησιμοποιήθηκαν στο συγκεκριμένο μοντέλο πρόβλεψης ήταν οι εξής: θερμοκρασία αέρα, σχετική υγρασία, ατμοσφαιρική πίεση, ώρα μέτρησης, ώρα έτους, ηλιακή ακτινοβολία. Μετά την εκπαίδευση του μοντέλου, ακολούθησε η μετατροπή του σε παράλληλη αρχιτεκτονική μέσω της συνάρτησης του Matlab "**closeloop**", για να μπορεί να γίνει η μεσοπρόθεσμη πρόβλεψη της ταχύτητας του ανέμου.



Εικόνα 26: Βήματα για την πρόβλεψη με το μοντέλο NARX

3) Αναδρομικό Μοντέλο με ARMA σφάλματα

Το μοντέλο αυτό δημιουργήθηκε με τη βοήθεια του Econometric Modeler App του Matlab. Αρχικά εκχωρήθηκε όλο το σύνολο δεδομένων και επιλέχθηκε το αναδρομικό μοντέλο με ARMA σφάλματα απ' τη λίστα των μοντέλων. Στη συνέχεια ορίστηκε η μεταβλητή εξόδου απ' το σύνολο δεδομένων, η οποία πρέπει να προβλεφθεί (στην προκειμένη περίπτωση η ταχύτητα του ανέμου), καθώς και οι παράμετροι του μοντέλου, όπως φαίνονται στην ακόλουθη εικόνα (Εικ.27). Συγκεκριμένα **Autoregressive Order=10**, **Moving Average Order=24**, **Autoregressive Lags=[1:10]** και **Moving Average Lags=[1:24]**. Ως μεταβλητές εισόδου (Predictors) ορίστηκαν τα εξής: θερμοκρασία αέρα, σχετική υγρασία, ατμοσφαιρική πίεση, ώρα μέτρησης, ώρα έτους, ταχύτητα ανέμου προηγούμενου 24ωρου και ηλιακή ακτινοβολία. Η εξίσωση του μοντέλου απ' την οποία προκύπτει η τελική πρόβλεψη φαίνεται στην παρακάτω εικόνα (Εικ.27). Συγκεκριμένα το y_t περιγράφει την ταχύτητα του ανέμου. Το c είναι μια σταθερά του αναδρομικού μοντέλου. Το X δηλώνει τα διανύσματα εισόδου που αναφέρθηκαν πιο πάνω (Predictors). Το β είναι συντελεστής παλινδρόμησης. Το μ_t είναι η σειρά που περιγράφει τις διαταραχές/διακυμάνσεις. Το $(1-\phi_1L-\dots-\phi_{10}L^{10})$ είναι το αυτό-αναδρομικό πολυώνυμο-βαθμού 10. Το $(1+\theta_1L+\dots+\theta_{24}L^{24})$ είναι το πολυώνυμο κινητού μέσου-βαθμού 24. Τέλος, η διαδικασία (ε_t) είναι μια ανεξάρτητη και ταυτόσημη κατανομημένη (iid), μέσης τιμής 0 διαδικασία με γνωστή κατανομή. Το Econometrics Toolbox™ γενικεύει τη διαδικασία σε $\varepsilon_t = \sigma z_t$, όπου το z_t είναι μια

σειρά με iid τυχαίες μεταβλητές μέσης τιμής 0 και διακύμανσης 1, όπου σ^2 είναι η σταθερή διακύμανση του ε_t .

The screenshot shows the EViews 'Lag Order' specification window. Under the 'Lag Order' tab, the 'Autoregressive Order' is set to 10 and the 'Moving Average Order' is set to 24. The 'Include Intercept' checkbox is checked. The 'Predictors' table on the right lists X1 through X7, all of which are included (checked). The 'Model Equation' section displays the equation: $y_t = c + X_1\beta_1 + \dots + X_7\beta_7 + \mu_t$, where $\mu_t = (1 - \phi_1L - \dots - \phi_{10}L^{10})\mu_t = (1 + \theta_1L + \dots + \theta_{24}L^{24})\varepsilon_t$. At the bottom, the 'Innovation Distribution' is set to 'Gaussian', and buttons for 'Details', 'Estimate', and 'Cancel' are visible.

Εικόνα 27: Παράμετροι αναδρομικού μοντέλου με ARMA σφάλματα για την πρόβλεψη ταχύτητας ανέμου

4) Βαθιά Νευρωνικά Δίκτυα Μακράς-Βραχείας Διάρκειας Μνήμης (LSTM)

Το μοντέλο που αναπτύχθηκε και βασίζεται στα LSTM- DNN, αποτελείται από 8 επίπεδα (layers), όπως είναι φανερό και στην παρακάτω εικόνα. Συγκεκριμένα αποτελείται από 1 SequenceInputLayer, 3 Lstm layers, 2 Dropout layers, 1 Dense layer και ένα RegressionOutput layer.

Το sequenceInputLayer με το οποίο εισάγονται τα δεδομένα στο δίκτυο αποτελείται από 150 νευρώνες με 24 input_timesteps. Τρία Lstm layers με 150 νευρώνες τα οποία όπως είναι γνωστό από τη θεωρία, μαθαίνουν μακροπρόθεσμες εξαρτήσεις μεταξύ χρονικών βημάτων σε χρονοσειρές και δεδομένα ακολουθιών.

Τα Dropout layers χρησιμοποιούνται στο να αποφεύγονται καταστάσεις όπως το overfitting στα μοντέλα. Το overfitting δηλώνει ότι το μοντέλο έχει μάθει να προβλέπει σχεδόν τέλεια ένα συγκεκριμένο σύνολο δεδομένων και με την εισαγωγή νέων χρονοσειρών αποτυγχάνει. Τα Dropout layers αγνοούν κάποιους νευρώνες από μια ομάδα νευρώνων, κατά τη διαδικασία της εκπαίδευσης του μοντέλου, τους οποίους τους έχουν επιλέξει με τυχαίο τρόπο. Από τεχνικής άποψης, σε κάθε στάδιο προπόνησης, μεμονωμένοι κόμβοι είτε αγνοούνται από το δίκτυο με πιθανότητα $1-p$ είτε διατηρούνται με πιθανότητα p , έτσι ώστε να μείνει ένα μειωμένο δίκτυο. Οι εισερχόμενες και εξερχόμενες άκρες σε έναν αποκλεισμένο κόμβο αγνοούνται επίσης. Η τιμή (rate) της πιθανότητας καθορίζεται από μας. Στην περίπτωση μας και τα δυο Dropout layers έχουν rate ίσο με 0.2.

Το Dense layer είναι ένα κλασικό πλήρως συνδεδεμένο layer νευρωνικού δικτύου όπου κάθε κόμβος εισόδου συνδέεται σε κάθε κόμβο εξόδου.

Το RegressionOutput layer υπολογίζει την απώλεια μισού μέσου-τετραγωνικού-σφάλματος (half-mean-squared-error loss). Σε προβλήματα πρόβλεψης χρονοσειρών ένα RegressionOutput layer πρέπει να ακολουθεί το τελικό πλήρως συνδεδεμένο στρώμα (Dense layer), όπως γίνεται και στην περίπτωση μας. Η απώλεια μισού μέσου-τετραγωνικού-σφάλματος δίνεται από τη σχέση:

$$\text{loss} = \frac{1}{2N} \sum_{i=1}^M (X_i - T_i)^2$$

Όπου:

X_i είναι η απόκριση δικτύου

T_i είναι ο στόχος

M είναι ο συνολικός αριθμός αποκρίσεων στο X (σε όλες τις παρατηρήσεις)

N είναι ο συνολικός αριθμός παρατηρήσεων στο X .



Εικόνα 28: Μορφή DNN

Επιπλέον, στη μηχανική μάθηση ο τελικός σκοπός βασίζεται στην ελαχιστοποίηση ή τη μεγιστοποίηση μιας συνάρτησης που ονομάζεται αντικειμενική συνάρτηση (objective function). Το σύνολο των συναρτήσεων που ελαχιστοποιούνται ονομάζονται "συναρτήσεις απώλειας". Η συνάρτηση απώλειας χρησιμοποιείται ως μέτρηση του πόσο καλό είναι ένα μοντέλο πρόβλεψης, δηλαδή κατά πόσο η πρόβλεψη του μοντέλου είναι κοντά στην πραγματική τιμή. Στην περίπτωση μας σαν loss function χρησιμοποιούμε το μέσο τετραγωνικό σφάλμα (mean square error). Επίσης μαζί με τη συνάρτηση απώλειας θα πρέπει να καθοριστεί και ο βελτιστοποιητής (optimizer). Ο optimizer ενημερώνει κάθε φορά τις παραμέτρους του βάρους, έτσι ώστε να ελαχιστοποιείται η συνάρτηση απώλειας. Ο optimizer που χρησιμοποιούμε είναι ο adam optimizer.


Οι εισοδοί που χρησιμοποιούνται στο μοντέλο είναι : θερμοκρασία αέρα, σχετική υγρασία, ατμοσφαιρική πίεση, ταχύτητα ανέμου προηγούμενου 24ωρου και έξοδος είναι η ταχύτητα του ανέμου.

4.2.2: Μοντέλα Πρόβλεψης Ηλιακής Ακτινοβολίας

Τα μοντέλα μεσοπρόθεσμης πρόβλεψης ηλιακής ακτινοβολίας βασίστηκαν στην ίδια φιλοσοφία και ακολουθηθήκαν τα ίδια βήματα κατασκευής τους με αυτά της ταχύτητας ανέμου. Οι είσοδοι που χρησιμοποιήθηκαν στα μοντέλα πρόβλεψης ηλιακής ακτινοβολίας είναι: **θερμοκρασία αέρα, σχετική υγρασία, ατμοσφαιρική πίεση, ώρα μέτρησης, ώρα έτους και ηλιακή ακτινοβολία προηγούμενης ημέρας**. Αξίζει να σημειωθεί ότι στα σύνολα δεδομένων θα χρειαζόταν ιδανικά να υπήρχαν και καταγραφές για θολερότητα (ποσοστό κάλυψης συννέφων) ανά ώρα, καθώς και η μέση διάρκεια ηλιοφάνειας ανά ώρα, ωστόσο δεν βρέθηκαν αυτά τα δεδομένα για τη συγκεκριμένη τοποθεσία. Όπως είναι φανερό, καθώς επίσης αποδεικνύεται απ' την βιβλιογραφία [14], η θολερότητα είναι ένας παράγοντας που επηρεάζει ως ένα βαθμό την ηλιακή ακτινοβολία. Σε περιπτώσεις που επικρατεί συννεφιά, φαίνεται πως δυσκολεύει η πρόβλεψη της ηλιακής ακτινοβολίας και παρατηρούνται μεγαλύτερα σφάλματα πρόβλεψης, συγκριτικά με τις περιπτώσεις που έχουμε χαμηλή κάλυψη από σύννεφα ή και καθόλου. Επίσης δοκιμάστηκε η αξιοποίηση της εξωγήινης ακτινοβολίας (G_0) εντάσσοντάς τη στο δiάνυσμα εισόδου, ωστόσο δεν βελτιώθηκε η ακρίβεια πρόβλεψης.


1) Αναδρομικά Δέντρα Απόφασης

Το βέλτιστο μέγεθος των φύλλων (leaf size) καθορίστηκε με τον ίδιο τρόπο όπως στην πρόβλεψη ταχύτητας ανέμου. Αρχικά φτιάχτηκε το μοντέλο αναπτύσσοντας 50 δέντρα προκειμένου να μην είναι πολύ χρονοβόρα η διαδικασία. Χρησιμοποιώντας ενδεικτικά 5 προτεινόμενα leaf sizes (5,10,20,50,100) συγκρίνοντας τα μέσα τετραγωνικά σφάλματα που προέκυψαν μετά την εφαρμογή του μοντέλου και την πρόβλεψη για τα ενδεικτικά μεγέθη φύλλων, εξήχθηκε τελικά το βέλτιστο μέγεθος φύλλου, το οποίο ισούται με 5 όπως φαίνεται παρακάτω.




Εικόνα 29: Εύρεση βέλτιστου ελάχιστου μεγέθους φύλλων για την πρόβλεψη ηλιακής ακτινοβολίας

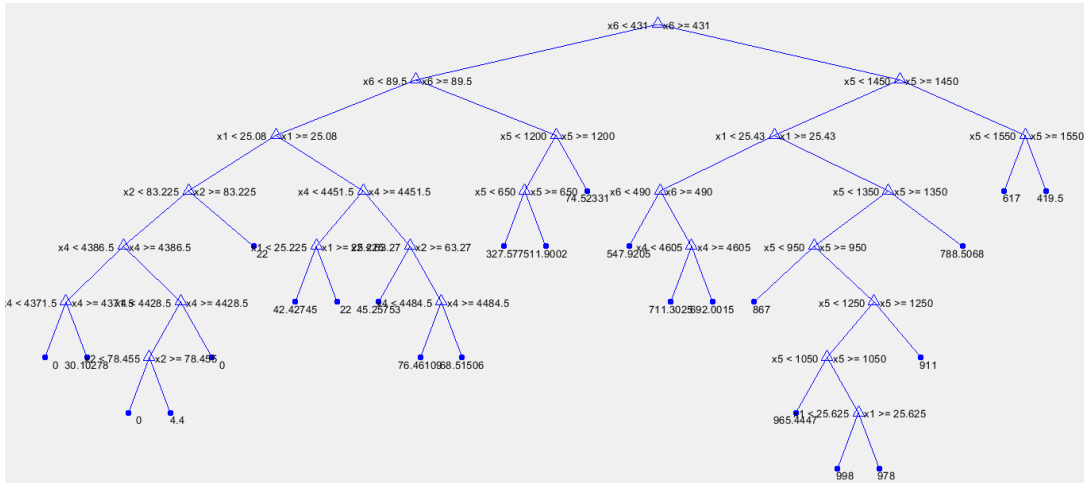
Το μοντέλο δημιουργήθηκε με χρήση της συνάρτησης του Matlab **TreeBagger**. Στο μοντέλο αναπτύχθηκαν 200 δέντρα (κατά την εκπαίδευση), με minLeafsize 5, έχοντας ως διάνυσμα εισόδου: θερμοκρασία αέρα, σχετική υγρασία, ατμοσφαιρική πίεση, ώρα μέτρησης, ώρα έτους και ηλιακή ακτινοβολία προηγούμενης ημέρας και ως έξοδο είχε την ηλιακή ακτινοβολία. Η βαρύτητα της κάθε μεταβλητής εισόδου στην πρόβλεψη της ηλιακής ακτινοβολίας (ενδεικτικά για τον Ιούλιο) φαίνεται παρακάτω.



Εικόνα 30: Σημασία/Βαρύτητα κάθε μεταβλητής εισόδου για την πρόβλεψη ηλιακής ακτινοβολίας



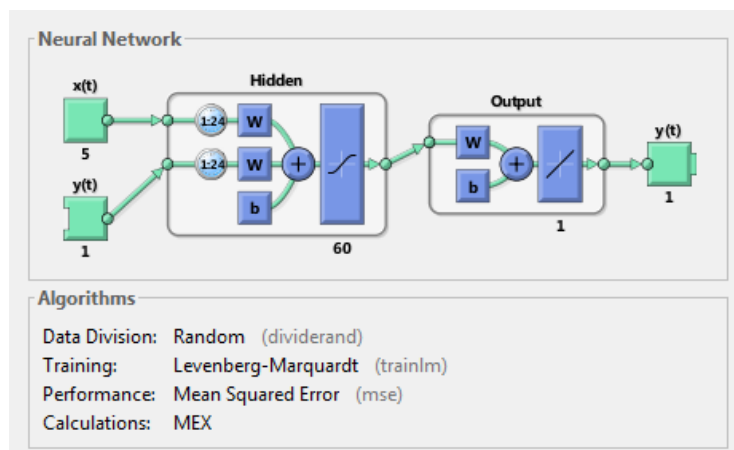
Εικόνα 31: Στιγμιότυπο δέντρου απόφασης για την πρόβλεψη ηλιακής ακτινοβολίας



Εικόνα 32: Στιγμιότυπο δέντρου απόφασης με ετικέτες στους κόμβους για την πρόβλεψη ηλιακής ακτινοβολίας


2) Μη-γραμμικό αυτό-ρυθμιζόμενο εξωγενές μοντέλο (NARX)

Τα βήματα τα οποία ακολουθήθηκαν για την δημιουργία του συγκεκριμένου μοντέλου ήταν τα ίδια με το αντίστοιχο της πρόβλεψης ταχύτητας ανέμου. Στην εικόνα που ακολουθεί, φαίνεται η αρχιτεκτονική παράλληλης σειράς που αναπτύχθηκε για την μεσοπρόθεσμη πρόβλεψη ηλιακής ακτινοβολίας.



Εικόνα 33: Αρχιτεκτονική παράλληλης σειράς του μοντέλου NARX για την πρόβλεψη ηλιακής ακτινοβολίας

Στη συνέχεια η παραπάνω αρχιτεκτονική μετατρέπεται σε παράλληλη αρχιτεκτονική για την πρόβλεψη 24 ωρών εκ' των προτέρων .



Εικόνα 34: Παράλληλη Αρχιτεκτονική για μεσοπρόθεσμη πρόβλεψη ηλιακής ακτινοβολίας

Απ' τα παραπάνω σχήματα είναι φανερές και οι μεταβλητές που χρησιμοποιήθηκαν για τη δημιουργία του δικτύου. Συγκεκριμένα το μοντέλο φτιάχτηκε μέσω της συνάρτησης του Matlab **"narxnet"** με παραμέτρους: **inputDelays=[1:24]**, **feedbackDelays=[1:24]**, **hiddenLayerSize=60**, **trainFcn = 'trainlm'(Levenberg-Marquardt backpropagation)**. Οι εισοδοί που χρησιμοποιήθηκαν στο συγκεκριμένο μοντέλο πρόβλεψης ήταν οι εξής: θερμοκρασία αέρα, σχετική υγρασία, ατμοσφαιρική πίεση, ώρα μέτρησης, ώρα έτους. Μετά την εκπαίδευση του μοντέλου, ακολούθησε η μετατροπή του σε παράλληλη αρχιτεκτονική μέσω της συνάρτησης του Matlab **"closeloop"**, για να μπορεί να γίνει η μεσοπρόθεσμη πρόβλεψη της ηλιακής ακτινοβολίας.

3) Αναδρομικό Μοντέλο με ARMA σφάλματα

Το μοντέλο αυτό δημιουργήθηκε με τη βοήθεια του Econometric Modeler App του Matlab. Αφού εκχωρήθηκε το σύνολο δεδομένων και επιλέχθηκε το αναδρομικό μοντέλο με ARMA σφάλματα απ' τη λίστα των μοντέλων, στη συνέχεια ορίστηκε η μεταβλητή εξόδου την οποία θέλουμε να προβλέψουμε (στην προκειμένη περίπτωση η ηλιακή ακτινοβολία), καθώς και οι παράμετροι του μοντέλου. Συγκεκριμένα **Autoregressive Order=10**, **Moving Average Order= 24**, **Autoregressive Lags=[1:10]** και **Moving Average Lags=24**. Ως μεταβλητές εισόδου (Predictors) ορίστηκαν τα εξής: θερμοκρασία αέρα, σχετική υγρασία, ατμοσφαιρική πίεση, ώρα μέτρησης, ώρα έτους και ηλιακή ακτινοβολία προηγούμενης ημέρας.

4.3: Εκπαίδευση Μοντέλων και Πρόβλεψη

Κατά τη διαδικασία της εκπαίδευσης τα βάρη των συντελεστών των μοντέλων προσαρμόζονται με τέτοιο τρόπο ώστε οι προβλεπόμενες τιμές να προσεγγίζουν τις πραγματικές. Στην περίπτωση μας χρησιμοποιούνται σύνολα δεδομένων τα οποία έχουν καταγραφεί για τις χρονιές 2007, 2008 και 2009 (απ' το νησί Ντία). Σ' όλα τα μοντέλα μεσοπρόθεσμης πρόβλεψης ακολουθείται η ίδια διαδικασία εκπαίδευσης. Τα σύνολα δεδομένων χωρίζονται σε μικρότερα σύνολα τα οποία περιλαμβάνουν τον κάθε μήνα ξεχωριστά. Στη συνέχεια ομαδοποιούνται


σε σύνολα με τους κοινούς μήνες. Τέλος εκπαιδεύεται το εκάστοτε μοντέλο χρησιμοποιώντας τα σύνολα με μήνες του 2007 και του 2008 (training sets) και προβλέπεται ο εκάστοτε μήνας του 2009 (test set) σε ημερήσια βάση (μεσοπρόθεσμη πρόβλεψη). Συγκριμένα, αρχικά γίνεται training χρησιμοποιώντας το σύνολο που περιέχει τον Ιανουάριο του 2007 και του 2008 και προβλέπεται ημερησίως ο Ιανουάριος του 2009. Αυτή η διαδικασία συνεχίζεται επαναληπτικά και για τους υπόλοιπους μήνες. Το σκεπτικό του να χωρίζονται τα δεδομένα, να ομαδοποιούνται ανά μήνα και να εκπαιδεύονται τα μοντέλα με τα σύνολα που προκύπτουν βασίζεται στο ότι, τόσο η ηλιακή ακτινοβολία όσο και ο άνεμος εμφανίζουν περιοδικότητα κατά τη διάρκεια της ημέρας, του μήνα και της εποχής.

Συγκεκριμένα όσον αφορά την ταχύτητα του ανέμου παρατηρούνται διακυμάνσεις συνεχώς. Κατά συνέπεια μεταβάλλεται αντίστοιχα και η ενέργεια του ανέμου. Το ακριβές μέγεθος των μεταβολών εξαιτίας των διακυμάνσεων εξαρτάται τόσο από τις καιρικές συνθήκες, όσο και από την τραχύτητα του εδάφους και από τυχόν υπάρχοντα εμπόδια κατά την ροή του ανέμου. Στις περισσότερες περιοχές της γης οι άνεμοι κατά την διάρκεια της ημέρας, είναι ισχυρότεροι από τους αντίστοιχους που καταγράφονται κατά την διάρκεια της νύχτας. Αυτή η παρατηρούμενη μεταβλητότητα οφείλεται κυρίως στις μεγαλύτερες θερμοκρασιακές διαφορές, για παράδειγμα, μεταξύ της θάλασσας και της ξηράς, κατά την διάρκεια της ημέρας σε σχέση με τις αντίστοιχες που υφίστανται κατά την διάρκεια της νύχτας. Επίσης, ο άνεμος έχει εντονότερα τυρβώδη χαρακτηριστικά και τείνει να αλλάζει διευθύνσεις συχνότερα κατά την διάρκεια της ημέρας, παρά κατά την διάρκεια της νύχτας. Όσον αφορά την ημερήσια κατανομή της ταχύτητας ανά μήνα, όπως είναι φανερό και στις παρακάτω εικόνες, παρατηρήθηκε ότι η ταχύτητα του ανέμου παρουσιάζει μεγάλες διακυμάνσεις τις ημέρες των χειμερινών μηνών. Η διακύμανση στις ημερήσιες ταχύτητες, για τους μήνες από τον Αύγουστο έως το Σεπτέμβριο είναι μικρότερη. Γενικότερα ισχυρότεροι ημερήσιοι άνεμοι παρατηρήθηκαν κυρίως χειμερινούς μήνες (τέλη Δεκεμβρίου μέχρι Φεβρουάριο) και το καλοκαίρι (Ιούνιο και Ιούλιο), γνωστοί ως Shamal, που σημαίνει άνεμος προερχόμενος από το βορρά. Η μέγιστη τιμή της ταχύτητας σημειώνεται κατά τη διάρκεια της ημέρας, λόγω της επίδρασης της ηλιακής ακτινοβολίας στο προφίλ της ημερήσιας ταχύτητας του ανέμου. Ιδιαίτερα τους καλοκαιρινούς μήνες, υπάρχει ξεκάθαρη διαφορά της ταχύτητας του ανέμου μεταξύ των ωρών της ημέρας και της νύχτας. Αυτό οφείλεται στην ένταση της ηλιακής ακτινοβολίας κατά τη διάρκεια της ημέρας η οποία προσπίπτει στην επιφάνεια της γης και μετατρέπεται σε άνεμο. Αντίθετα, Σεπτέμβριο- Νοέμβριο, καθώς και καθ' όλη σχεδόν τη διάρκεια της άνοιξης, ο άνεμος είναι σχετικά μικρής έντασης, αλλά δυναμώνει από το Δεκέμβριο μέχρι το Μάρτιο.


Ομοίως και η ηλιακή ακτινοβολία εμφανίζει μια περιοδικότητα κατά τη διάρκεια της ημέρας, του μήνα και της εποχής όπως φαίνεται παρακάτω. Συγκεκριμένα, ξεκινά πάντα απ' το μηδέν (W/m^2) τις νυχτερινές ώρες, στη συνέχεια αυξάνει και παίρνει τη μέγιστη τιμή της κατά τις μεσημεριανές ώρες και από εκεί και πέρα αρχίζει και φθίνει. Ο λόγος που η ηλιακή ακτινοβολία έχει τη μορφή καμπάνας σε καθημερινή βάση, δεν είναι άλλος απ' την εναλλαγή της θέσης του ηλίου κατά την διάρκεια της ημέρας. Επίσης η περιοδικότητα που εμφανίζει σχετικά με τις εποχές οφείλεται στην εναλλαγή της απόστασης του ήλιου σε σχέση με τη γη.

Όπως είναι αναμενόμενο και κάτι το οποίο επαληθεύεται απ' τις εικόνες, τους καλοκαιρινούς μήνες που ο ήλιος βρίσκεται στην πιο κοντινή θέση σε σχέση με τη γη, η ηλιακή ακτινοβολία παίρνει τη μέγιστη τιμή της. Αντίθετα, τους φθινοπωρινούς και τους χειμερινούς μήνες παίρνει χαμηλές τιμές.

A) Δεδομένα ανέμου για τη χρονιά 2007




B) Δεδομένα ανέμου για τη χρονιά 2008




Εικόνα 35: Δεδομένα ανέμου του Training-set

Γ) Δεδομένα ανέμου για τη χρονιά 2009




Εικόνα 36: Δεδομένα ανέμου του Test-set

Α) Δεδομένα ηλιακής ακτινοβολίας για τη χρονιά 2007




Β) Δεδομένα ηλιακής ακτινοβολίας για τη χρονιά 2008



Εικόνα 37: Ηλιακή Ακτινοβολία- Training Set

Γ) Δεδομένα ηλιακής ακτινοβολίας για τη χρονιά 2009



Εικόνα 38: Ηλιακή Ακτινοβολία - Test Set

4.4: Μέθοδοι Μεσοπρόθεσμης Πρόβλεψης

Η πρόβλεψη χρονοσειρών σχετίζεται συνήθως με πρόβλεψη κυρίως ενός χρονικού βήματος εκ' των προτέρων. Στην περίπτωση μας όμως κάνουμε πρόβλεψη πολλαπλών βημάτων εκ' των προτέρων. Για το λόγο αυτό έχουν αναπτυχθεί τέσσερις βασικές στρατηγικές, που χρησιμοποιούνται για την πρόβλεψη πολλαπλών βημάτων, οι οποίες είναι οι ακόλουθες :

1. Άμεση πρόβλεψη πολλαπλών βημάτων
2. Αναδρομική πρόβλεψη πολλαπλών βημάτων
3. Άμεση- Αναδρομική υβριδική πρόβλεψη πολλαπλών βημάτων
4. Στρατηγική πολλαπλής πρόβλεψης

1) Άμεση πρόβλεψη πολλαπλών βημάτων

Η άμεση μέθοδος περιλαμβάνει την ανάπτυξη ενός ξεχωριστού μοντέλου για κάθε χρονικό βήμα πρόβλεψης. Για παράδειγμα στην περίπτωση πρόβλεψης της τιμής ενός προϊόντος για τις επόμενες δύο ημέρες, θα αναπτύσσαμε ένα μοντέλο για την πρόβλεψη της τιμής την 1^η ημέρα και ένα ξεχωριστό μοντέλο για την πρόβλεψη την 2^η ημέρα. Δηλαδή:

$$\begin{aligned}\text{prediction}(t+1) &= \text{model1}(\text{obs}(t-1), \text{obs}(t-2), \dots, \text{obs}(t-n)) \\ \text{prediction}(t+2) &= \text{model2}(\text{obs}(t-2), \text{obs}(t-3), \dots, \text{obs}(t-n))\end{aligned}$$

Βέβαια υπάρχουν κάποια προβλήματα στη χρήση αυτής της στρατηγικής. Έχοντας ένα μοντέλο για κάθε βήμα είναι ένα πρόσθετο υπολογιστικό βάρος, ειδικά καθώς ο αριθμός των χρονικών βημάτων που πρόκειται να προβλεφθεί αυξάνεται πέρα από το ασήμαντο. Επιπλέον, επειδή χρησιμοποιούνται ξεχωριστά μοντέλα, αυτό σημαίνει ότι δεν υπάρχει δυνατότητα μοντελοποίησης των εξαρτήσεων μεταξύ των προβλέψεων, όπως η πρόβλεψη της ημέρας 2 που εξαρτάται από την πρόβλεψη την ημέρα 1, όπως συμβαίνει συχνά σε χρονολογικές σειρές.

2) Αναδρομική πρόβλεψη πολλαπλών βημάτων

Η αναδρομική στρατηγική περιλαμβάνει τη χρήση ενός μοντέλου ενός βήματος πολλές φορές, όπου η πρόβλεψη για το προηγούμενο βήμα χρησιμοποιείται ως είσοδος για την πρόβλεψη για το επόμενο χρονικό βήμα.

Σε περίπτωση πρόβλεψης της τιμής ενός προϊόντος για τις επόμενες δύο ημέρες, θα αναπτύσσαμε ένα μοντέλο πρόβλεψης ενός βήματος. Αυτό το μοντέλο στη συνέχεια θα χρησιμοποιηθεί για την πρόβλεψη της ημέρας 1, και μετά αυτή η πρόβλεψη θα χρησιμοποιηθεί ως είσοδος για την πρόβλεψη της ημέρας 2.

$$\begin{aligned}\text{prediction}(t+1) &= \text{model}(\text{obs}(t-1), \text{obs}(t-2), \dots, \text{obs}(t-n)) \\ \text{prediction}(t+2) &= \text{model}(\text{prediction}(t+1), \text{obs}(t-1), \dots, \text{obs}(t-n))\end{aligned}$$

Σ' αυτή την περίπτωση τα βασικά προβλήματα της στρατηγικής 1 ξεπερνιούνται. Το μόνο θέμα που ίσως υπάρξει σ' αυτή τη στρατηγική είναι ότι συσσωρεύονται τα σφάλματα πρόβλεψης. Αυτό ενδέχεται να επηρεάσει την απόδοση του μοντέλου αν ο χρονικός ορίζοντας αυξηθεί κατά πάρα πολύ.

3) Άμεση- αναδρομική υβριδική πρόβλεψη πολλαπλών βημάτων

Η στρατηγική αυτή, όπως είναι φανερό προκύπτει απ' τον συνδυασμό των δυο προηγούμενων. Ένα ξεχωριστό μοντέλο μπορεί να κατασκευαστεί για κάθε χρονικό βήμα που πρέπει να προβλεφθεί, αλλά κάθε μοντέλο μπορεί να χρησιμοποιήσει τις προβλέψεις που έγιναν από μοντέλα σε προηγούμενα χρονικά βήματα, ως τιμές εισόδου.

Μπορούμε να δούμε πώς αυτό μπορεί να λειτουργήσει για την πρόβλεψη της τιμής ενός προϊόντος για τις επόμενες δύο ημέρες, όπου χρησιμοποιούνται δύο μοντέλα, αλλά η έξοδος από το πρώτο μοντέλο χρησιμοποιείται ως είσοδος για το δεύτερο μοντέλο.

$$\begin{aligned}\text{prediction}(t+1) &= \text{model1}(\text{obs}(t-1), \text{obs}(t-2), \dots, \text{obs}(t-n)) \\ \text{prediction}(t+2) &= \text{model2}(\text{prediction}(t+1), \text{obs}(t-1), \dots, \text{obs}(t-n))\end{aligned}$$

4) Στρατηγική Πολλαπλής πρόβλεψης

Η στρατηγική αυτή περιλαμβάνει την ανάπτυξη ενός μοντέλου που μπορεί να προβλέψει ολόκληρη την ακολουθία πρόβλεψης με έναν τρόπο. Σε περίπτωση πρόβλεψης της τιμής ενός προϊόντος για τις επόμενες δύο ημέρες, θα αναπτύσσαμε ένα μοντέλο και θα το χρησιμοποιούσαμε για να προβλέψουμε τις επόμενες δύο ημέρες ως μία λειτουργία.

$$\text{prediction}(t+1), \text{prediction}(t+2) = \text{model}(\text{obs}(t-1), \text{obs}(t-2), \dots, \text{obs}(t-n))$$

Τέτοιου είδους μοντέλα είναι πιο περίπλοκα καθώς μπορούν να μάθουν τη δομή εξάρτησης μεταξύ εισόδων και εξόδων καθώς και μεταξύ εξόδων. Το να είναι πιο περίπλοκο μπορεί να σημαίνει ότι είναι πιο αργά και απαιτούν περισσότερα δεδομένα κατά την εκπαίδευση τους. [\[10\]](#)

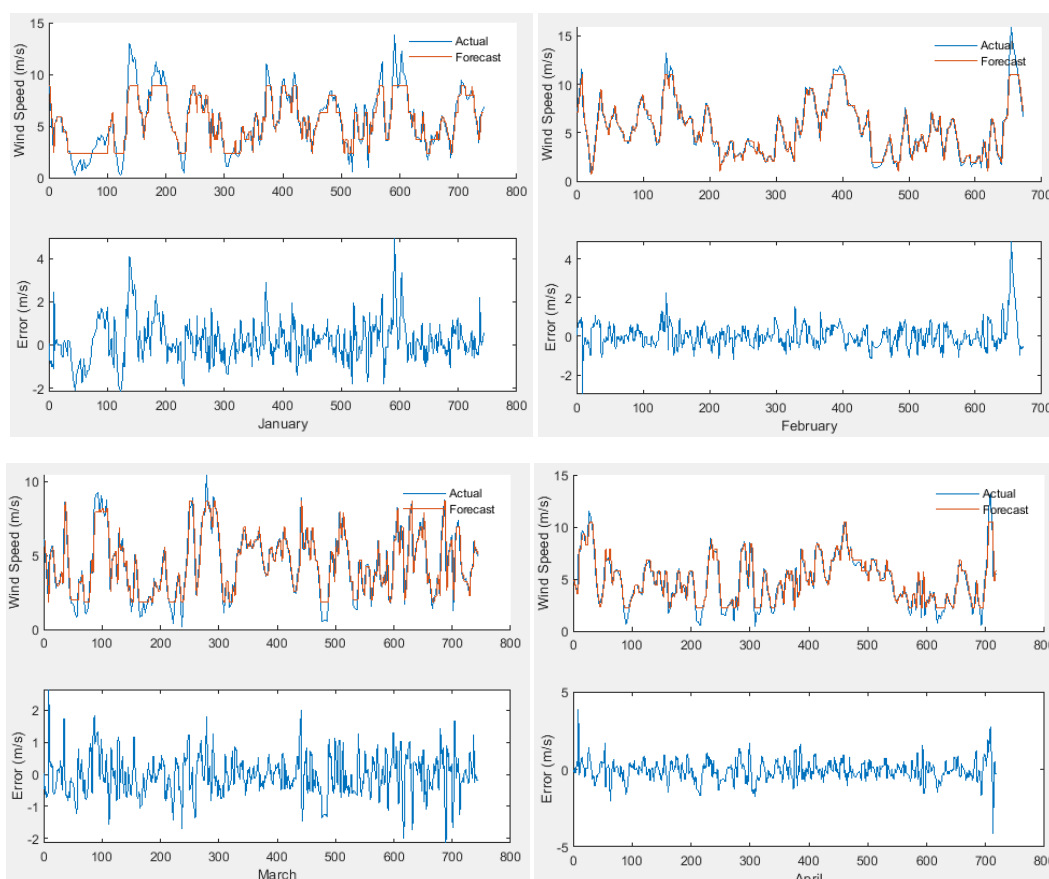
Στην περίπτωση μας οι προβλέψεις, τόσο της ταχύτητας ανέμου όσο και της ηλιακής ακτινοβολίας, γίνονται χρησιμοποιώντας τη στρατηγική 2, σε όλα τα μοντέλα επιμέρους. Ωστόσο στο κεφάλαιο 6 παρατίθενται συγκριτικά, αποτελέσματα μεταξύ των στρατηγικών 2 και 4, ενδεικτικά για τα μοντέλα Narx και RegArma για κάποιες ημέρες του χρόνου, που επιλέχθηκαν με τυχαίο τρόπο.

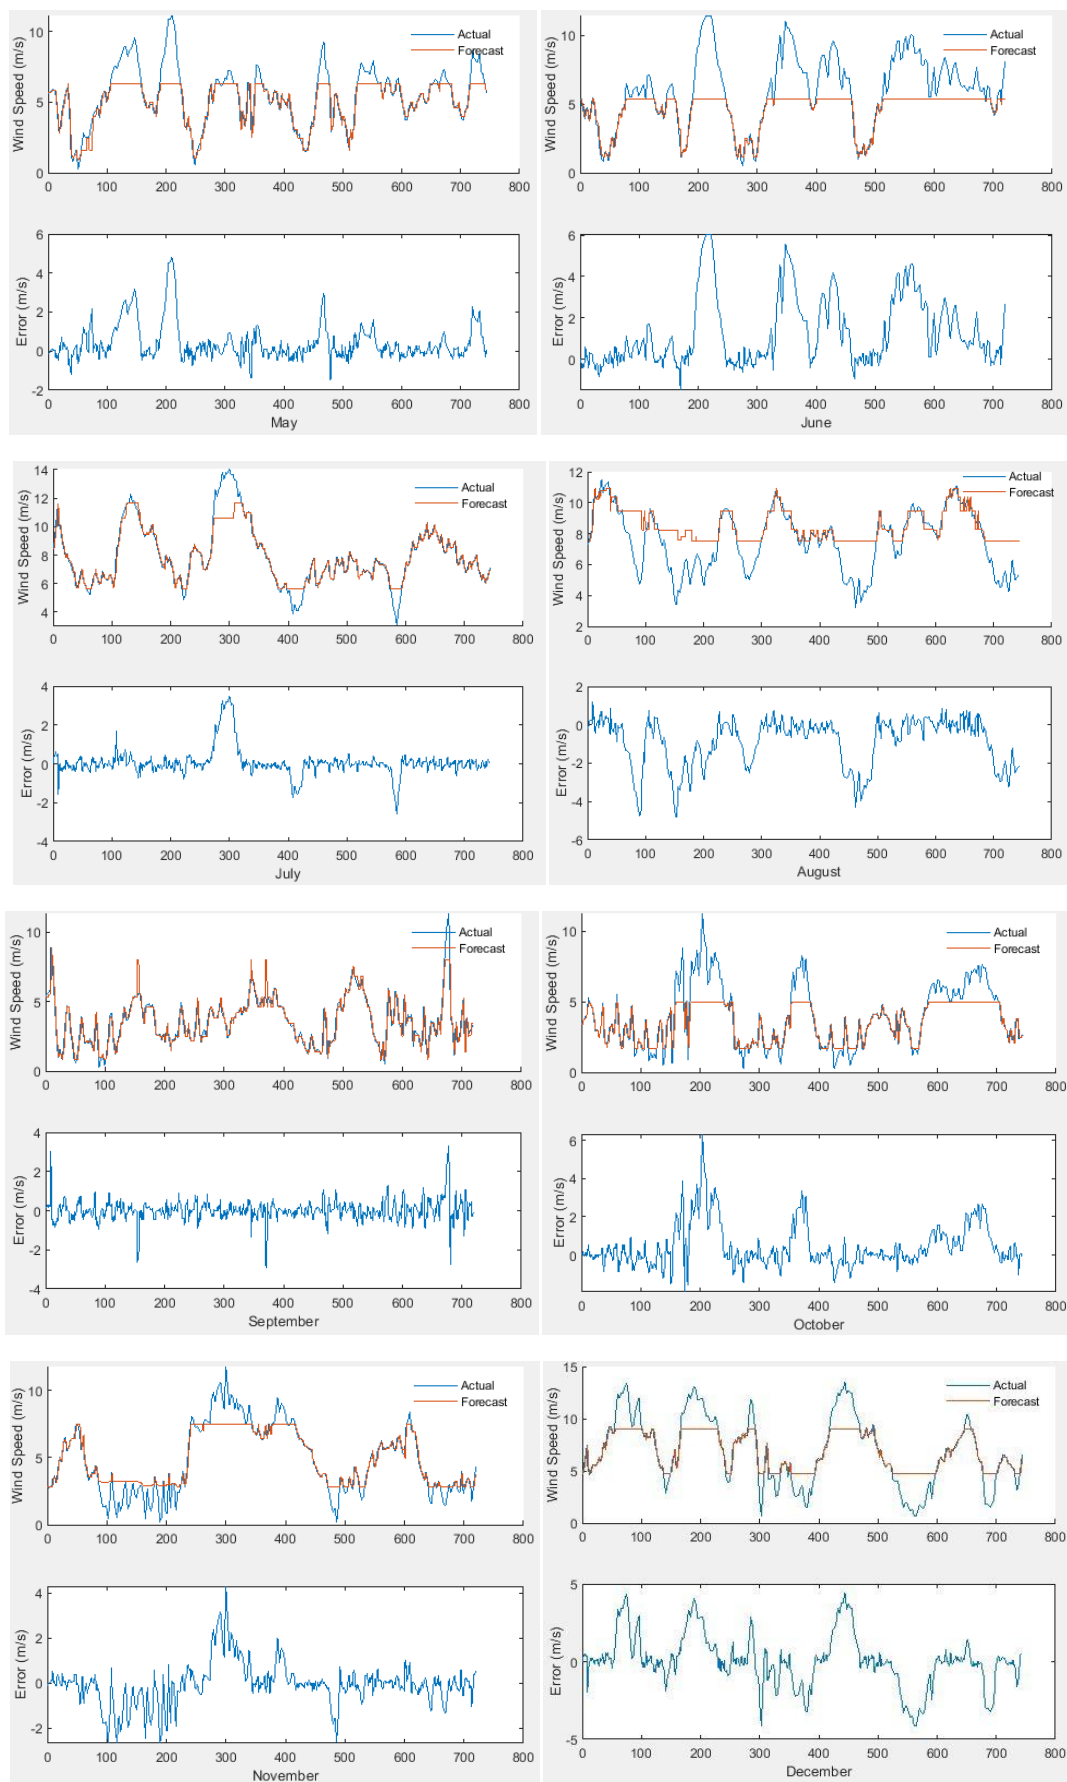
Κεφάλαιο 5: Αποτελέσματα μεσοπρόθεσμης πρόβλεψης

Σ' αυτό το κεφάλαιο παρουσιάζονται τα αποτελέσματα μεσοπρόθεσμης πρόβλεψης της ταχύτητας του ανέμου και της ηλιακής ακτινοβολίας όπως αυτά προέκυψαν μετά την εφαρμογή των μοντέλων. Παρατίθενται συγκριτικά τα αποτελέσματα των μοντέλων σε σχέση με τις πραγματικές τιμές και παράλληλα παρουσιάζονται οι αποκλίσεις (σφάλματα) προβλεπόμενης και πραγματικής τιμής. Στον άξονα x βρίσκονται οι ώρες κάθε μέρας και κατ' επέκταση του εκάστοτε μήνα και στον άξονα y η ταχύτητα του ανέμου ή η ηλιακή ακτινοβολία, αλλά και η απόκλιση προβλεπόμενης με πραγματική.

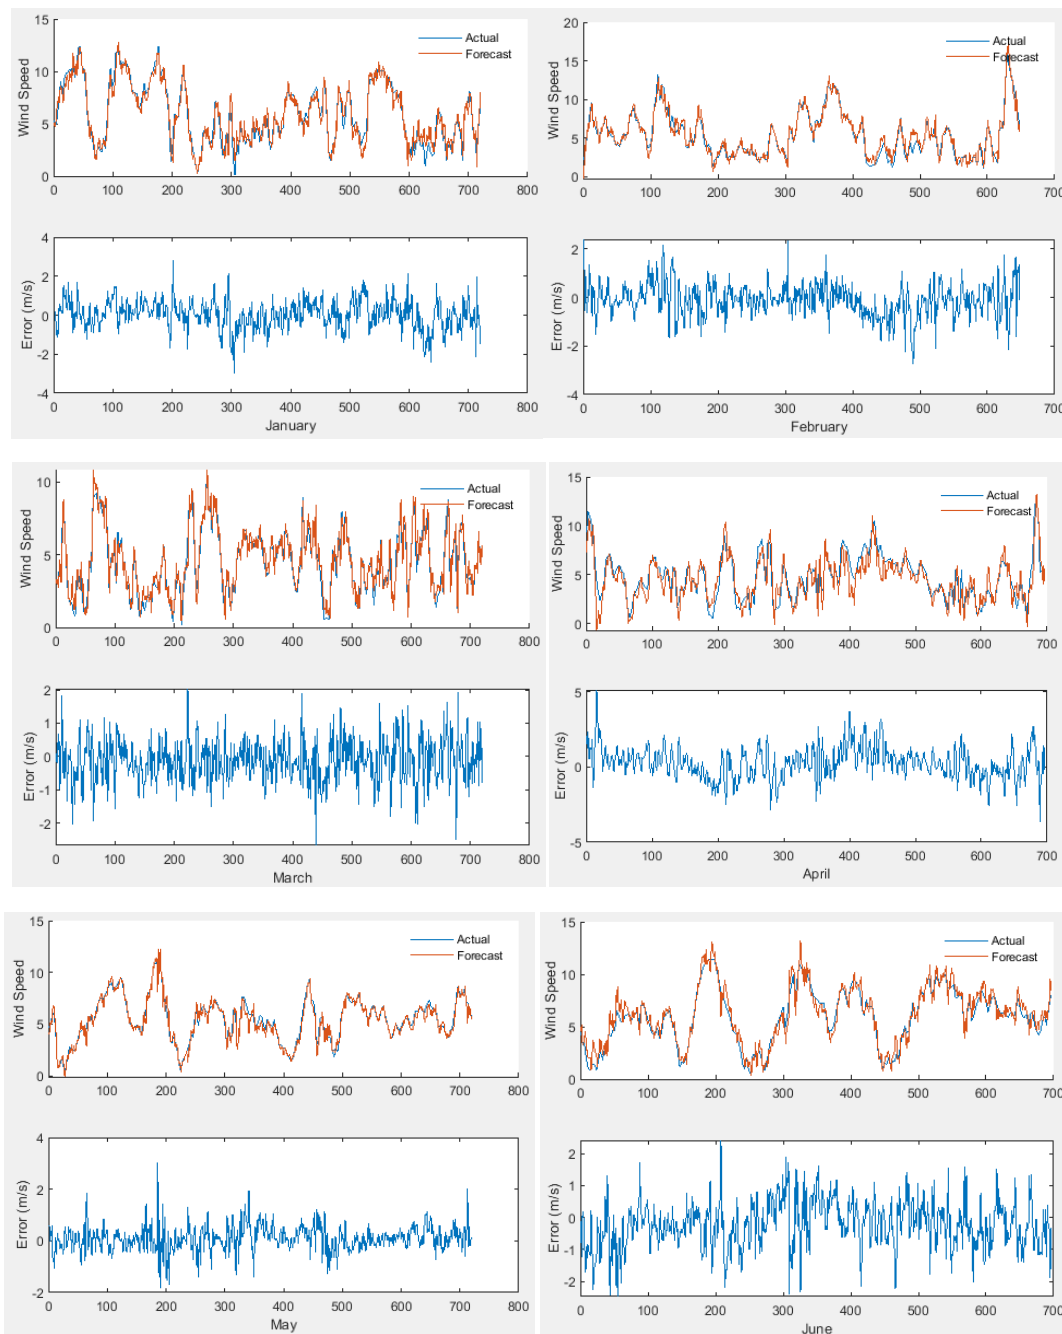
5.1: Αποτελέσματα μεσοπρόθεσμης πρόβλεψης ταχύτητας ανέμου συγκεντρωτικά ανά μήνα

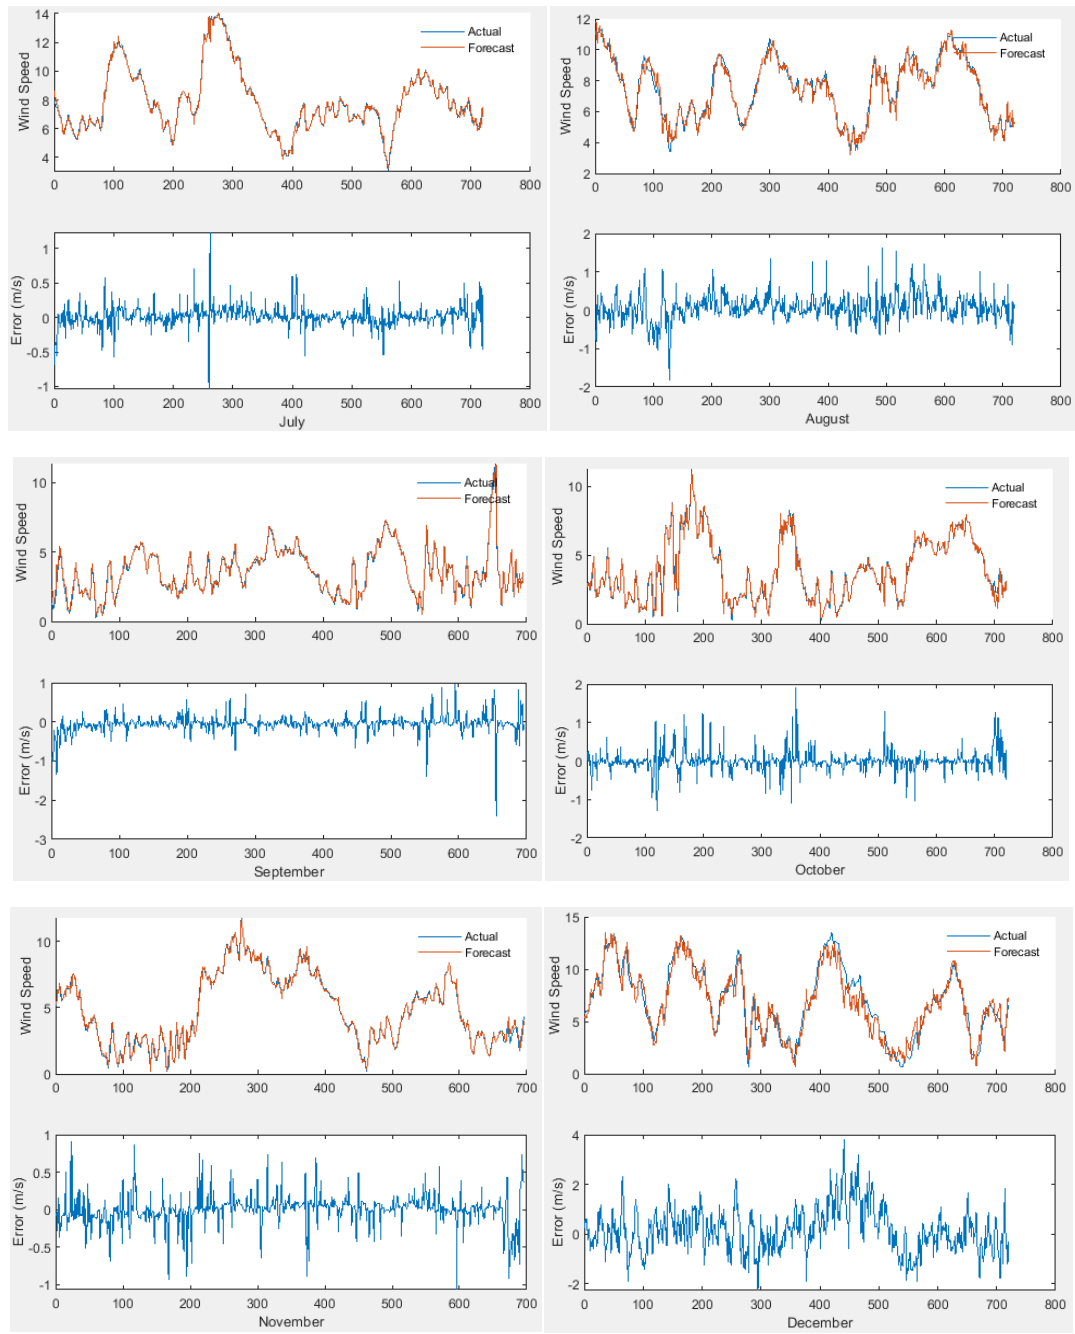
1) Αποτελέσματα Μοντέλου: Αναδρομικά Δέντρα Απόφασης



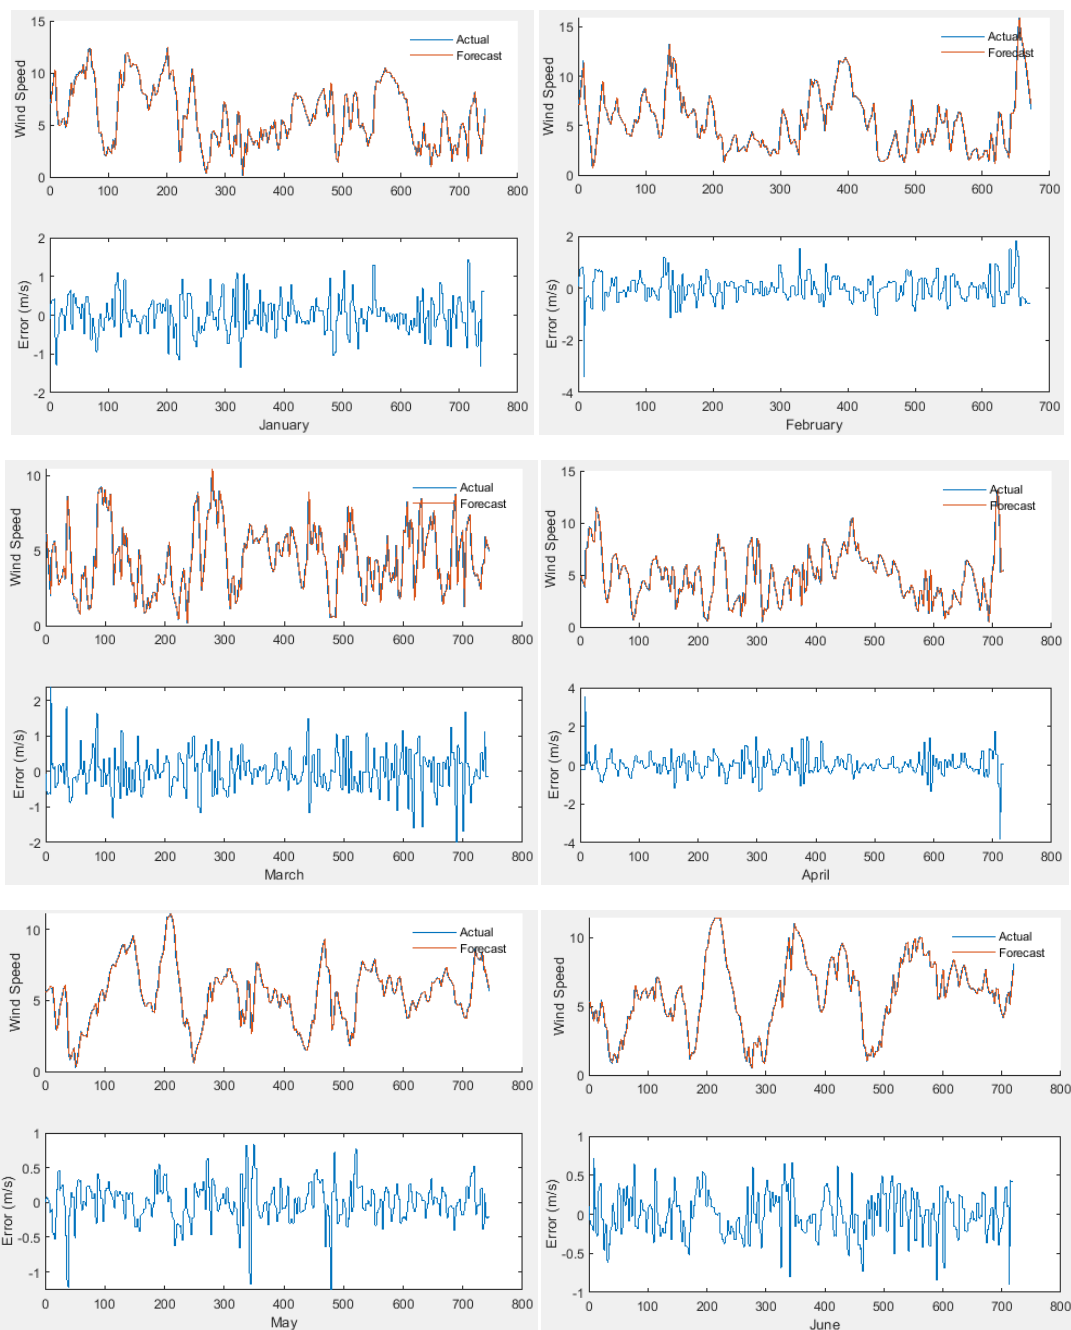


2) Αποτελέσματα Μοντέλου: Μη-γραμμικό αυτό-ρυθμιζόμενο εξωγενές μοντέλο (NARX)



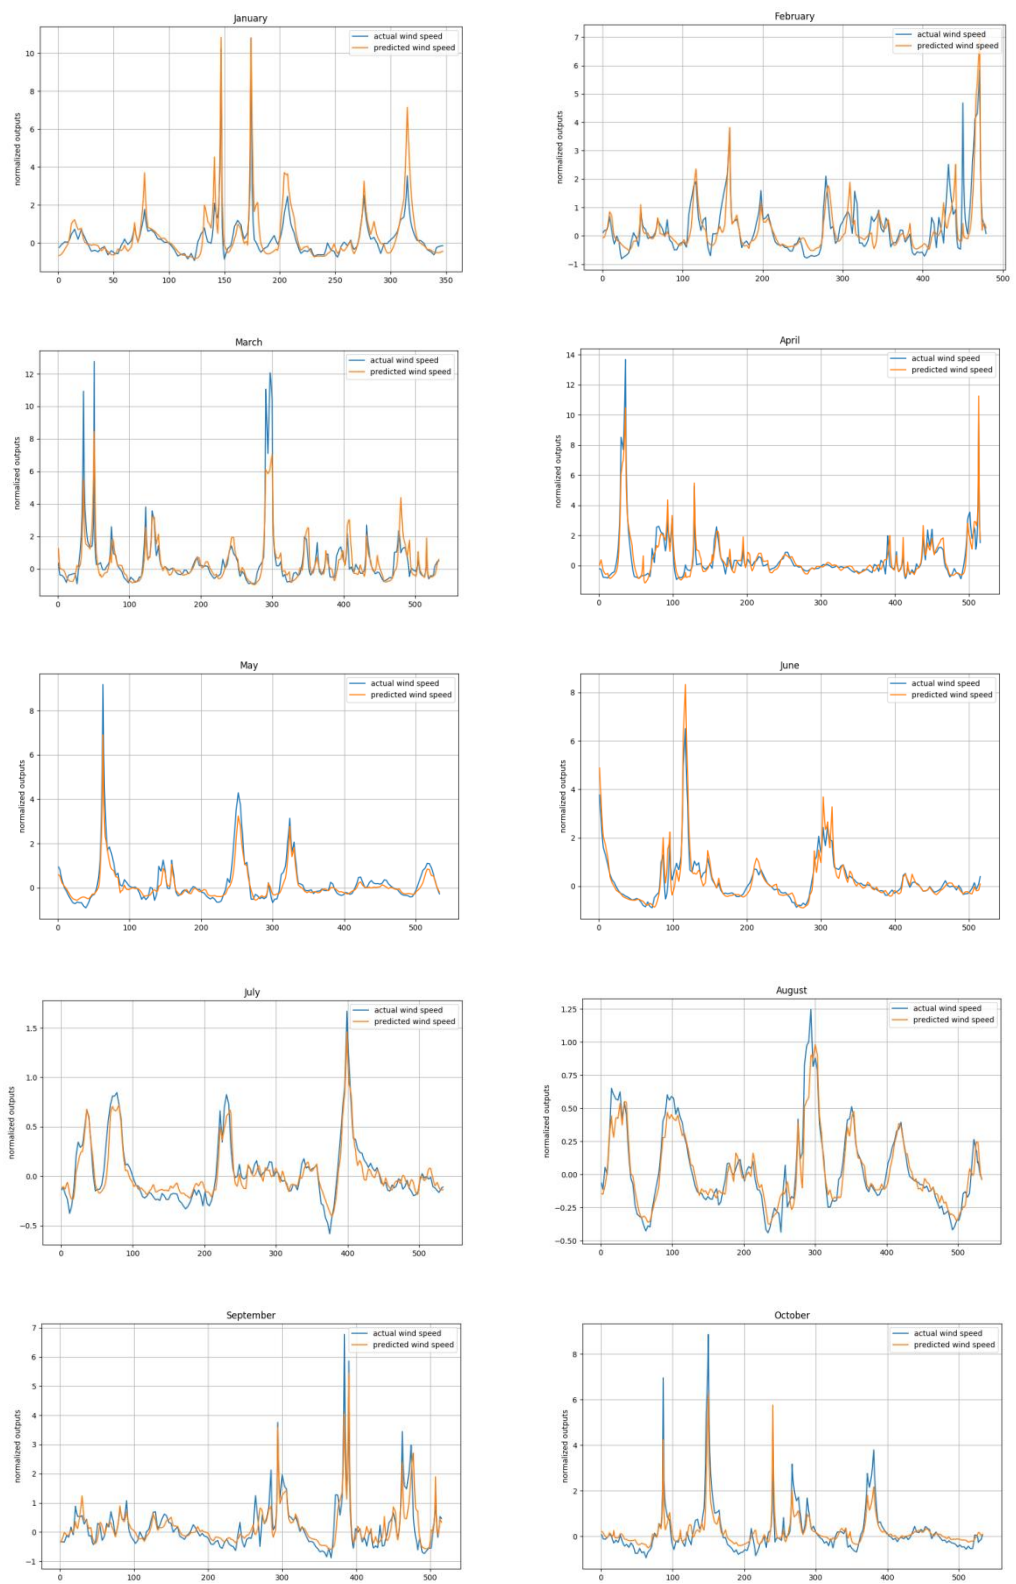




3) Αποτελέσματα Αναδρομικού Μοντέλου με ARMA σφάλματα









4) Αποτελέσματα Μοντέλου LSTM

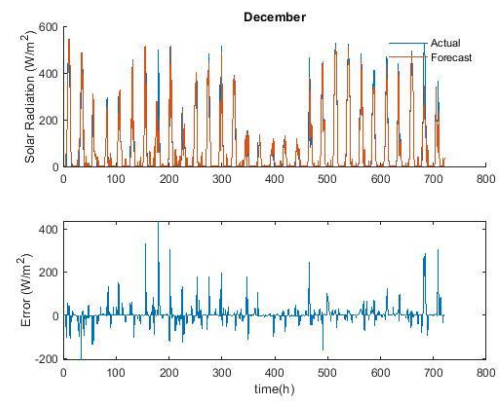

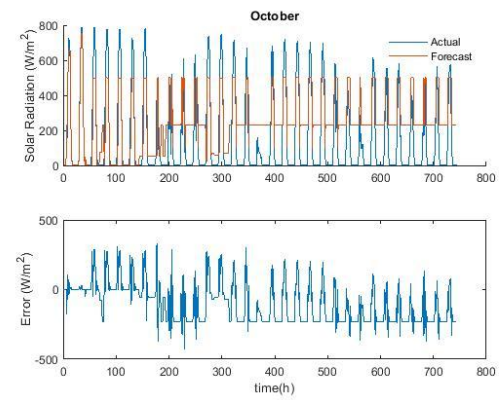
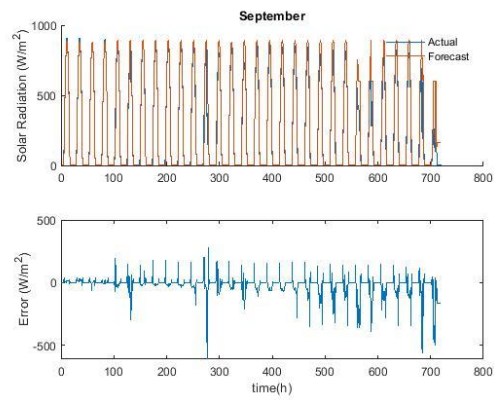

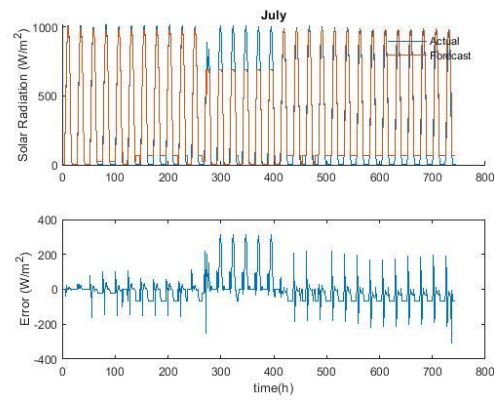

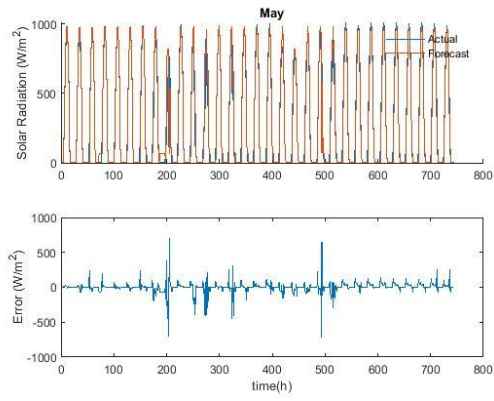




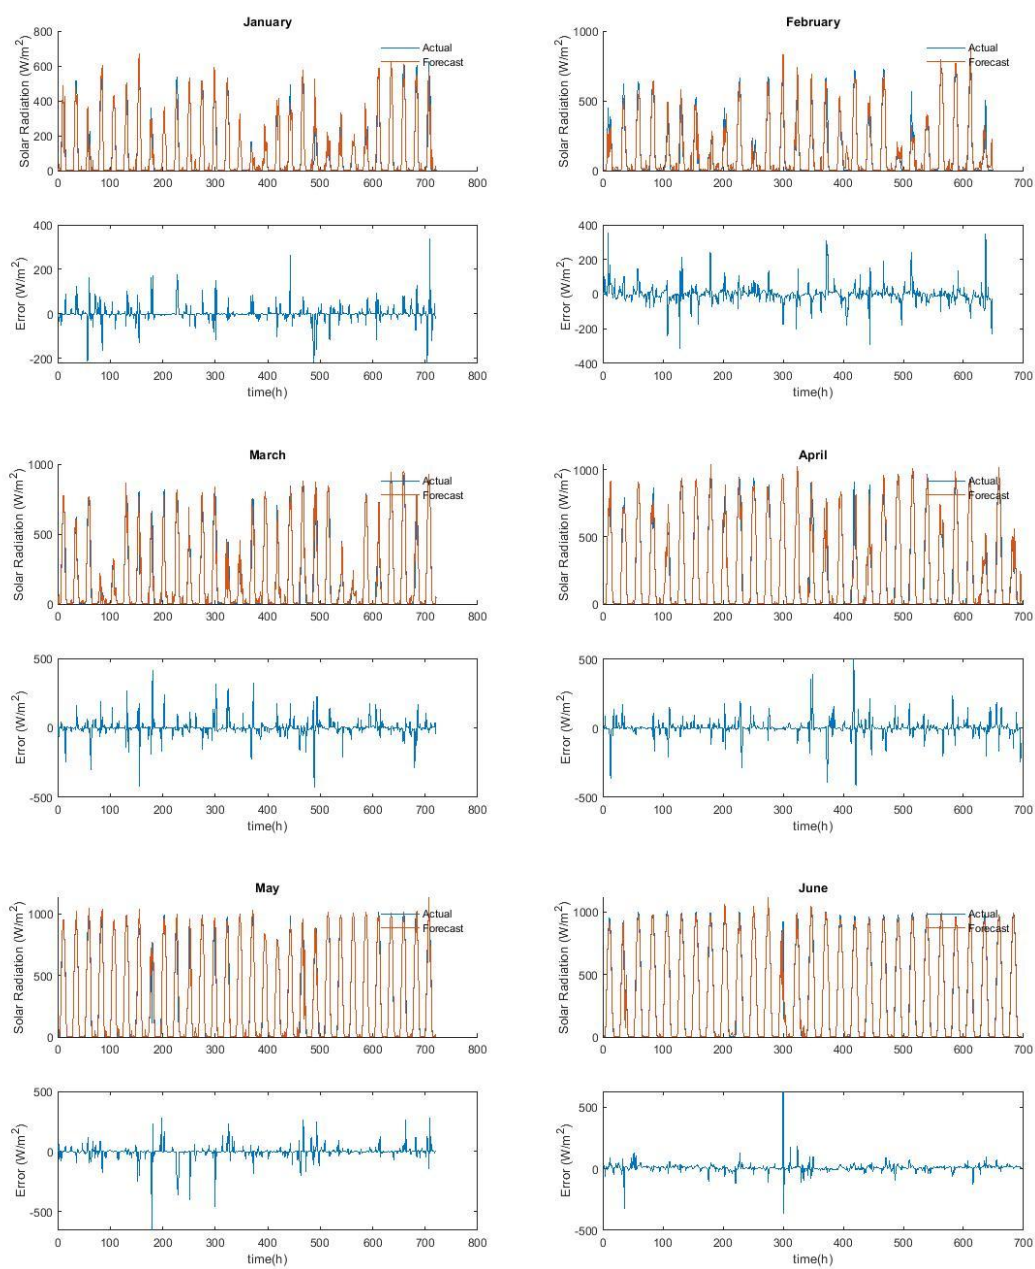
5.2: Αποτελέσματα μεσοπρόθεσμης πρόβλεψης ηλιακής ακτινοβολίας συγκεντρωτικά ανά μήνα

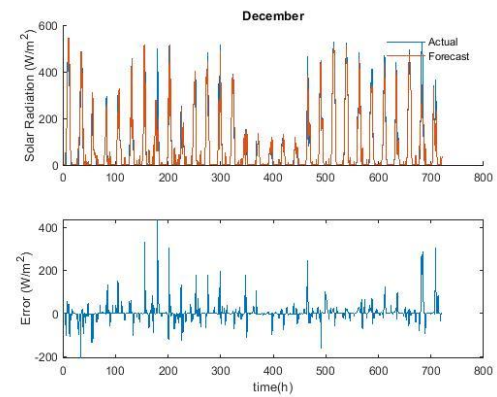





1) Αποτελέσματα Μοντέλου: Αναδρομικά Δέντρα Απόφασης



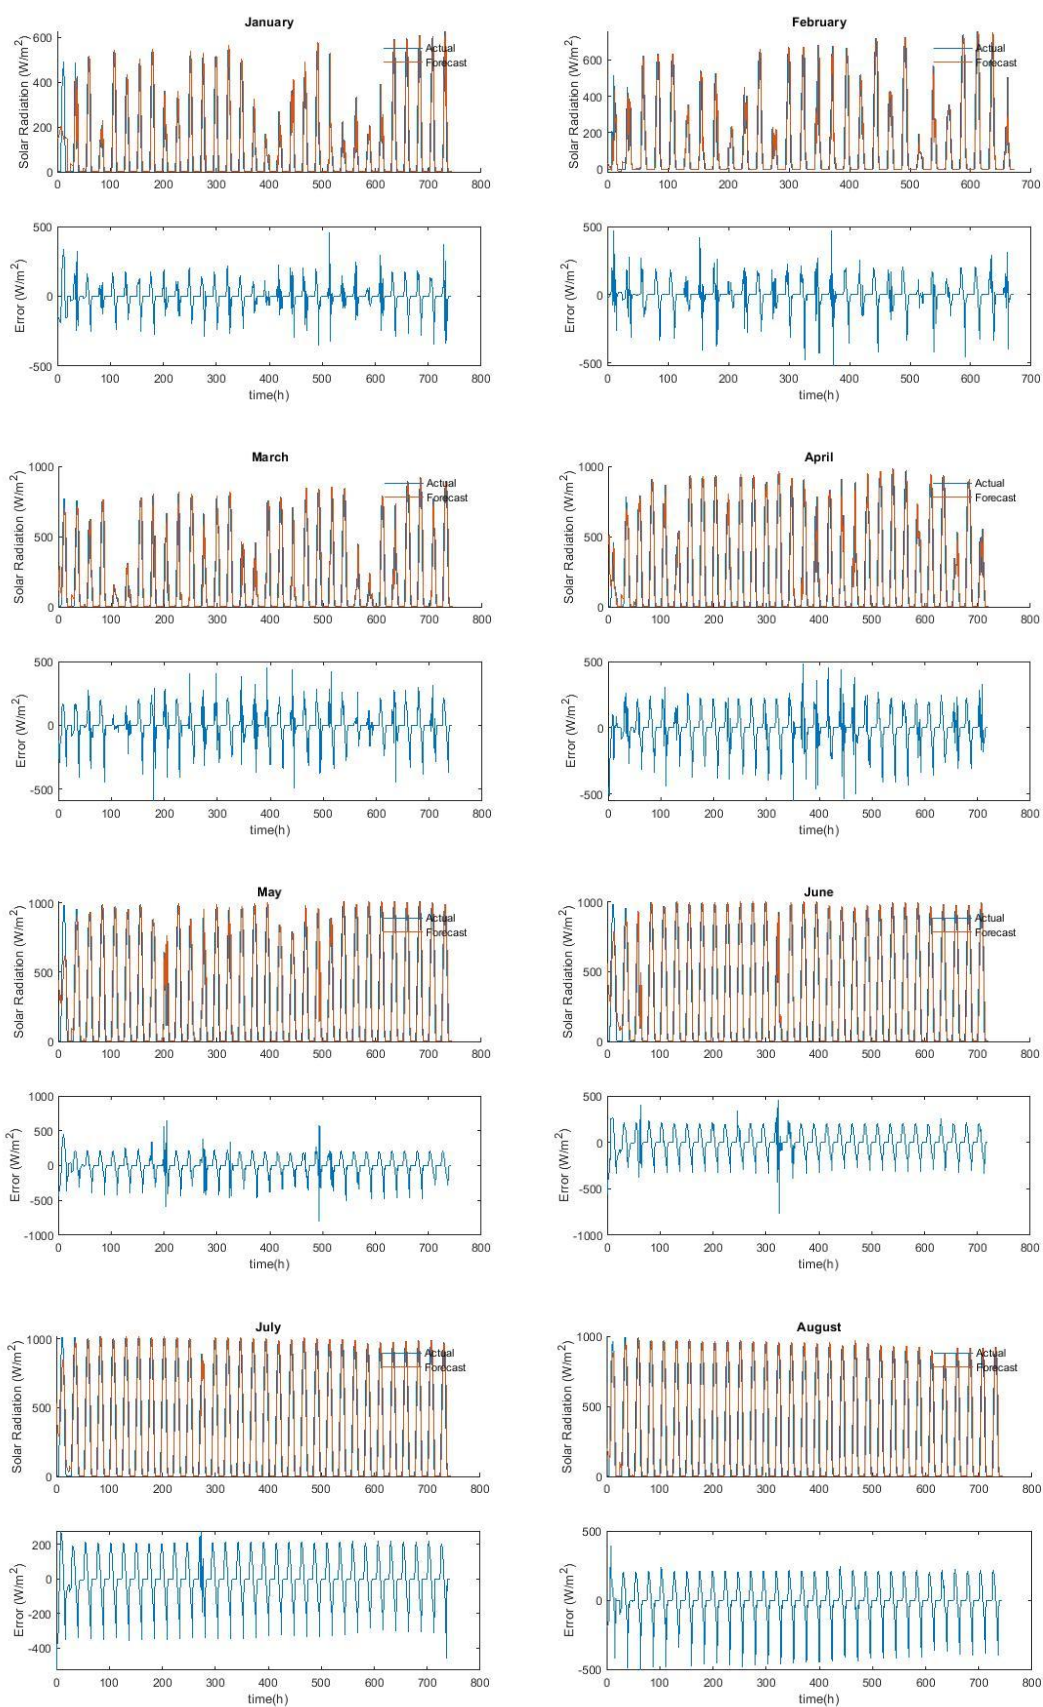


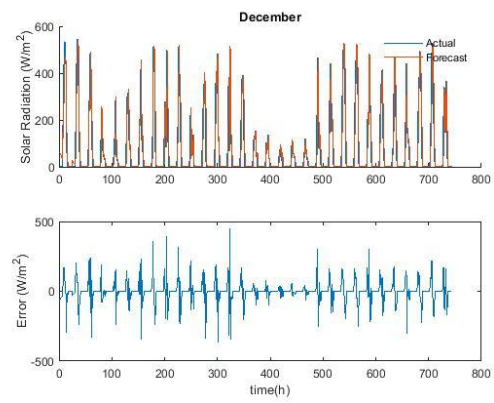
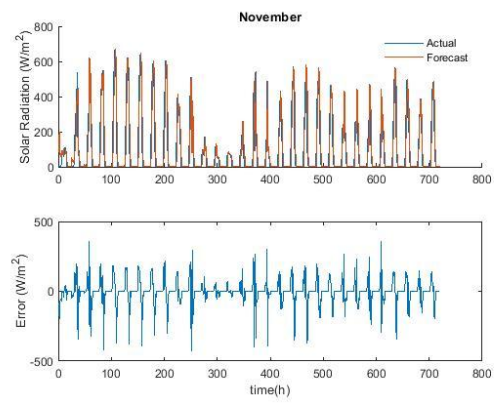
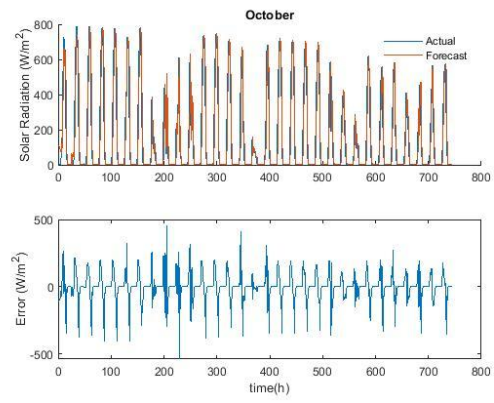
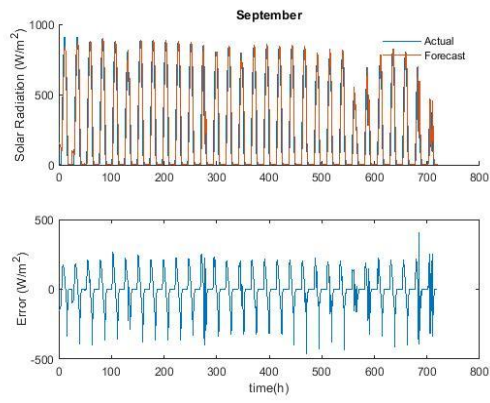
2) Αποτελέσματα Μοντέλου: Μη-γραμμικό αυτό-ρυθμιζόμενο εξωγενές μοντέλο (NARX)





3) Αποτελέσματα Αναδρομικού Μοντέλου με ARMA σφάλματα






Κεφάλαιο 6: Σύγκριση αποτελεσμάτων μεσοπρόθεσμης πρόβλεψης μεταξύ διαφορετικών μεθόδων πρόβλεψης






Όπως έχει ήδη προαναφερθεί, τα μοντέλα κάνουν πρόβλεψη με τη μέθοδο της **αναδρομικής πρόβλεψης πολλαπλών βημάτων (μέθοδος 2)**. Ωστόσο «δοκιμάστηκαν» ενδεικτικά τα μοντέλα NARX και Regarma με τη μέθοδο **πολλαπλής πρόβλεψης (μέθοδος 4)**. Όσο αφορά την μεσοπρόθεσμη πρόβλεψη της ταχύτητας του ανέμου, η μέθοδος πρόβλεψης 2, είχε περίπου 20% μικρότερο MAPE απ' τη μέθοδο 4. Στην περίπτωση της μεσοπρόθεσμης πρόβλεψης ηλιακής ακτινοβολίας, είχαμε μικρότερες διαφορές. Συγκεκριμένα η μέθοδος πρόβλεψης 2 είχε περίπου 5-7% μικρότερο MAPE σε σχέση με τη μέθοδο πρόβλεψης 4. Παρακάτω ακολουθούν αποτελέσματα μεταξύ των στρατηγικών 2 και 4, για κάποιες ημέρες του χρόνου, που επιλέχτηκαν τυχαία. Στον **άξονα x** απεικονίζονται οι **ώρες της εκάστοτε ημέρας** και στον **άξονα y** η **ταχύτητα ανέμου** ή η **ηλιακή ακτινοβολία**.



Πρόβλεψη ταχύτητας ανέμου

RegArma: Μέθοδος πρόβλεψης 2









RegArma: Μέθοδος πρόβλεψης 4







NARX: Μέθοδος πρόβλεψης 2




NARX: Μέθοδος πρόβλεψης 4










Πρόβλεψη ηλιακής ακτινοβολίας

RegArma: Μέθοδος πρόβλεψης 2









RegArma: Μέθοδος πρόβλεψης 4







NARX: Μέθοδος πρόβλεψης 2

NARX: Μέθοδος πρόβλεψης 4






Κεφάλαιο 7: Σύγκριση αποτελεσμάτων μεσοπρόθεσμης πρόβλεψης μεταξύ καταγεγραμμένων δεδομένων αστικού περιβάλλοντος & βραχονησίδας


Για να αναδεχθεί η σημασία των δεδομένων στη διαδικασία της εκπαίδευσης και κατ' επέκταση της πρόβλεψης των μοντέλων, χρησιμοποιήθηκαν δεδομένα αστικού περιβάλλοντος. Συγκριμένα χρησιμοποιήθηκαν καταγεγραμμένα δεδομένα από αισθητήρες που είχαν τοποθετηθεί στην περιοχή των Χανίων και συγκεκριμένα στην κατοικημένη περιοχή, Χαλέπα. Φυσικά, για να μπορεί να γίνει η σύγκριση μεταξύ των αποτελεσμάτων έχει ακολουθηθεί η ίδια διαδικασία σε όλα τα στάδια της εκπαίδευσης και της πρόβλεψης (βλ. κεφ 4.3 και 4.4) τόσο στα μοντέλα της ηλιακής ακτινοβολίας όσο και της ταχύτητας του ανέμου. Επιπλέον τα μοντέλα έχουν προφανώς τις ίδιες εισόδους. Τέλος τα δεδομένα που χρησιμοποιήθηκαν απ' την περιοχή της Χαλέπας των Χανίων αναφέρονται στις χρονιές 2007, 2008 και 2009 με το 2007&2008 να χρησιμοποιούνται για την εκπαίδευση των μοντέλων και το 2009 για την πρόβλεψη, όπως έγινε με τα δεδομένα απ' το ακατοίκητο νησί, Ντία. Παρακάτω παρατίθενται τα αποτελέσματα μεσοπρόθεσμης πρόβλεψης, ενδεικτικά από κάποια μοντέλα συγκεντρωμένα σε κοινή γραφική παράσταση για όλο το χρόνο.

Μεσοπρόθεσμη πρόβλεψη ταχύτητας ανέμου

Αποτελέσματα *Narx* με δεδομένα αστικού περιβάλλοντος (Χαλέπα)




Αποτελέσματα NARX με δεδομένα βραχονησίδας (Ντία)




Πίνακας 1: Αποτελέσματα σχέσεων μέτρησης σφάλματος, πρόβλεψης ταχύτητας ανέμου μοντέλου NARX, μεταξύ δεδομένων αστικού περιβάλλοντος και βραχονησίδας

	Mean Mape	Mean RMSE	Mean MSE	Mean R ²	Mean MAE
NARX Χαλέπα	0.3183	0.8935	0.7983	0.7401	0.623
NARX Ντία	0.092	0.55	0.389	0.9359	0.4072

Αποτελέσματα DNN-LSTM με δεδομένα αστικού περιβάλλοντος (Χαλέπα)



Αποτελέσματα DNN-LSTM με δεδομένα βραχονησίδας (Ντία)




Πίνακας 2: Αποτελέσματα σχέσεων μέτρησης σφάλματος, πρόβλεψης ταχύτητας ανέμου μοντέλου LSTM, μεταξύ δεδομένων αστικού περιβάλλοντος και βραχονησίδας


	Mean Mape	Mean RMSE	Mean MSE	Mean R^2	Mean MAE
LSTM Χαλέπα	0.412	0.9251	0.924	0.6201	0.36
LSTM Ντία	0.128	0.438	0.24	0.8	0.254

Μεσοπρόθεσμη πρόβλεψη ηλιακής ακτινοβολίας

Αποτελέσματα Naxos με δεδομένα αστικού περιβάλλοντος (Χαλέπα)



Αποτελέσματα NARX με δεδομένα βραχονησίδας (Ντία)



Πίνακας 3: Αποτελέσματα σχέσεων μέτρησης σφάλματος, πρόβλεψης ηλιακής ακτινοβολίας μοντέλου NARX, μεταξύ δεδομένων αστικού περιβάλλοντος και βραχονησίδας

	Mean SMape	Mean NRMSE	Mean NMSE	Mean R^2	Mean NMAE
NARX Χαλέπα	0.2593	0.8237	0.9689	0.9512	0.1112
NARX Ντία	0.2236	0.8078	0.9457	0.9523	0.093

Κεφάλαιο 8: Αξιολόγηση αποτελεσμάτων βάσει των σχέσεων μέτρησης σφάλματος

Η αξιολόγηση των αποτελεσμάτων της πρόβλεψης ταχύτητας ανέμου αλλά και ηλιακής ακτινοβολίας θα γίνει βάσει κάποιων σχέσεων, οι οποίες μετρούν την απόκλιση (σφάλμα) μεταξύ προβλεπόμενων και πραγματικών τιμών. Οι πιο γνωστές σχέσεις οι οποίες χρησιμοποιούνται κατά κύριο λόγο σε τέτοιου είδους προβλήματα πρόβλεψης είναι:

- Μέσο Τετραγωνικό Σφάλμα (MSE)
- Τετραγωνική Ρίζα του Μέσου Τετραγωνικού Σφάλματος (RMSE)
- Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (MAPE)
- Μέσο Απόλυτο Σφάλμα (MAE)
- Συντελεστής R^2
- Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (SMAPE)
- Κανονικοποιημένη Τετραγωνική Ρίζα του Μέσου Τετραγωνικού Σφάλματος (NRMSE)
- Κανονικοποιημένο Μέσο Τετραγωνικό Σφάλμα (NMSE)
- Κανονικοποιημένο Μέσο Απόλυτο Σφάλμα (NMAE)

Μέσο Απόλυτο Σφάλμα (MAE)

Το μέσο απόλυτο σφάλμα (MAE) είναι η πιο απλή μέτρηση σφάλματος πρόβλεψης. Υπολογίζεται σημείο προς σημείο η απολυτή τιμή της διαφοράς των δεδομένων και μετά εξάγεται η μέση τιμή της προηγούμενης ποσότητας. Σε γενικές γραμμές το MAE περιγράφει το μέγεθος των αποκλίσεων. Η μαθηματική σχέση που περιγράφει το μέσο απόλυτο σφάλμα είναι:

$$MAE = \frac{1}{n} \sum \left| y - \hat{y} \right|$$

Divide by the total number of data points
Predicted output value
Actual output value
Sum of
The absolute value of the residual

Το MAE είναι μια πιο γενική προσέγγιση του σφάλματος, καθώς απλώς εξετάζεται η απόλυτη διαφορά μεταξύ των πραγματικών τιμών και των προβλέψεων του μοντέλου. Επειδή χρησιμοποιείται η απόλυτη τιμή της διαφοράς, το MAE δεν υποδηλώνει υποαπόδοση ή υπεραπόδοση του μοντέλου (ανεξάρτητα από το αν το μοντέλο είναι κάτω ή υπερβαίνει τα πραγματικά δεδομένα). Κάθε υπολειπόμενο μέρος συμβάλλει αναλογικά στο συνολικό ποσό σφάλματος, πράγμα που σημαίνει ότι μεγαλύτερα σφάλματα θα συνεισφέρουν γραμμικά στο συνολικό σφάλμα. Όπως αναφέρθηκε παραπάνω, ένα μικρό MAE υποδηλώνει ότι το μοντέλο

είναι εξαιρετικό στην πρόβλεψη, ενώ ένα μεγάλο MAE υποδηλώνει ότι το μοντέλο μπορεί να έχει πρόβλημα σε ορισμένες περιοχές. Το $MAE=0$ σημαίνει ότι το μοντέλο κάνει την τέλεια πρόβλεψη κάποιας μεταβλητής (αλλά αυτό δύσκολα συμβαίνει στην πραγματικότητα).

Μέσο Τετραγωνικό Σφάλμα (MSE)

Το μέσο τετραγωνικό σφάλμα (MSE) είναι ακριβώς όπως το MAE, αλλά τετραγωνίζει τη διαφορά πριν τα αθροίσει όλα, αντί να χρησιμοποιήσει την απόλυτη τιμή. Μπορούμε να δούμε αυτήν τη διαφορά στην παρακάτω εξίσωση.

$$MSE = \frac{1}{n} \sum \left(\underbrace{y - \hat{y}}_{\substack{\text{The square of the difference} \\ \text{between actual and} \\ \text{predicted}}} \right)^2$$

Επειδή τετραγωνίζονται οι διαφορές, το MSE θα είναι σχεδόν πάντα μεγαλύτερο από το MAE. Για το λόγο αυτό, δεν μπορεί να συγκριθεί άμεσα το MAE με το MSE. Μπορούν να συγκριθούν μόνο οι μετρήσεις σφάλματος του μοντέλου με εκείνες ενός ανταγωνιστικού μοντέλου. Η επίδραση του τετραγωνικού όρου στην εξίσωση MSE είναι πιο εμφανής με την παρουσία πολύ υψηλών τιμών στα δεδομένα μας. Ενώ κάθε υπόλοιπο στο MAE συμβάλλει αναλογικά στο συνολικό σφάλμα, το σφάλμα στο MSE αυξάνεται τετραγωνικά. Αυτό τελικά σημαίνει ότι οι ακραίες τιμές στα δεδομένα, θα συμβάλουν σε πολύ υψηλότερο συνολικό σφάλμα στο MSE απ' ότι στο MAE. Οπότε το μοντέλο θα επιβαρυνθεί περισσότερο με την πραγματοποίηση προβλέψεων που διαφέρουν πολύ από την αντίστοιχη πραγματική τιμή. Αυτό σημαίνει ότι οι μεγάλες διαφορές μεταξύ πραγματικών και προβλεπόμενων «τιμωρούνται» περισσότερο στο MSE παρά στο MAE.

Τετραγωνική Ρίζα του Μέσου Τετραγωνικού Σφάλματος (RMSE)

Όπως υποδηλώνει το όνομα, είναι η τετραγωνική ρίζα του MSE ($RMSE = \sqrt{MSE}$). Επειδή το MSE είναι υψωμένο στο τετράγωνο, οι μονάδες του δεν ταιριάζουν με εκείνες της αρχικής εξόδου. Δεδομένου ότι στο MSE και στο RMSE τα αποτελέσματα των διαφορών (residuals) υψώνονται στο τετράγωνο, επηρεάζονται ομοίως και οι ακραίες τιμές. Το RMSE είναι ανάλογο με την τυπική απόκλιση (MSE to variance) και δείχνει την κατανομή των αποτελεσμάτων των διαφορών.

Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (MAPE)

Η εξίσωση του MAPE μοιάζει με αυτή του MAE, αλλά με τη βασική διαφορά ότι μετατρέπει τα πάντα σε ποσοστά. Ακριβώς όπως το MAE δείχνει το μέσο μέγεθος του σφάλματος το οποίο παράγεται από το μοντέλο, το MAPE δηλώνει πόσο μακριά είναι οι προβλέψεις του μοντέλου από τις πραγματικές εξόδους κατά μέσο όρο. Τόσο το MAPE όσο και το MAE είναι ανθεκτικά στα αποτελέσματα των

ακραίων τιμών (outliers) χάρη στην ύπαρξη της απόλυτης τιμής στον τύπο τους. Η εξίσωση του MAPE φαίνεται παρακάτω:

$$MAPE = \frac{100\%}{n} \sum \left| \frac{\widehat{y - y}}{y} \right|$$

Multiplying by 100% converts to percentage
The residual
Each residual is scaled against the actual value

Απ' την παραπάνω σχέση είναι φανερό το γεγονός ότι προκύπτουν κάποια προβλήματα στον υπολογισμό του.

- Δεν μπορεί να χρησιμοποιηθεί αν υπάρχουν μηδενικές τιμές (κάτι που συμβαίνει για παράδειγμα σε δεδομένα όπως στην πρόβλεψη ηλιακής ακτινοβολίας) επειδή θα υπάρχει διαίρεση με μηδέν.
- Για προβλέψεις που είναι πολύ χαμηλές, το ποσοστό σφάλματος δεν μπορεί να υπερβαίνει το 100%, αλλά για προβλέψεις που είναι πολύ υψηλές δεν υπάρχει ανώτερο όριο στο ποσοστό σφάλματος.
- Τέλος, το MAPE είναι μεροληπτικό ως προς τις προβλέψεις που είναι συστηματικά μικρότερες από τις αντίστοιχες πραγματικές τιμές. Δηλαδή, το MAPE θα είναι χαμηλότερο όταν η πρόβλεψη είναι χαμηλότερη από την πραγματική τιμή (υποεκτίμηση), σε σύγκριση με μια πρόβλεψη που είναι υψηλότερη κατά το ίδιο ποσό (υπερεκτίμηση). Άρα το MAPE επιβάλλει μεγαλύτερη ποινή σε αρνητικά σφάλματα απ' ότι σε θετικά.

Στην εικόνα που ακολουθεί φαίνονται τα συμπεράσματα των τεσσάρων σχέσεων που αναλύθηκαν παραπάνω. [\[9\]](#)

Acronym	Full Name	Residual Operation?	Robust To Outliers?
MAE	Mean Absolute Error	Absolute Value	Yes
MSE	Mean Squared Error	Square	No
RMSE	Root Mean Squared Error	Square	No
MAPE	Mean Absolute Percentage Error	Absolute Value	Yes

Εικόνα 39: Συμπεράσματα εξισώσεων μέτρησης σφάλματος

Για να ξεπεραστούν αυτά τα ζητήματα με το MAPE, υπάρχουν κάποια μέτρα που προτείνονται στη βιβλιογραφία όπως το Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (SMAPE). Ο τύπος του SMAPE δίνεται από τη σχέση:

$$SMAPE = \frac{100\%}{n} \sum_{t=1}^n \frac{|F_t - A_t|}{(|A_t| + |F_t|)/2}$$

Όπου A_t είναι η πραγματική τιμή και το F_t είναι η τιμή πρόβλεψης

Σε αντίθεση με το μέσο απόλυτο ποσοστιαίο σφάλμα, το SMAPE έχει τόσο κατώτερο όσο και ανώτερο όριο. Ο παραπάνω τύπος παρέχει ένα αποτέλεσμα μεταξύ 0% και 200%. Ωστόσο, ένα ποσοστό σφάλματος μεταξύ 0% και 100% είναι πολύ πιο εύκολο να ερμηνευθεί. Αυτός είναι ο λόγος για τον οποίο ο παρακάτω τύπος χρησιμοποιείται συχνά στην πράξη (χωρίς τον παράγοντα 0,5 στον παρονομαστή): [\[37\]](#)

$$\text{SMAPE} = \frac{100\%}{n} \sum_{t=1}^n \frac{|F_t - A_t|}{|A_t| + |F_t|}$$

Επιπλέον σε προβλέψεις όπως αυτή της ηλιακής ακτινοβολίας όπου υπάρχει μια αυξημένη διακύμανση στα σφάλματα ο υπολογισμός των RMSE, MSE και MAE δεν είναι ενδεδειγμένος. Για παράδειγμα η λήψη της τετραγωνικής ρίζας των μέσων τετραγωνικών σφαλμάτων έχει κάποιες επιπτώσεις για το RMSE. Αυτό το πρόβλημα είναι φανερό και στον παρακάτω πίνακα που υπολογίζεται το RMSE για παραδείγματα αυξανόμενης διακύμανσης σφάλματος. Για το λόγο αυτό σε τέτοιου είδους περιπτώσεις υπολογίζουμε και αξιολογούμε τα αποτελέσματα βάσει των NRMSE, NMSE, NMAE και SMAPE.

Πίνακας 4: Παραδείγματα υπολογισμού RMSE

Ομοιόμορφα κατανεμημένο Σφάλμα				Σφάλμα με μικρή διακύμανση				Σφάλμα με μεγάλη διακύμανση			
ID	Error	Error	Error ²	ID	Error	Error	Error ²	ID	Error	Error	Error ²
1	2	2	4	1	1	1	1	1	0	0	0
2	2	2	4	2	1	1	1	2	0	0	0
3	2	2	4	3	1	1	1	3	0	0	0
4	2	2	4	4	1	1	1	4	0	0	0
5	2	2	4	5	1	1	1	5	0	0	0
6	2	2	4	6	3	3	9	6	0	0	0
7	2	2	4	7	3	3	9	7	0	0	0
8	2	2	4	8	3	3	9	8	0	0	0
9	2	2	4	9	3	3	9	9	0	0	0
10	2	2	4	10	3	3	9	10	20	20	400
RMSE=2.00				RMSE=2.236				RMSE=6.325			

Κανονικοποιημένη Τετραγωνική Ρίζα του Μέσου Τετραγωνικού Σφάλματος (NRMSE)

Η κανονικοποίηση του RMSE διευκολύνει τη σύγκριση μεταξύ συνόλων δεδομένων ή μοντέλων με διαφορετικές κλίμακες. Αν και δεν υπάρχει συγκεκριμένος τρόπος ομαλοποίησης στη βιβλιογραφία, το NRMSE στην περίπτωση μας έχει υπολογιστεί απ' τον τύπο:

$$\text{NRMSE} = 1 - \frac{\|y - y_{\text{pred}}\|}{\|y - \text{mean}(y)\|}$$

Κανονικοποιημένο Μέσο Τετραγωνικό Σφάλμα (NMSE) και Κανονικοποιημένο Μέσο Απόλυτο Σφάλμα (NMAE)

Οι τύποι που χρησιμοποιήθηκαν για τον υπολογισμό του NMSE και του NMAE είναι οι εξής:

$$NMSE = \frac{\sum_{i=1}^{N_{test}} (\hat{y}_i - y_i)^2}{\sum_{i=1}^{N_{test}} (\bar{y} - y_i)^2} \quad NMAE = \frac{\sum_{i=1}^{N_{test}} |\hat{y}_i - y_i|}{\sum_{i=1}^{N_{test}} |\bar{y} - y_i|}$$

Συντελεστής R^2

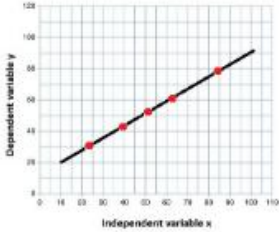
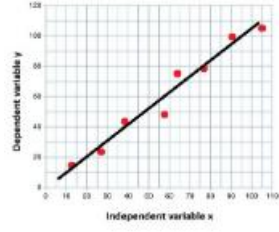
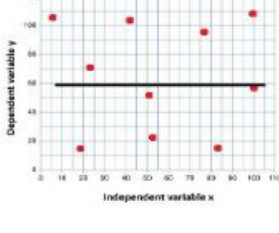
Το R^2 είναι ένα στατιστικό μέτρο το οποίο δείχνει πόσο κοντά είναι τα δεδομένα στην προσαρμοσμένη γραμμή παλινδρόμησης. Συγκεκριμένα δείχνει το κατά πόσο οι ανεξάρτητες μεταβλητές στο σύνολο τους, μπορούν να εξηγήσουν το ποσοστό της διακύμανσης που εμφανίζει η εξαρτημένη μεταβλητή. Σε αντίθεση με τις σχέσεις MSE, RMSE, MAPE και MAE οι οποίες όσο πιο κοντά βρίσκονται στο μηδέν τόσο μεγαλύτερη ακρίβεια πρόβλεψης εμφανίζει το μοντέλο, ο συντελεστής R^2 μπορεί να ισούται στην καλύτερη περίπτωση με 1 (100%). Συγκεκριμένα:

- Για $R^2 = 0\%$ δηλώνει ότι το μοντέλο δεν εξηγεί καμία από τις μεταβλητές των δεδομένων απόκρισης γύρω από το μέσο όρο του.
- Για $R^2 = 100\%$ δηλώνει ότι το μοντέλο εξηγεί όλη τη διακύμανση της μεταβλητής απόκρισης γύρω από τη μέση τιμή της. [\[36\]](#)

Ο τύπος με τον οποίο υπολογίζουμε τον παραπάνω συντελεστή είναι

$$\begin{aligned} R^2 &= 1 - \frac{\text{sum squared regression (SSR)}}{\text{total sum of squares (SST)}} \\ &= 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}. \end{aligned}$$

Ακολουθεί ένα παράδειγμα που συνοψίζει τα παραπάνω.

Τιμές R^2	Ερμηνεία	Γραφική αναπαράσταση
$R^2=1$	Όλες οι μεταβολές στις τιμές y υπολογίζονται από τις τιμές x	
$R^2=0.85$	Το 85% της διακύμανσης στις τιμές y υπολογίζεται από τις τιμές x	
$R^2=0$	Καμία απ' τις μεταβολές στις τιμές y δεν υπολογίζεται από τις τιμές x	

Κεφάλαιο 9: Παράθεση αποτελεσμάτων των σχέσεων μέτρησης σφάλματος

Ακολουθεί η παρουσίαση των αποτελεσμάτων των σχέσεων μέτρησης σφάλματος, όπως αυτά προέκυψαν μετά την εφαρμογή των μοντέλων μεσοπρόθεσμης πρόβλεψης ταχύτητας ανέμου και ηλιακής ακτινοβολίας. Αξίζει να σημειωθεί ότι στον υπολογισμό του SMAPE για την ηλιακή ακτινοβολία χρειάστηκε να αντικατασταθούν οι μηδενικές τιμές ενδεικτικά με 0.01, προκειμένου να μην υπήρχε διαίρεση με μηδέν στον τύπο. Ουσιαστικά μηδενικές τιμές (0 W/m^2) ηλιακής ακτινοβολίας καταγράφονται μόνο τις νυχτερινές ώρες. Η αντικατάσταση αυτών των τιμών για τον υπολογισμό καθαρά του SMAPE, δεν επηρεάζει κάποιο αποτέλεσμα.

9.1: Αποτελέσματα Πρόβλεψης Ταχύτητας Ανέμου

Πίνακας 5: Αποτελέσματα σχέσεων μέτρησης σφάλματος – Πρόβλεψη Ταχύτητας Ανέμου
Χρυσό: BDT, Κόκκινο: NARX, Μπλε: RegARMA, Μαύρο: LSTM

ΜΗΝΑΣ	MAPE	RMSE	MSE	R ²	MAE
ΙΑΝΟΥΑΡΙΟΣ	0.257 0.1399 0.0928 0.1603	0.961 0.7424 0.4689 0.3659	0.9236 0.5512 0.2199 0.1339	0.8763 0.9313 0.9722 0.8653	0.6991 0.5762 0.359 0.2667
ΦΕΒΡΟΥΑΡΙΟΣ	0.1025 0.1139 0.0819 0.182	0.6529 0.6965 0.4898 0.499	0.4262 0.4852 0.2399 0.2501	0.9472 0.9391 0.9703 0.6939	0.4521 0.5253 0.366 0.3253
ΜΑΡΤΙΟΣ	0.1894 0.1538 0.1255 0.2101	0.6402 0.6569 0.5754 0.869	0.4099 0.4315 0.331 0.7561	0.907 0.9043 0.9249 0.702	0.4913 0.5138 0.4309 0.4637
ΑΠΡΙΛΙΟΣ	0.1661 0.2123 0.1055 0.172	0.6557 1.093 0.5334 0.4993	0.4299 1.1946 0.2845 0.2493	0.9167 0.761 0.9449 0.8706	0.4823 0.8375 0.3763 0.3353
ΜΑΪΟΣ	0.1121 0.0588 0.0547 0.1272	1.0465 0.4917 0.2868 0.3428	1.0951 0.2418 0.0823 0.1175	0.7393 0.9436 0.9804 0.7858	0.6239 0.362 0.2122 0.2185
ΙΟΥΝΙΟΣ	0.2025 0.1345 0.0574 0.052	2.1205 0.7794 0.2907 0.335	4.4953 0.6075 0.0845 0.1122	0.3345 0.9123 0.9875 0.9101	1.4422 0.609 0.2332 0.2036

ΙΟΥΛΙΟΣ	0.0491 0.01 0.0218 0.084	0.7253 0.1539 0.2093 0.1	0.526 0.0237 0.0438 0.01	0.8859 0.9949 0.9905 0.8639	0.3723 0.0938 0.1611 0.078
ΑΥΓΟΥΣΤΟΣ	0.1952 0.026 0.0229 0.091	1.5574 0.3562 0.1975 0.098	2.4254 0.1269 0.039 0.0097	0.3532 0.9655 0.9896 0.8643	1.0623 0.2534 0.1549 0.071
ΣΕΠΤΕΜΒΡΙΟΣ	0.1147 0.0398 0.1032 0.1133	0.5446 0.2309 0.4043 0.4014	0.2965 0.0533 0.1634 0.1611	0.8935 0.9798 0.9413 0.6849	0.345 0.1285 0.2777 0.2578
ΟΚΤΩΒΡΙΟΣ	0.2278 0.0461 0.1109 0.1302	1.2167 0.2819 0.4094 0.473	1.4805 0.0794 0.1676 0.2238	0.6815 0.9834 0.9639 0.701	0.7723 0.1514 0.2915 0.3
ΝΟΕΜΒΡΙΟΣ	0.326 0.0475 0.0886 0.087	0.9524 0.2158 0.3053 0.5226	0.907 0.0466 0.0932 0.2731	0.8613 0.993 0.9858 0.8015	0.6215 0.1308 0.2343 0.2171
ΔΕΚΕΜΒΡΙΟΣ	0.3567 0.13 0.0492 0.122	1.7111 0.9065 0.3286 0.7578	2.9278 0.8217 0.108 0.5743	0.7203 0.9235 0.9897 0.7607	1.179 0.7043 0.2046 0.3189

Πίνακας 6: Μέσες Τιμές Αποτελεσμάτων σχέσεων μέτρησης σφάλματος – Πρόβλεψη Ταχύτητας Ανέμου – Χρυσό: BDT, Κόκκινο: NARX, Μπλε: RegARMA, Μαύρο: LSTM

MEAN MAPE	MEAN RMSE	MEAN MSE	MEAN R ²	MEAN MAE
0.19159 0.09272 0.0762 0.12759	1.05045 0.550425 0.37495 0.43865	1.809557 0.3886167 0.1547583 0.2392583	0.759725 0.935975 0.9700833 0.792025	0.711942 0.407167 0.275142 0.254658

9.2: Αποτελέσματα Πρόβλεψης Ηλιακής Ακτινοβολίας

Πίνακας 7: Αποτελέσματα σχέσεων μέτρησης σφάλματος – Πρόβλεψη Ηλιακής Ακτινοβολίας – Χρυσό: BDT, Κόκκινο: NARX, Μπλε: RegARMA

MONTH	SMAPE	NRMSE	NMSE	R ²	NMAE
ΙΑΝΟΥΑΡΙΟΣ	0.475 0.2404 0.2161	0.543 0.7697 0.4705	0.791 0.927 0.7197	0.7809 0.942 0.721	0.363 0.101 0.3664
ΦΕΒΡΟΥΑΡΙΟΣ	0.505 0.342 0.2107	0.316 0.732 0.4809	0.5321 0.906 0.731	0.551 0.923 0.737	0.549 0.161 0.3464
ΜΑΡΤΙΟΣ	0.563 0.3012 0.2228	0.58 0.771 0.5544	0.823 0.924 0.8015	0.8231 0.9438 0.8015	0.3 0.1093 0.3022
ΑΠΡΙΛΙΟΣ	0.2408 0.1922 0.2274	0.3267 0.801 0.5775	0.5467 0.942 0.8207	0.566 0.9595 0.8215	0.4425 0.0788 0.2955
ΜΑΪΟΣ	0.1187 0.1751 0.2077	0.765 0.819 0.5948	0.945 0.964 0.8358	0.945 0.9729 0.83	0.1069 0.0565 0.2742
ΙΟΥΝΙΟΣ	0.2984 0.1134 0.2287	0.5266 0.8977 0.6444	0.7759 0.963 0.8735	0.7756 0.988 0.88	0.3051 0.0427 0.2596
ΙΟΥΛΙΟΣ	0.344 0.1249 0.2269	0.802 0.9246 0.666	0.9608 0.9969 0.8884	0.977 0.9967 0.88	0.1311 0.02 0.2441
ΑΥΓΟΥΣΤΟΣ	0.4799 0.136 0.2137	0.5357 0.9631 0.6411	0.7845 0.99 0.8712	0.79 0.9991 0.8721	0.3789 0.011 0.2365
ΣΕΠΤΕΜΒΡΙΟΣ	0.125 0.2453 0.1991	0.7173 0.8602 0.613	0.92 0.98 0.8498	0.944 0.967 0.8501	0.1481 0.0681 0.2624
ΟΚΤΩΒΡΙΟΣ	0.5855 0.2507 0.2122	0.2127 0.7655 0.5475	0.3802 0.945 0.7953	0.3901 0.938 0.7953	0.8178 0.1323 0.3064

ΝΟΕΜΒΡΙΟΣ	0.5763 0.355 0.19	0.46 0.728 0.4553	0.7084 0.9263 0.7033	0.7083 0.9176 0.7133	0.4207 0.1821 0.3605
ΔΕΚΕΜΒΡΙΟΣ	0.696 0.2068 0.1912	0.2902 0.6616 0.4184	0.496 0.885 0.6618	0.4956 0.8801 0.66	0.8493 0.1561 0.3861

Πίνακας 8: Μέσες Τιμές Αποτελεσμάτων σχέσεων μέτρησης σφάλματος – Πρόβλεψη
Ηλιακής Ακτινοβολίας – Χρυσό: BDT, Κόκκινο: NARX, Μπλε: RegARMA

MEAN SMAPE	MEAN NRMSE	MEAN NMSE	MEAN R ²	MEAN NMAE
0.4173 0.223583 0.2122	0.5063 0.8078 0.555	0.722 0.9458 0.796	0.7289 0.9523 0.7968	0.40103 0.093 0.3033

Κεφάλαιο 10: Παρατηρήσεις & Συμπεράσματα

Μεσοπρόθεσμη πρόβλεψη ταχύτητας ανέμου

Ακρίβεια πρόβλεψης των μοντέλων: Όσο αφορά την ακρίβεια πρόβλεψης η βιβλιογραφία ορίζει τις εξής κατηγορίες βάσει του Μέσου Απόλυτου Ποσοστιαίου Σφάλματος (MAPE). Για $MAPE < 10\%$ θεωρείται υψηλή ακρίβεια πρόβλεψης. Για $10\% \leq MAPE < 20\%$ έχουμε καλή ακρίβεια πρόβλεψης. Για $20\% \leq MAPE \leq 50\%$ έχουμε αξιόπιστη πρόβλεψη. Για $MAPE > 50\%$ έχουμε κακή ακρίβεια πρόβλεψης. Συνεπώς τα μοντέλα NARX και RegArma βάσει των αποτελεσμάτων τους, έχουν υψηλή ακρίβεια πρόβλεψης. Το DNN-LSTM έχει καλή ακρίβεια πρόβλεψης πλησιάζοντας την υψηλή και το μοντέλο BDT βρίσκεται οριακά στην κατηγορία της καλής πρόβλεψης.

Χρόνος εκπαίδευσης: Σχετικά με το χρόνο της εκπαίδευσης και κατ' επέκταση την εξαγωγή των προβλέψεων, τα μοντέλα NARX και LSTM είχαν πιο σύντομους χρόνους εκτέλεσης, με το δεύτερο να είναι οριακά πιο γρήγορο. Αντίθετα, τα μοντέλα RegArma και BDT είχαν μεγαλύτερες καθυστερήσεις, με το BDT να είναι το πιο αργό μοντέλο, όσο αφορά το χρόνο που χρειάστηκε για την εκπαίδευση και την εξαγωγή αποτελεσμάτων.

Μέθοδος πρόβλεψης 2 και 4: Μέσα απ' τη σύγκριση των αποτελεσμάτων μεταξύ των δυο στρατηγικών πρόβλεψης, συμπεραίνουμε ότι στην περίπτωση μας βάσει των συνόλων δεδομένων που διαθέτουμε, η μέθοδος πρόβλεψης 2 είναι καλύτερη, καθώς έχει περίπου 20% μικρότερο mape σε σχέση με τη μέθοδο 4. Σύμφωνα με αυτό επιβεβαιώνεται και η βιβλιογραφία, που θέλει τη μέθοδο 4 να ενδείκνυται σε περιπτώσεις που τα σύνολα δεδομένων είναι περισσότερα.

Χρήση δεδομένων αστικού περιβάλλοντος και βραχονησίδας: Όπως ήταν αναμενόμενο, τα δεδομένα που ήταν καταγεγραμμένα απ' τη Χαλέπα (Κατοικημένη περιοχή) και χρησιμοποιήθηκαν στα μοντέλα, οδήγησαν σε μεγαλύτερα σφάλματα πρόβλεψης σε σχέση με τα δεδομένα της Ντία (Ακατοίκητη βραχονησίδα). Αυτό σχετίζεται με κάποιους παράγοντες που επηρεάζουν τον άνεμο. Συγκεκριμένα η τραχύτητα του εδάφους, τα ενδεχόμενα εμπόδια στη ροή του ανέμου (π.χ. κτήρια) και το υψόμετρο είναι απ' τους βασικούς παράγοντες που επηρεάζουν τη χρονοσειρά του ανέμου. Όλα αυτά λαμβάνονται προφανώς υπ' όψιν στην περίπτωση της Χαλέπας και όπως είναι προφανές αντικατοπτρίζεται στο αποτέλεσμα, όπως είδαμε στο κεφάλαιο 7. Από την άλλη πλευρά τα δεδομένα απ' τη βραχονησίδα (Ντία), που δεν επηρεάζονται σε μεγάλο βαθμό απ' αυτούς τους παράγοντες, «οδηγούν» τα μοντέλα ακόμα και σε υψηλή ακρίβεια πρόβλεψης.

Ακρίβεια πρόβλεψης ανά εποχή: Από τα αποτελέσματα μεσοπρόθεσμης πρόβλεψης είναι φανερό ότι η χειρότερη ακρίβεια πρόβλεψης παρατηρείται τους χειμερινούς μήνες, σε όλα τα μοντέλα πρόβλεψης επιμέρους. Αυτό είναι αναμενόμενο αν αναλογιστούμε ότι το χειμώνα ο καιρός είναι παραδοσιακά πιο άστατος. Ωστόσο προς τους καλοκαιρινούς μήνες, όπου οι καιρικές συνθήκες είναι

καλύτερες, η ακρίβεια πρόβλεψης βελτιώνεται και τα σφάλματα γίνονται πολύ μικρά.

Σύγκριση αποτελεσμάτων με υφιστάμενη βιβλιογραφία: Στην βιβλιογραφία πέραν των κλασικών μοντέλων βρίσκονται μοντέλα τα οποία έχουν προκύψει μέσα από το συνδυασμό διάφορων τεχνικών και μοντέλων, τα λεγόμενα υβριδικά μοντέλα. Αυτά τα μοντέλα, σε πολλές περιπτώσεις επιτυγχάνουν MAPE (το πολύ) ίσο με 5-6%. Ωστόσο τα μοντέλα τα οποία έχουν αναπτυχθεί στα πλαίσια της παρούσας διπλωματικής εργασίας, έχουν εξίσου πολύ καλές επιδόσεις και καλύτερες από αντίστοιχα μοντέλα, με το καλύτερο εξ' αυτών, το Regression Model with Arma Errors, να έχει μέσο MAPE περίπου 7.5%.

Μεσοπρόθεσμη πρόβλεψη ηλιακής ακτινοβολίας

Ακρίβεια πρόβλεψης των μοντέλων: Η πρόβλεψη των μοντέλων που κατασκευάστηκαν για τη μεσοπρόθεσμη πρόβλεψη της ηλιακής ακτινοβολίας χαρακτηρίζεται ως αξιόπιστη. Αν υπήρχαν τα δεδομένα θολερότητας και μέσης διάρκειας ηλιοφάνειας ανά ώρα για τη βραχονησίδα, Ντία και εντάσσονταν στο διάνυσμα εισόδου, τα μοντέλα NARX και Regarma είναι δεδομένο πως θα είχαν καλή ακρίβεια και πολύ πιθανό υψηλή ακρίβεια πρόβλεψης. Το μοντέλο BDT, σε αντίθεση με τα υπόλοιπα που βρίσκονται οριακά εκτός καλής ακρίβειας πρόβλεψης, πετυχαίνει SMAPE περίπου 41%. Όπως είναι αντιληπτό ακόμα και να υπήρχαν οι δύο μεταβλητές που αναφέρθηκαν, δεν είναι βέβαιο ότι θα ήταν στην κατηγορία της καλής ακρίβειας πρόβλεψης. Οι λόγοι που μας οδηγούν σ' αυτά τα συμπεράσματα έχουν αναλυθεί πλήρως στην εισαγωγή του κεφαλαίου 4.2.2.

Χρόνος εκπαίδευσης: Σχετικά με το χρόνο της εκπαίδευσης και κατ' επέκταση την εξαγωγή των προβλέψεων, τα μοντέλα NARX και Regarma είχαν πιο σύντομους χρόνους εκτέλεσης, με το πρώτο να είναι πιο γρήγορο. Αντίθετα, το μοντέλο BDT είχε μεγαλύτερες καθυστερήσεις.

Μέθοδος πρόβλεψης 2 και 4: Τα συμπεράσματα που προκύπτουν είναι παρόμοια με τα αντίστοιχα της μεσοπρόθεσμης πρόβλεψης ταχύτητας ανέμου, αλλά δεν παρατηρούνται πολύ μεγάλες αποκλίσεις όσο αφορά την ακρίβεια πρόβλεψης μεταξύ των δυο στρατηγικών. Μέσα απ' τη σύγκριση των αποτελεσμάτων μεταξύ των δύο στρατηγικών πρόβλεψης, συμπεραίνεται ότι στην περίπτωση μας, η μέθοδος πρόβλεψης 2 είναι προτιμότερη σε σχέση με τη μέθοδο 4.

Χρήση δεδομένων αστικού περιβάλλοντος και βραχονησίδας: Στην περίπτωση της ηλιακής ακτινοβολίας δεν παρατηρούνται μεγάλες αποκλίσεις στις προβλέψεις με χρήση δεδομένων κατοικημένης περιοχής από αστικό περιβάλλον, σε σχέση με της ακατοίκητης βραχονησίδας. Απ' ότι φαίνεται η χωρική προέλευση των δεδομένων δεν επηρεάζει σε τόσο μεγάλο βαθμό την ακρίβεια πρόβλεψης της

ηλιακής ακτινοβολίας. Αυτό ήταν αναμενόμενο καθώς οι βασικοί παράγοντες που επηρεάζουν την ηλιακή ακτινοβολία είναι το γεωγραφικό μήκος και πλάτος, και κυρίως οι νεφώσεις. Αντίθετα στον άνεμο είδαμε ότι η ακρίβεια πρόβλεψης χειροτέρευε σε μεγάλο βαθμό στην περίπτωση που χρησιμοποιήσαμε δεδομένα αστικού περιβάλλοντος.

Ακρίβεια πρόβλεψης ανά εποχή: Όπως και στην περίπτωση της πρόβλεψης της ταχύτητας του ανέμου, έτσι και στην πρόβλεψη της ηλιακής ακτινοβολίας, παρατηρείται μεγαλύτερη ακρίβεια τους μήνες της άνοιξης και ακόμα περισσότερο του καλοκαιριού, σε σχέση με τους φθινοπωρινούς και χειμερινούς μήνες.

Σύγκριση αποτελεσμάτων με υφιστάμενη βιβλιογραφία: Στη βιβλιογραφία βρίσκονται υλοποιήσεις μοντέλων νευρωνικών δικτύων που επιτυγχάνουν SMAPE ακόμα και κοντά στο 6%. Τα μοντέλα της παρούσας διπλωματικής εργασίας έχουν στην καλύτερη περίπτωση SMAPE περίπου ίσο με 21%. Ωστόσο με την προσθήκη των δυο μεταβλητών που προαναφέρθηκαν στο διάνυσμα εισόδου, είναι βέβαιο ότι τα μοντέλα θα είναι εξίσου ανταγωνιστικά.

Ιδέες για Μελλοντική Έρευνα

Στην παρούσα διπλωματική εργασία θα μπορούσαν να υλοποιηθούν κάποιες προεκτάσεις οι οποίες ξεφεύγουν απ' το πλαίσιο της. Θα μπορούσαν να δημιουργηθούν υβριδικά μοντέλα μεσοπρόθεσμης πρόβλεψης τα οποία θα χρησιμοποιούν την άμεση- αναδρομική υβριδική πρόβλεψη πολλαπλών βημάτων (μέθοδος 3). Αυτό ενδεχομένως να οδηγούσε σε καλύτερα αποτελέσματα. Απ' τα υβριδικά μοντέλα θα επωφελούμασταν απ' το συνδυασμό των θετικών στοιχείων του κάθε μοντέλου, κάτι που επιβεβαιώνεται και στην βιβλιογραφία. Επίσης η άμεση και η αναδρομική μέθοδος πρόβλεψης αν συνδυαστούν σωστά θα μπορούσαν να προσφέρουν τα οφέλη τους, βελτιώνοντας περεταίρω την ακρίβεια πρόβλεψης. Η διαδικασία της εκπαίδευσης και της μεσοπρόθεσμης πρόβλεψης θα ήταν προτιμότερο να γίνεται με τον τρόπο που παρουσιάστηκε στην παρούσα διπλωματική εργασία, δηλαδή ανά μήνα ή ακόμα και ανά εποχή.

Βιβλιογραφία

1. "Machine Learning Algorithms in Multi-Processing Environments ", Stergiou Konstantinos
2. "Prediction models theoretical evaluation and applications", Eleni Katti
3. "ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΣΤΗΝ ΥΠΟΛΟΓΙΣΤΙΚΗ
ΌΡΑΣΗ", ΠΑΠΑΔΟΠΟΥΛΟΣ ΑΘΑΝΑΣΙΟΣ
4. https://en.wikipedia.org/wiki/Nonlinear_autoregressive_exogenous_model
5. <https://colah.github.io/posts/2015-08-Understanding-LSTMs>
6. "A Regression Model with ARIMA Errors to Investigate the Frequency and Severity of Road Traffic Accidents", Filip Van den Bossche, Geert Wets, Tom Brijs
7. "Narx Based Short Term Wind Power Forecasting Model", M. Nandana Jyothi¹, V. Dinakar², N. S S Ravi Teja³
8. <https://www.mathworks.com/help/>
9. <https://www.dataquest.io/blog/understanding-regression-error-metrics/>
10. <https://machinelearningmastery.com/multi-step-time-series-forecasting/>
11. "The state-of-the-art in short-term prediction of wind power: A literature overview", G Giebel, R Brownsword, G Kariniotakis, M Denhard, C Draxl
12. "Trading wind generation from short-term probabilistic forecasts of wind power", P Pinson, C Chevallier, GN Kariniotakis
13. "Standardizing the performance evaluation of short-term wind power prediction models", H Madsen, P Pinson, G Kariniotakis, HA Nielsen, TS Nielsen
14. "Short-Term Solar Irradiance Forecasting Model Based on Artificial Neural Network Using Statistical Feature Parameters", Fei Wang, Zengqiang Mi, Shi Shu, Hongshan Zhao
15. "Different Models of Wind Speed Prediction: A Comprehensive Review", S. M. Lawan, W. A. W. Z. Abidin, W. Y. Chai, A. Baharun and T. Masri
16. "Short-Term Wind Speed Prediction using Supervised Machine Learning Techniques", Frank E. Yeboah, Andrea N. Ofori-Boadu, Peter A. Sam, Musibau A. Shofoluwe
17. "Using Artificial Intelligence to Predict Wind Speed for Energy Application in Saudi Arabia", Tayeb Brahimi
18. "Short-term wind power forecasting using long-short term memory based recurrent neural network model and variable selection", Umit Cali, Vinayak Sharma
19. "Multi-step Ahead Wind Power Forecasting Based on Recurrent Neural Networks", Yiwei FU, Wei HU, Maolin TANG, Rui YU and Baisi LIU
20. "Multi-Step Wind Speed Forecasting Based On Ensemble Empirical Mode Decomposition, Long Short Term Memory Network and Error Correction Strategy", Yuansheng Huang, Lei Yang, Shijian Liu and Guangli Wan
21. "Solar Irradiance Forecasting Using Deep Neural Networks", Ahmad Alzahrani, Pourya Shamsi, Cihan Dagli, and Mehdi Ferdowsi
22. "Predicting Solar Irradiance Using Time Series Neural Networks", Alzahrani, A*. Kimball, J.W. Dagli, C

23. "Solar radiation prediction using Artificial Neural Network techniques: A review", Amit Kumar Yadav, S.S. Chandel
24. "Deep Learning to Predict the Generation of a Wind Farm", J.M. Torres, R.M. Aguilar, and K.V. Zuniga-Meneses
25. "Wind speed forecasting using the NARX model, case: La Mata,
26. Oaxaca, Mexico", Erasmo Cadenas, Wilfrido Rivera, Rafael Campos-Amezcuca, Roberto Cadenas
27. "Solar radiation forecasting using MARS, CART, M5, and random forest model: A case study for India", Rachit Srivastava, A.N. Tiwari, V.K. Giri
28. "A comprehensive review of hybrid models for solar radiation forecasting", Mawloud Guermoui, Farid Melgani, Kacem Gairaa, Mohamed Lamine Mekhalfi
29. "Solar radiation forecasting using artificial neural network and random forest methods: Application to normal beam, horizontal diffuse and global components", L. Benali, G. Notton, A. Fouilloy, C. Voyant, R. Dizene
30. "Multi-step ahead forecasting of daily global and direct solar radiation: A review and case study of Ghardaia region", Mawloud Guermoui, Farid Melgani, Celine Danilo
31. "Machine learning methods for solar radiation forecasting: A review", Cyril Voyant, Gilles Notton, Soteris Kalogirou, Marie-Laure Nivet, Christophe Paoli, Fabrice Motte, Alexis Fouilloy
32. <https://www.altumintelligence.com/articles/a/Time-Series-Prediction-Using-LSTM-Deep-Neural-Networks>
33. "Πρόβλεψη παραγωγής αιολικής ισχύος με χρήση τεχνητών νευρωνικών δικτύων και τεχνικών ασαφούς λογικής", ΚΥΡΑΤΖΟΥΛΗ ΑΧΙΛΛΕΑ, ΚΩΣΤΑΛΑ ΑΠΟΣΤΟΛΟΥ
34. https://el.wikipedia.org/wiki/Τεχνητή_νοημοσύνη
35. https://el.wikipedia.org/wiki/Artificial_neural_network
36. <https://internal.ncl.ac.uk/ask/numeracy-maths-statistics/statistics/regression-and-correlation/>
37. https://wiki2.org/en/Symmetric_mean_absolute_percentage_error