

**ΑΥΤΟΜΑΤΟΠΟΙΗΜΕΝΕΣ ΜΕΘΟΔΟΙ ΕΥΡΕΣΗΣ ΒΕΛΤΙΣΤΩΝ
ΥΠΕΡ-ΠΑΡΑΜΕΤΡΩΝ ΣΕ ΤΕΧΝΙΚΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΓΙΑ
ΤΗ ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΤΗΣ ΙΟΝΟΣΦΑΙΡΙΚΗΣ ΔΡΑΣΤΗΡΙΟΤΗΤΑΣ
ΜΕΣΩ ΜΕΤΡΗΣΕΩΝ GNSS**

Μάριος Σπανάκης

Διπλωματική Εργασία

Σχολή Αγρονόμων και Τοπογράφων Μηχανικών – Μηχανικών Γεωπληροφορικής

Εθνικό Μετσόβιο Πολυτεχνείο



School of Rural, Surveying and Geoinformatics Engineering

National Technical University of Athens

Αθήνα, Σεπτέμβριος 2022

Επιβλέπων: Νικόλαος Δουλάμης

Αναπληρωτής Καθηγητής ΕΜΠ

Τριμελής επιτροπή

Νικόλαος Δουλάμης
Αναπληρωτής Καθηγητής

Μαρία Τσακίρη
Καθηγήτρια

Βασίλειος Γκίκας
Καθηγητής

Ευχαριστίες

Με την εκπόνηση της παρούσας διπλωματικής εργασίας, ολοκληρώνεται ο προπτυχιακός κύκλος σπουδών μου στη Σχολή Αγρονόμων και Τοπογράφων Μηχανικών – Μηχανικών Γεωπληροφορικής του Εθνικού Μετσόβιου Πολυτεχνείου. Ελπίζω, πρωτίστως με τη βοήθεια του Θεού, στην επαγγελματική και ακαδημαϊκή μου εξέλιξη, καθώς ως Αξιωματικός δυνάμεως του Γεωγραφικού σώματος, θεωρώ υποχρέωσή μου την άρτια επαγγελματική μου κατάρτιση.

Ευχαριστώ τους γονείς μου, Ζαχαρία και Μαργαρίτα Σπανάκη, και τον αδερφό μου και συνάμα συνάδελφο Γεώργιο Σπανάκη για τη στήριξη, την καθοδήγηση και την αγάπη που μου έδωσαν και συνεχίζουν να μου δίνουν.

Ευχαριστώ τους συναδέλφους μου Δημήτριο Σακελλαρίου και Τσουμενή Εμμανουήλ, με τους οποίους αντιμετώπισαμε τις ίδιες δυσκολίες από τη Σχολή Ευελπίδων μέχρι και σήμερα και από τη μέρα που παρουσιαστήκαμε στη ΓΥΣ ήμασταν πάντα ο ένας για τον άλλο.

Ευχαριστώ τον Αναπληρωτή Καθηγητή κ. Νικόλαο Δουλάμη, καθώς ως καθηγητής μου στη Σχολή Τοπογραφίας της ΓΥΣ αλλά και στο ΕΜΠ, μου έδωσε πολλά εφόδια για την κατάρτισή μου ως μηχανικός. Περισσότερο όμως τον ευχαριστώ γιατί μου εμφύσησε ένα διαφορετικό τρόπο αντίληψης και αντιμετώπισης καταστάσεων και γιατί έδειξε εμπιστοσύνη στις δυνατότητές μου.

Ευχαριστώ τους φίλους και συμφοιτητές μου για την όμορφη συνεργασία που είχαμε στα έτη φοίτησής μου στη σχολή και για όλες τις ευχάριστες αναμνήσεις που αποκομίσαμε παρέα.

Τέλος, θα ήθελα να ευχαριστήσω και την Δρ. Μαρία Κασελίμη και τον υποψήφιο Δρ. Αναστάσιο Τέμενο για την άψογη συνεργασία και τη συνεχή καθοδήγηση στην εκπόνηση αυτής της εργασίας.

Περίληψη

Τα παγκόσμια συστήματα δορυφορικού εντοπισμού (GNSS), έχουν πλέον εφαρμογή σχεδόν σε όλες τις δράσεις του ανθρώπου, από τη βαριά λεγόμενη βιομηχανία έως και την καθημερινότητα. Για την ορθή εκμετάλλευση της πληροφορίας που προσλαμβάνουμε από εκπεμπόμενο δορυφορικό σήμα, οφείλουμε να το απαλλάξουμε από κάθε λογής σφάλμα. Μια κατηγορία σφαλμάτων οφείλονται στη διάδοση του σήματος στην ατμόσφαιρα. Στην παρούσα μελέτη, σκοπός μας είναι να υλοποιήσουμε βέλτιστο μοντέλο πρόβλεψης ιονοσφαιρικής δραστηριότητας, ώστε να έχουμε τη δυνατότητα να απαλείψουμε το σφάλμα που δημιουργείται κατά τη διάδοση του σήματος διαμέσου του στρώματος της ιονόσφαιρας (ιονοσφαιρική καθυστέρηση). Πιο συγκεκριμένα εκμεταλλευόμενοι τις δυνατότητες βαθιάς μάθησης και τα δεδομένα γνωστών ιονοσφαιρικών μεταβολών σε συνεχείς χρονοσειρές, εκπαιδεύσαμε τρία νευρωνικά δίκτυα (RNN, LSTM & GRU). Ο βέλτιστος συνδυασμός παραμέτρων έχει αναδειχθεί από προγενέστερη αντίστοιχη μελέτη. Στην παρούσα καλούμαστε να αναδείξουμε τον βέλτιστο πλήθος φίλτρων (υπερπαραμέτροι) που θα εφαρμοστούν, ώστε να έχουμε πλέον ένα ολοκληρωμένο και πιο αξιόπιστο μοντέλο πρόβλεψης ιονοσφαιρικής δραστηριότητας (πυκνότητες ηλεκτρονίων - TEC).

Λέξεις κλειδιά

παγκόσμια συστήματα δορυφορικού εντοπισμού, GNSS, ιονοσφαιρική καθυστέρηση, βαθιά μάθηση, επαναλαμβανόμενα νευρωνικά δίκτυα, RNN, LSTM, GRU, υπερπαραμέτροι, μοντέλο πρόβλεψης ιονοσφαιρικής δραστηριότητας

Abstract

Global Navigation Satellite Systems (GNSS) are now applied to almost all human activities, from heavy industry to everyday life. In order to make proper use of the information received from a transmitted satellite signal, we must rid it of all kinds of errors. One category of errors is due to the propagation of the signal in the atmosphere. In this study, we aim to implement an optimal ionospheric activity prediction model to be able to eliminate the error generated during the propagation of the signal through the ionospheric layer (ionospheric delay). More specifically, exploiting deep learning capabilities and data of known ionospheric variations in continuous time series, we trained three neural networks (RNN, LSTM & GRU). The optimal combination of parameters has been highlighted by a previous similar study. In the present one we are called to highlight the optimal set of filters (hyperparameters) to be applied, so that we now have a comprehensive and more reliable ionospheric activity (electron densities - TEC) prediction model.

Keywords

Global Navigation Satellite Systems, GNSS, ionospheric delay, deep learning, neural networks, RNN, LSTM, GRU, hyperparameters, ionospheric activity, prediction model

Περιεχόμενα

Ευχαριστίες.....	2
Περίληψη	3
Λέξεις κλειδιά	3
Abstract.....	4
Keywords.....	4
Περιεχόμενα	5
Ευρετήριο εικόνων	7
Ευρετήριο πινάκων.....	10
Κατάλογος συντομογραφιών.....	10
ΚΕΦΑΛΑΙΟ 1	12
Εισαγωγή.....	12
1.1 Η σημασία της πρόβλεψης της ιονοσφαιρικής δραστηριότητας.	12
1.2 Προκλήσεις.	12
1.3 Συνεισφορά.....	13
1.4 Δομή εργασίας.....	13
ΚΕΦΑΛΑΙΟ 2	15
Βιβλιογραφική ανασκόπηση	15
2.1 Απόδοση διαφορετικών μοντέλων TEC για την παροχή ιονοσφαιρικών διορθώσεων GPS	15
2.2 Εφαρμογή του μετασχηματισμού Hilbert-Huang στη μελέτη μεταβολών της ιονόσφαιρας HILBERT-HUANG transform application in ionospheric variability studies.....	15
2.3 Σύγκριση και έρευνα συνέπειας περιφερειακών μοντέλων ιονοσφαιρικής TEC με βάση μετρήσεις GPS	17
2.4 Μελέτη της ιονόσφαιρας στην Ελλάδα μέσω της επεξεργασίας παρατηρήσεων GPS.....	17
2.5 Υλοποίηση υβριδικού αλγορίθμου πρόβλεψης ιονοσφαιρικού TEC με χρήση της μεθόδου PCA-NN.....	18
ΚΕΦΑΛΑΙΟ 3	19
Συστήματα GNSS & Ατμόσφαιρα.....	19
3.1 Συστήματα GNSS.....	19
3.2 Ατμόσφαιρα	21

3.3 Η Ιονόσφαιρα και τα στρώματά της.....	24
3.4 Οι τιμές TEC (Total Electron Content).....	27
3.5 Παράμετροι επιρροής τιμών Tec.....	30
ΚΕΦΑΛΑΙΟ 4.....	39
Τεχνητή νοημοσύνη.....	39
4. Εισαγωγικά.....	39
4.1 Μηχανική Μάθηση (machine learning).....	39
4.2 Βαθιά Μάθηση (deep learning).....	41
4.3 Νευρωνικά Δίκτυα (Neural Networks).....	42
4.4 Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks).....	43
4.5 Νευρώνες μακράς-βραχείας διάρκειας μνήμης (Long Short-Term Memory - LSTM).....	44
4.6 Αναδρομική Μονάδα με Πύλες (Gated Recurrent Units).....	45
ΚΕΦΑΛΑΙΟ 5.....	47
Προγραμματισμός διαδικασιών σε Python.....	47
5.1 Η Python ως γλώσσα προγραμματισμού.....	47
5.2 Google Colab.....	47
5.3 Βιβλιοθήκες που χρησιμοποιήθηκαν.....	48
5.4 Υλοποίηση σε Python.....	49
ΚΕΦΑΛΑΙΟ 6.....	52
Διαχείριση δεδομένων.....	52
6.1 Εισαγωγικές έννοιες.....	52
6.2 Περιγραφή των δεδομένων.....	52
6.3 Επεξεργασία των δεδομένων.....	67
ΚΕΦΑΛΑΙΟ 7.....	68
Μελέτη σεναρίων επίδρασης υπερ-παραμέτρων.....	68
7. Εισαγωγικά.....	68
7.1 Βέλτιστο σενάριο παραμέτρων.....	68
7.2 Σενάρια μελέτης υπερπαραμέτρων.....	69
7.3 Δείκτες αξιολόγησης αποτελεσμάτων.....	69
7.4 Παράθεση και αξιολόγηση σεναρίων.....	72
7.4.1 Αποτελέσματα μοντέλων πρόβλεψης με δεδομένα εξόδου VTEC.....	72
1° ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 64.....	72

2° ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 128.....	76
3° ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 256.....	80
4° ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 512.....	84
7.4.2 Αποτελέσματα μοντέλων πρόβλεψης με δεδομένα εξόδου STEC.....	88
1° ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 64.....	88
2° ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 128.....	92
3° ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 256.....	96
4° ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 512.....	100
7.5 Βέλτιστο μοντέλο πρόβλεψης ιονοσφαιρικής δραστηριότητας.....	103
ΚΕΦΑΛΑΙΟ 8.....	105
Συμπεράσματα.....	105
Αναφορές.....	106
Παραρτήματα.....	109
Α. Πίνακας δεδομένων ανά μήνα.....	109
Β. Κώδικας σε γλώσσα προγραμματισμού Python.....	109

Ευρετήριο εικόνων

Εικόνα 1. Συσχέτιση κωδίκων.....	20
Εικόνα 2. Παρατήρηση φάσης.....	20
Εικόνα 3. διαίρεση της ατμοσφαιρας σε στρώματα.....	21
Εικόνα 4. Τα στρώματα της ιονόσφαιρας.....	27
Εικόνα 5. Έκρηξη CME στις 31 Αυγούστου 2012 (Πηγή: NASA Goddard Space Flight Center).....	34
Εικόνα 6. Οι X2.2 και X9.3 Solar Flares που εξέπεμψε ο Ήλιος στις 6 Σεπτεμβρίου 2017. Οι εικόνες καταγράφηκαν από το Solar Dynamics Observatory της NASA και δείχνουν φως στο μήκος κύματος των 131 angstrom. (Πηγή: NASA/Goddard/SDO).....	36
Εικόνα 7. Τεχνητή νοημοσύνη.....	39
Εικόνα 8. Φάσεις αλγορίθμου Μηχανικής Μάθησης.....	41
Εικόνα 9. Τυπική δομή πολυεπίπεδων μοντέλων.....	42
Εικόνα 10. Λειτουργία τεχνητού νευρώνα.....	43
Εικόνα 11. Τυπική δομή αναδρομικού νευρωνικού δικτύου.....	44
Εικόνα 12. Σύγκριση αναδρομικών μοντέλων.....	44
Εικόνα 13. Μοντέλο LSTM που χρησιμοποιείται για την εκτίμηση του TEC.....	45
Εικόνα 14. Τυπική δομή αναδρομικού νευρωνικού δικτύου με πύλες.....	46
Εικόνα 15. Εισαγωγή βιβλιοθηκών.....	49
Εικόνα 16. Επιλογή παραμέτρων εκπαίδευσης.....	49

Εικόνα 17.Κανονικοποίηση δεδομένων.	49
Εικόνα 18. Τυχαίο "ανακάτεμα" δεδομένων.	50
Εικόνα 19. Δυνατότητα τροποποίησης υπερπαραμέτρων.	50
Εικόνα 20. Αρχιτεκτονική μοντέλων RNN, LSTM & GRU από αριστερά προς τα δεξιά.	50
Εικόνα 21. Υπολογισμός των μέτρων μετρητικών δεικτών αξιολόγησης MAE και MSE.	51
Εικόνα 22. Σταθμός COTE00ATA (Πηγή: IGS)	52
Εικόνα 23. Όλοι οι διαθέσιμοι σταθμοί του συστήματος GNSS (Πηγή: IGS).....	53
Εικόνα 24. Τυπική μορφή αρχείου RINEX.	53
Εικόνα 25.Συμπεριφορά των τιμών TEC ανά ώρα με βάση το γεωγραφικό πλάτος ..	57
Εικόνα 26. Τιμές TEC ανά Δορυφόρο	57
Εικόνα 27.Η διακύμανση της τιμής TEC την 01 Ιανουαρίου 2018, ανά Δ/Φ (PRN 01, 02 κλπ) σε κάποιο εύρος υψομέτρων.	58
Εικόνα 28. Υπόδειγμα δεδομένων γεωμαγνητικής δραστηριότητας (K).....	59
Εικόνα 29. Ανταπόκριση παραμέτρων AE και SME σε γεγονός την 30 Ιανουαρίου 1997 (Πηγή: Newell and Gjerloev, Evaluation of SuperMAG auroral electrojet indices as indicators of substorms and auroral power, 2011)	60
Εικόνα 30. Υπόδειγμα δεδομένων SME.....	60
Εικόνα 31. Υπόδειγμα δεδομένων Dst	61
Εικόνα 32. Υπόδειγμα δεδομένων Solar Radio Flux	63
Εικόνα 33. Υπόδειγμα δεδομένων Sunspot Number	64
Εικόνα 34. Βασιλικό Αστεροσκοπείο Βελγίου (Πηγή: wwwbis.sidc.be).....	64
Εικόνα 35. Υπόδειγμα δεδομένων Energetic Particle Flux.....	65
Εικόνα 36. Υπόδειγμα δεδομένων Solar Flares.....	66
Εικόνα 37. Υπόδειγμα δεδομένων Coronal Mass Ejections.	66
Εικόνα 38.Αποτέλεσμα εκπαίδευσης δικτύου RNN με 64 φίλτρα σε 200 εποχές.....	71
Εικόνα 39. Αποτέλεσμα εκπαίδευσης δικτύου RNN με 64 φίλτρα σε 100 εποχές.....	72
Εικόνα 40. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.	73
Εικόνα 41. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.....	73
Εικόνα 42. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.....	74
Εικόνα 43. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.	74
Εικόνα 44.Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.	75
Εικόνα 45. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.....	75
Εικόνα 46. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.	77
Εικόνα 47. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.....	77
Εικόνα 48. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.....	78
Εικόνα 49. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.....	78

Εικόνα 50. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.	79
Εικόνα 51. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.....	79
Εικόνα 52. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.	81
Εικόνα 53. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.....	81
Εικόνα 54. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.....	82
Εικόνα 55. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.	82
Εικόνα 56. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.	83
Εικόνα 57. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.....	83
Εικόνα 58. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.	85
Εικόνα 59. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.....	85
Εικόνα 60. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.....	86
Εικόνα 61. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.	86
Εικόνα 62. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.	87
Εικόνα 63. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.....	87
Εικόνα 64. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.	89
Εικόνα 65. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.....	89
Εικόνα 66. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.....	90
Εικόνα 67. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.	90
Εικόνα 68. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.	91
Εικόνα 69. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.....	91
Εικόνα 70. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.	93
Εικόνα 71. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.....	93
Εικόνα 72. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.....	94
Εικόνα 73. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.	94
Εικόνα 74. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.	95
Εικόνα 75. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.....	95
Εικόνα 76. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.	96
Εικόνα 77. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.....	97
Εικόνα 78. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.....	97

Εικόνα 79. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.....	98
Εικόνα 80. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.	98
Εικόνα 81. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.....	99
Εικόνα 82. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.	100
Εικόνα 83. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.....	100
Εικόνα 84. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.....	101
Εικόνα 85. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.....	101
Εικόνα 86. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.	102
Εικόνα 87. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.....	102

Ευρετήριο πινάκων

Πίνακας 1. Παράμετροι επιρροής της ιονόσφαιρας.	30
Πίνακας 2. Excel με τα δεδομένα των παραμέτρων που χρησιμοποιήθηκαν.....	58
Πίνακας 3. Σενάρια για επιλογή καταλληλότερων παραμέτρων.....	68
Πίνακας 4. Διαχωρισμός σεναρίων μελέτης υπερπαραμέτρων επιρροής πρόβλεψης των τιμών TEC.	69
Πίνακας 5. Συγκεντρωτικό γράφημα μετρητικών δεικτών MAE και MSE όλων των σεναρίων μοντέλων πρόβλεψης VTEC.	104
Πίνακας 6. Συγκεντρωτικό γράφημα μετρητικών δεικτών MAE και MSE όλων των σεναρίων μοντέλων πρόβλεψης STEC.....	104

Κατάλογος συντομογραφιών

AE	Auroral Electrojet
CDDIS	Crustal Dynamics Data Information System
CDP	Crustal Dynamics Project
CME	Coronal Mass Ejection
CODE	Center for Orbit Determination in Europe
DORIS	Doppler Orbitography and Radio-positioning Integrated by Satellite
Dst	Disturbance storm time
EGNOS	European Geostationary Navigation Overlay Service
GIM	Global Ionosphere Maps
IAGA	International Association of Geomagnetism and Aeronomy
IDS	International DORIS Service
IGS	International GNSS Service

ILRS	International Laser Ranging Service
IVS	International VLBI Service for Geodesy and Astrometry
GLONASS	GLOBAL Navigation Satellite System
GNSS	Global Navigation Satellite System
GOES-15	Geostationary Operational Environmental Satellite
GPS	Global Positioning System
GTEC	Global Total Electron Content
IRNSS	Indian Regional Navigational Satellite System
LASO	Large Angle and Spectrometric Coronagraph
LSTM	Long Short-Term Memory
MAE	Mean Absolute Error
MEV	Mega ElectronVolt
MSE	Mean Square Error
NASA	National Aeronautics and Space Administration
NAVSTAR	NAVigation Satellite Timing And Ranging
NOAA	National Oceanic and Atmospheric Administration
PCA-NN	Principal Component Analysis Neural Networks
QZSS	Quasi-Zenith Satellite System
RHESSI	Ramaty High Energy Solar Spectroscopic Imager
RINEX	Receiver Independent Exchange Format
RMSE	Rooted mean squared error
RNN	Reccurent Neural Network
SBAS	Satellite-Based Augmentation System
SLR	Satellite Laser Ranging
SME	SuperMAG Electrojet
SML	SuperMAG Upper
SMU	SuperMAG Lower
STEC	Slant Total Electron Content
SWPC	Space Weather Prediction Center
TEC	Total Electron Content
TECU	Total Electron Content Units
VLBI	Very Long Baseline Interferometry
VTEC	Vertical Total Electron Content

Εισαγωγή

1.1 Η σημασία της πρόβλεψης της ιονοσφαιρικής δραστηριότητας.

Βασική αρχή για την λειτουργία δορυφορικών συστημάτων εντοπισμού (GNSS), είναι η λήψη του σήματος από τον δορυφορικό δέκτη. Το σήμα αυτό εκπέμπεται από δορυφόρους με ύψος πτήσης 20.000 χιλιόμετρα και διαδίδεται διαμέσου της ατμόσφαιρας έως τη φυσική γήινη επιφάνεια. Αναπόφευκτες είναι οι καθυστερήσεις, λόγω των στρωμάτων της ατμόσφαιρας και λόγω τυχαίων πολλαπλών διαδρομών και ανακλάσεων. Συνεπώς απαραίτητες κρίνονται οι διορθώσεις λόγω των καθυστερήσεων για εξάλειψη σφαλμάτων.

Η ιονόσφαιρα, που αποτελεί στρώμα της ατμόσφαιρας σε ύψος 50 έως 1000 χιλιόμετρα πάνω από την γήινη επιφάνεια, επηρεάζει τη διάδοση του σήματος. Η ύπαρξη ελευθέρων φορτισμένων σωματιδίων, κυρίων ηλεκτρονίων από άτομα οξυγόνου, μεταβάλλουν την ταχύτητα, τη διεύθυνση και την πολικότητα του σήματος, με μεγαλύτερη επίδραση στο μέτρο της ταχύτητας και συνεπώς στον ορθό υπολογισμό απόστασης δορυφόρου – δέκτη (ιονοσφαιρικό σφάλμα). Το ιονοσφαιρικό σφάλμα, αποτελεί τυχαίο σφάλμα (random error) που προφανώς είναι αναπόφευκτο κατά την εκτέλεση των μετρήσεων, και ονομάζεται θόρυβος (noise, white noise).

Η ιονοσφαιρική καθυστέρηση είναι ανάλογη της πυκνότητας των ηλεκτρονίων TEC (Total Electron Content). Οι τιμές TEC παρουσιάζουν διακυμάνσεις ακόμα και κατά τη διάρκεια του 24ώρου. Η εξασφάλιση δυνατότητας πρόβλεψης των τιμών αυτών διαδραματίζει σπουδαίο ρόλο για τα συστήματα GNSS, καθώς η ιονοσφαιρική δραστηριότητα όπως θα διαπιστώσουμε και ακολούθως επηρεάζει ουσιαστικά την ορθή λειτουργία τους.

1.2 Προκλήσεις.

Το κύριο ερευνητικό πεδίο στην παρούσα μελέτη αποτελεί το ιονοσφαιρικό μοντέλο TEC, που είναι ένα σημαντικό ζήτημα σε πολλές real – time εφαρμογές GNSS. Η αξιόπιστη και γρήγορη γνώση για τις ιονοσφαιρικές παραλλαγές γίνεται όλο και πιο σημαντική. Χρήστες GNSS, με δέκτες μονής συχνότητας και συστημάτων δορυφορικής πλοήγησης, χρειάζονται ακριβείς διορθώσεις για να αφαιρέσουν την υποβάθμιση του σήματος που προκαλείται από την ιονόσφαιρα. Η ιονοσφαιρική μοντελοποίηση με κατάλληλο συνδυασμό παραμέτρων είναι το αντικείμενο συζήτησης στο παρούσα συνεισφορά.

Το Ευρωπαϊκό Κέντρο Προσδιορισμού Τροχιών (CODE) παρέχει Παγκόσμιους Ιονοσφαιρικούς Χάρτες (GIM) σε ένα κάναβο (2,5°×5,0°), με ανάλυση 2 ωρών. Ωστόσο, οι τιμές STEC και VTEC αποτυγχάνουν να αφαιρέσουν τη συνολική ποσότητα θορύβου που προκαλείται από την ιονόσφαιρα, λόγω της ευρείας τους κάλυψης και

την αδυναμία τους να προσαρμοστούν με ακρίβεια σε περιφερειακό (και περισσότερο σε τοπικό) επίπεδο.

Η πρόβλεψη τιμών TEC είναι εφικτή με χρήση μοντέλων μηχανικής μάθησης, εκμεταλλευόμενοι γνωστές ιονοσφαιρικές μεταβολές σε συνεχείς χρονοσειρές. Ωστόσο, επιλέγοντας το πιο βολικό τύπο νευρωνικού δικτύου βαθιάς μάθησης και η παραμετροποίηση του, είναι ένα σύνθετο έργο που απαιτεί μελέτη και επιμονή.

Στόχος της παρούσας διπλωματικής εργασίας είναι, μέσω αξιολόγησης αποτελεσμάτων εκπαίδευσης νευρικών δικτύων, χρησιμοποιώντας δεδομένα μετρήσεων GNSS, να αναδείξουμε βέλτιστο μοντέλο πρόβλεψης ιονοσφαιρικής δραστηριότητας. Εκμεταλλευόμενοι την γνώση βέλτιστου συνδυασμού παραμέτρων από ανάλογη μελέτη, θα εστιάσουμε στην ανάδειξη βέλτιστου συνδυασμού υπερπαραμέτρων, για την επίτευξη του σκοπού μας.

1.3 Συνεισφορά

Η συνολική συνεισφορά της παρούσας διπλωματικής εργασίας προσδιορίζεται από τους ακόλουθους στόχους:

- να εκπαιδεύσει μοντέλα βαθιάς μάθησης χρησιμοποιώντας κατάλληλα επεξεργασμένα δεδομένα GNSS συνεχών χρονοσειρών, με σκοπό την παρουσίαση μιας ολοκληρωμένης ανάλυσης και την σύγκριση των αποτελεσμάτων εκπαίδευσης.
- να αναδείξει βέλτιστο μοντέλο βαθιάς μάθησης, που εκμεταλλεύεται συγκεκριμένες παραμέτρους και διάφορες υπερπαραμέτρους για τη βελτίωση της πρόβλεψης και της ακρίβειας στη μοντελοποίηση TEC

1.4 Δομή εργασίας

Στο δεύτερο κεφάλαιο γίνεται μία βιβλιογραφική ανασκόπηση σε αντίστοιχες μελέτες που έχουν μελετήσει σε κάποιο βαθμό την μεθόδους και μοντέλα πρόβλεψης ιονοσφαιρικής δραστηριότητας

Στο τρίτο κεφάλαιο αναφέρονται κάποια γενικά στοιχεία το παγκόσμιο σύστημα προσδιορισμού θέσης, για την ατμόσφαιρα της Γης και αναλύεται η ιονόσφαιρα, το ιονοσφαιρικό σφάλμα και πως αυτό επηρεάζει το δορυφορικό σήμα GNSS. Επίσης αναλύονται οι παράμετροι που επηρεάζουν την ιονοσφαιρική δραστηριότητα και αναλύεται η έννοια των δεδομένων TEC.

Στο τέταρτο κεφάλαιο πραγματοποιείται επιγραμματική ανάλυση της τεχνητής νοημοσύνης και ειδικότερα ανασκόπηση μοντέλων βαθιάς μάθησης.

Στο πέμπτο κεφάλαιο γίνεται μνεία στη γλώσσα προγραμματισμού Python και αναλύεται λεπτομερώς ο κώδικας του λογισμικού που συντάχθηκε για την επίλυση του προβλήματος

Στο έκτο κεφάλαιο παρατίθενται τα πειραματικά δεδομένα που χρησιμοποιήθηκαν για την επίλυση του θέματος και αναλύεται η επεξεργασία που απαιτήθηκε να γίνει σε αυτά.

Στο έβδομο κεφάλαιο αναλύονται και αξιολογούνται το σενάρια επιλογής υπερπαραμέτρων.

Στο όγδοο κεφάλαιο αναδεικνύεται το βέλτιστο εκ των σεναρίων.

Τέλος, στα παραρτήματα παρατίθενται το σύνολο των δεδομένων καθώς και ο κώδικας του προγράμματος που συντάχθηκε.

Βιβλιογραφική ανασκόπηση

Προτού εισαχθούμε και εντρυφήσουμε στο θεωρητικό υπόβαθρο, στο παρόν κεφάλαιο παρατίθεται μια βιβλιογραφική ανασκόπηση. Μέσω αυτής της σύντομης εξέτασης μεθόδων αντιμετώπισης πρόβλεψης της ιονοσφαιρικής δραστηριότητας, θα αποκτήσουμε μια πιο σφαιρική άποψη επί του θέματος, οπότε θα είμαστε σε θέση να κατανοήσουμε καλύτερα τη φυσική ροή της παρούσας μελέτης.

2.1 Απόδοση διαφορετικών μοντέλων TEC για την παροχή ιονοσφαιρικών διορθώσεων GPS

Η ύπαρξη ενός παγκόσμιου μόνιμου δικτύου δεκτών διπλής συχνότητας της διεθνούς υπηρεσίας GPS (IGS) καθιστά εφικτό τον υπολογισμό παγκόσμιων ιονοσφαιρικών χαρτών (GIM) του συνολικού περιεχομένου ηλεκτρονίων (TEC). Οι GIMs που υπολογίζονται από τα συνεργαζόμενα κέντρα ανάλυσης IGS σε καθημερινή βάση και από άλλα είδη GIMs πρόβλεψης, τα οποία μπορούν να υπολογιστούν, για παράδειγμα, από το διεθνές μοντέλο ιονόσφαιρας αναφοράς (IRI) και τα μοντέλα εκπομπής GPS στο μήνυμα πλοήγησης, μπορούν να εφαρμοστούν σε μια ευρεία ποικιλία τομέων, όπως, για παράδειγμα, η πλοήγηση και η μεταφορά χρόνου.

Σε αυτό το πλαίσιο, παρουσιάζονται οι επιδόσεις των διαφόρων ειδών μοντέλων [1], προκειμένου να προσδιοριστεί η ακρίβεια των διαφόρων GIM. Αυτό πραγματοποιείται με σύγκριση με τα δεδομένα TOPEX που παρέχουν έναν ανεξάρτητο και ακριβή (σε επίπεδο λίγων TECU) κατακόρυφο προσδιορισμό TEC πάνω από τους ωκεανούς και τις θάλασσες. Έτσι, οι λαμβανόμενες ακρίβειες, όσον αφορά το συνολικό σχετικό σφάλμα, κυμαίνονται από 54% που αντιστοιχεί στο μοντέλο εκπομπής GPS, σε περίπου 41% που αντιστοιχεί στο κλιματολογικό μοντέλο IRI και σε λιγότερο από 30% που αντιστοιχεί στα μοντέλα που βασίζονται σε δεδομένα GPS.

2.2 Εφαρμογή του μετασχηματισμού Hilbert-Huang στη μελέτη μεταβολών της ιονόσφαιρας HILBERT-HUANG transform application in ionospheric variability studies

Σκοπός της συγκεκριμένης μελέτης [2] είναι η εφαρμογή του μετασχηματισμού Hilbert-Huang σε μετρήσεις της παραμέτρου TEC της ιονόσφαιρας με σκοπό τη μελέτη των μεταβολών της κατάστασής της. Τα χρονικά διαστήματα που επιλέγησαν, με βάση κυρίως την ύπαρξη μετρήσεων οι οποίες ελήφθησαν με τη μέθοδο του GPS και τη χρήση 2 συχνοτήτων, αφορούν τις περιόδους 1 έως 28 Φεβρουαρίου 1980 (28

ημέρες), 24 Οκτωβρίου 1990 έως 3 Ιανουαρίου 1991 (72 ημέρες) και 9 Μαΐου 1990 έως 22 Αυγούστου 1990 (106 ημέρες).

Στη μελέτη αυτή γίνεται αναφορά στη δομή της ιονόσφαιρας και στη σύσταση των στρωμάτων της. Στη συνέχεια αναλύονται τα χαρακτηριστικά της διάδοσης HF κυμάτων στην ιονόσφαιρα, δίνονται οι ορισμοί βασικών παραμέτρων της, όπως τα TEC, foF2, εικονικό ύψος h' και διατυπώνονται κάποια θεωρήματα και βασικοί νόμοι που διέπουν τη διάδοση αυτή. Περιγράφονται οι κύριοι παράγοντες που προκαλούν ιονοσφαιρικές μεταβολές και παρατίθενται είδη ιονοσφαιρικών διαταραχών. Γίνεται εκτενής περιγραφή των τύπων των ιονοσφαιρικών radars και αναφέρονται κάποια μοντέλα πρόβλεψης της κατάστασης της ιονόσφαιρας με τη βοήθεια παραμέτρων της.

Αιτιολογείται, καταρχήν, η εισαγωγή μίας νέας μεθόδου επεξεργασίας μη γραμμικών – μη στάσιμων σημάτων, η οποία ονομάζεται μετασχηματισμός Hilbert-Huang. Ακολουθεί η παράθεση, με λεπτομέρεια, της έννοιας της στιγμιαίας συχνότητας, του τρόπου εξαγωγής των συναρτήσεων εγγενούς ρυθμού ταλάντωσης (IMFs) και της εμπειρικής μεθόδου αποσύνθεσης σε συνιστώσες (κλασσική EMD). Δίνονται τρία παραδείγματα εφαρμογής της μεθόδου και τέλος περιγράφονται αναλυτικά τρεις καινούριες παραλλαγές της EMD, η Ensemble EMD στην οποία γίνεται εισαγωγή λευκού θορύβου για την επίλυση του προβλήματος της ανάμιξης των ρυθμών ταλάντωσης, η bivariate EMD στην οποία το σήμα είναι μιγαδικό, αλλά πληροί και κάποιες προϋποθέσεις και τέλος η μέθοδος εισαγωγής σήματος μάσκας μαζί με την EMD για την επίλυση του προβλήματος διαλειπτότητας. Επίσης, ορίζονται και κάποια χαρακτηριστικά μεγέθη τα οποία δύνανται να υπολογιστούν μετά την εφαρμογή του μετασχηματισμού Hilbert – Huang, όπως η στιγμιαία πυκνότητα ενέργειας και το περιθωριακό φάσμα.

Στη συνέχεια γίνεται επεξεργασία μετρήσεων της παραμέτρου TEC της ιονόσφαιρας για τρεις χρονικές περιόδους, όπως αυτές ελήφθησαν από τον σταθμό της Φλωρεντίας στην Ιταλία με τη μέθοδο του GPS. Η επεξεργασία αφορά αρχικά την εφαρμογή του μετασχηματισμού Hilbert – Huang στις τρεις χρονοσειρές με την αντίστοιχη εξαγωγή των συναρτήσεων εγγενούς ρυθμού ταλάντωσης και την αναγνώριση των κυρίαρχων ρυθμών σε κάθε χρονοσειρά. Επίσης, από τα διαγράμματα των παραμέτρων TEC(t), Ap(t), R(t) αναγνωρίζονται ο αριθμός και το είδος των ιονοσφαιρικών καταιγίδων που έλαβαν χώρα στις εν λόγω περιόδους, καθώς και ο ρυθμός ταλάντωσης που κυριάρχησε κατά την περίοδο της κάθε καταιγίδας. Στη συνέχεια κατασκευάζεται το διάγραμμα στιγμιαίας πυκνότητας ενέργειας και το διάγραμμα περιθωριακού φάσματος.

Ο συνδυασμός του φάσματος Hilbert και του περιθωριακού φάσματος δίνει πληροφορίες, όχι μόνο για την ταυτότητα των κυρίαρχων IMFs μέσα στα χρονικά διαστήματα της χρονοσειράς, αλλά και για την κατάσταση της ιονόσφαιρας μέσω του προφίλ των παραμέτρων TEC, Ap και R όπως αυτό διαμορφώνεται από τις μεταβολές

τους. Στο τέλος αναφέρονται συνοπτικά τα συμπεράσματα που προέκυψαν από την επεξεργασία των δεδομένων.

2.3 Σύγκριση και έρευνα συνέπειας περιφερειακών μοντέλων ιονοσφαιρικής TEC με βάση μετρήσεις GPS

Οι πληροφορίες TEC από μετρήσεις GPS για όλο το έτος 2004 σε περισσότερους από 40 σταθμούς συνεχούς λειτουργίας πάνω από την Κίνα επιλύονται, και αυτά τα δεδομένα TEC μοντελοποιούνται με τρία κοινώς χρησιμοποιούμενα περιφερειακά μοντέλα:

- το μοντέλο poly (Poly),
- το μοντέλο τριγωνομετρικής σειράς (TRI) και
- το μοντέλο σφαιρικής συνάρτησης χαμηλού βαθμού (LSF).

Τα αποτελέσματα της εν λόγω έρευνας [3], δείχνουν ότι τα μοντέλα Poly και LSF είναι συνεπή με το μοντέλο GIM(CODE), αλλά το πρώτο υποβαθμίζεται από την οριακή επίδραση, και το μοντέλο TRI έχει αξιοσημείωτη μεροληψία προς το μοντέλο GIM, το οποίο μας προειδοποιεί ότι αυτό το μοντέλο δεν είναι κατάλληλο για την περιοχή, μόνο για το τοπικό. Επιπλέον, η ακρίβεια στην περιοχή υψηλού γεωγραφικού πλάτους είναι καλύτερη από εκείνη στην περιοχή χαμηλότερου γεωγραφικού πλάτους.

2.4 Μελέτη της ιονόσφαιρας στην Ελλάδα μέσω της επεξεργασίας παρατηρήσεων GPS

Η συγκεκριμένη μελέτη [4] έχει ως αντικείμενο τη μελέτη της ιονόσφαιρας πάνω από τον ελλαδικό χώρο. Η προσέγγιση γίνεται μέσω της επεξεργασίας παρατηρήσεων GPS , από την οποία δημιουργούνται ιονοσφαιρικά μοντέλα προσαρμοσμένα κατά το δυνατόν καλύτερα στην Ελλάδα. Το θέμα αντιμετωπίζεται σε δύο επίπεδα. Στο πρώτο μέρος διατυπώνεται το θεωρητικό πλαίσιο πάνω στο οποίο βασίζεται η μελέτη αυτή, ενώ στο δεύτερο παραθέτονται τα αποτελέσματα της μελέτης και διατυπώνονται τα συμπεράσματα για την ιονόσφαιρα πάνω από την Ελλάδα. Αρχικά γίνεται μια προσπάθεια να προσεγγιστεί ολοκληρωμένα το θέμα της ιονόσφαιρας. Ορίζεται η έννοια και παρατίθενται τα χαρακτηριστικά στοιχεία που την περιγράφουν και στη συνέχεια μελετώνται οι παράμετροι που επηρεάζουν την πυκνότητα και την κατανομή των ιόντων. Παρουσιάζονται, επιπλέον, οι συχνότερες ιονοσφαιρικές ανωμαλίες που έχουν παρατηρηθεί. Τέλος, γίνεται αναφορά σε τρεις ιδιαιτέρως σημαντικές υπηρεσίες για το GPS , την IGS , την EUREF και τη NOA . Έπιτα περιγράφεται η διαδικασία παραγωγής αρχείων IONEX (IONosphere EXchange), η χρησιμότητα αυτών των αρχείων, τι πληροφορίες παρέχουν και πως συμβάλλουν

στη μελέτη και την κατανόηση της ιονόσφαιρας και των φαινομένων που παρατηρούνται σ' αυτή. Ακολουθως γίνεται μία προσέγγιση της φιλοσοφίας του GPS επισημαίνοντας παράλληλα και κάποιες από τις βασικές αρχές της λειτουργίας του. Επιπλέον, παρατίθενται και αναλύονται τα σφάλματα που υπεισέρχονται στις μετρήσεις με GPS. Γίνεται ειδική μνεία στις τοπογραφικές εφαρμογές που μπορούν να γίνουν με τη χρήση του. Στο τέταρτο κεφάλαιο παρουσιάζεται η διαδικασία που ακολουθήθηκε, ώστε τελικά να παραχθούν τα αρχεία IONEX. Για το σκοπό αυτό δημιουργήθηκε ένα δίκτυο δορυφορικού εντοπισμού για το προσδιορισμό της θέσης τεσσάρων μόνιμων σταθμών, επιλεγμένων έτσι ώστε να περιβάλλουν την Ελλάδα. Καταληκτικά καταγράφονται και αξιολογούνται τα αποτελέσματα IONEX που παρήχθησαν από την επεξεργασία που προηγήθηκε. Τέλος συνοψίζονται τα συμπεράσματα που εξήχθησαν από τη μελέτη της ελλαδικής ιονόσφαιρας.

2.5 Υλοποίηση υβριδικού αλγορίθμου πρόβλεψης ιονοσφαιρικού TEC με χρήση της μεθόδου PCA-NN

Η πρόβλεψη του ιονοσφαιρικού διαστημικού καιρού είναι ζωτικής σημασίας για τη βελτίωση της ακρίβειας των παγκόσμιων δορυφορικών συστημάτων πλοήγησης (GNSS). Ωστόσο, η κατανόηση της ανομοιογενούς ιονοσφαιρικής μεταβλητότητας υπό διαστημικές γήινες περιβαλλοντικές συνθήκες αποτελεί μεγάλη πρόκληση, όπως και η ανάπτυξη ενός ακριβούς μοντέλου ιονοσφαιρικής πρόβλεψης. Οι πολύπλοκες χωρικές και χρονικές μεταβολές στην περιοχή της ιονόσφαιρας είναι αποτέλεσμα των ηλιακών και διαπλανητικών δραστηριοτήτων, εκτός από τις διεργασίες της μαγνητόσφαιρας, της μεσόσφαιρας, της θερμόσφαιρας, της στρατόσφαιρας, της τροπόσφαιρας και της λιθόσφαιρας. Έτσι, αυτό απαιτεί την επείγουσα ανάγκη ανάπτυξης ενός κατάλληλου αλγορίθμου πρόβλεψης της ιονόσφαιρας για την καταγραφή των ιονοσφαιρικών διαταραχών. Η συνολική περιεκτικότητα σε ηλεκτρόνια (TEC) είναι η βασική παράμετρος που προκύπτει από τους δέκτες GNSS για την αναπαράσταση της κατάστασης της ιονόσφαιρας. Σε αυτή τη μελέτη [5] παρουσιάζεται ένας νέος αλγόριθμος ιονοσφαιρικής πρόβλεψης που βασίζεται στη συγχώνευση των μεθόδων ανάλυσης κύριων συνιστωσών και τεχνητών νευρωνικών δικτύων (PCA-NN) για την πρόβλεψη των τιμών της ιονοσφαιρικής TEC. Χρησιμοποιήθηκαν ο ηλιακός δείκτης (F10.7), ο γεωμαγνητικός δείκτης (δείκτης Ap) και δεδομένα TEC 20 ετών (1997-2016) πάνω από ένα σημείο πλέγματος της Ιαπωνίας (34,95 °N και 134,05 °E) για την εφαρμογή μεθοδολογιών τεχνητής νοημοσύνης. Τα πειραματικά αποτελέσματα υπογραμμίζουν την αξιοπιστία του προτεινόμενου αλγορίθμου στην πρόβλεψη των επιπτώσεων της ιονοσφαιρικής χρονικής καθυστέρησης.

Συστήματα GNSS & Ατμόσφαιρα

3.1 Συστήματα GNSS


3.1.1 Η ανάπτυξη των συστημάτων

Τα παγκόσμια δορυφορικά συστήματα πλοήγησης (Global Navigation Satellite System) [6] αναπτύχθηκαν αρχικά από την Πολεμική Αεροπορία των ΗΠΑ, όταν η τεχνολογία ονομαζόταν Global Positioning System, ή GPS, και μπορούσε να χρησιμοποιηθεί μόνο από τον αμερικανικό στρατό. Με την πάροδο του χρόνου, η τεχνολογία GPS έγινε διαθέσιμη σε όλους σε αυτόν τον πλανήτη. Τώρα που κάθε smartphone εξοπλισμένο με GPS είναι εύκολα προσβάσιμο σε όλους. Οι κυβερνήσεις αρκετών χωρών αποφάσισαν να οδηγήσουν αυτήν την τεχνολογία σε ένα πιο προηγμένο, ακριβές και μακροπρόθεσμο επίπεδο. Έτσι, η εμφάνιση παγκόσμιων δορυφορικών συστημάτων πλοήγησης ή GNSS έχει γίνει επίσημο φαινόμενο για τους καταναλωτές του ιδιωτικού τομέα.

Επί του παρόντος, εκτός από τις Ηνωμένες Πολιτείες, το GLONASS της Ρωσίας και το Galileo της Ευρωπαϊκής Ένωσης είναι τα δύο κύρια επιχειρησιακά GNSS που λειτουργούν στην επιφάνεια του πλανήτη μας. Με την έλευση της τεχνολογίας GNSS, άρχισαν να λειτουργούν πολλές βοηθητικές τεχνολογίες, γνωστές ως Regional Navigation Systems. Η τεχνολογική ιδέα είναι η ίδια με αυτή του GNSS, αλλά καλύπτει λιγότερες γεωγραφικές περιοχές.


3.1.2 Δορυφορικός εντοπισμός και πλοήγηση.

Ο δορυφορικός εντοπισμός βασίζεται στην ιδέα της μέτρησης του μήκους προς ένα αντικείμενο που βρίσκεται και κινείται σε συγκεκριμένη τροχιά (γνωστές συντεταγμένες) μακριά από τη γη σε απόσταση περίπου 20.000 χιλιόμετρα και το οποίο ονομάζεται δορυφόρος. Με άλλα λόγια οι δορυφόροι λειτουργούν ως σημεία αναφοράς στο χώρο, δηλαδή σημεία γνωστών συντεταγμένων. Η θέση ενός σημείου στη γη, προσδιορίζεται με μετρήσεις των μηκών από την κεραία του δέκτη προς τουλάχιστον τέσσερις δορυφόρους. Η μέτρηση των μηκών γίνεται είτε με τον υπολογισμό ψευδοαποστάσεων, είτε με τον προσδιορισμό ασάφειας φάσης (initialization). Ο υπολογισμός της ψευδοαπόστασης βασίζεται στην παρατήρηση της ψευδοαπόστασης μέσω της συσχέτισης κωδίκων του δορυφόρου και του δέκτη.



Εικόνα 1. Συσχέτιση κωδίκων.

Όσον αφορά τον προσδιορισμό της ασάφειας φάσης, ο δέκτης του συστήματος μπορεί να μετρήσει με ακρίβεια τη στιγμιαία κλασματική φάση του φέροντος κύματος τη στιγμή της λήψης του σήματος με ακρίβεια περίπου 1mm. (phase shift). Δεν μπορεί όμως να μετρήσει τον ακέραιο αριθμό κύκλων (μήκη κύματος) που μεσολαβούν από τον δορυφόρο μέχρι τον δέκτη. Έτσι στο μέγεθος που μετράται πρέπει να προστεθεί ο ακέραιος αριθμός n των μηκών κύματος. Ο άγνωστος αυτός αριθμός ονομάζεται ασάφεια φάσης, με τον προσδιορισμό της οποίας μας οδηγεί στον υπολογισμό απόστασης δορυφόρου – δέκτη.



Εικόνα 2. Παρατήρηση φάσης.

Διακρίνεται μια σειρά σφαλμάτων, συστηματικού κυρίως χαρακτήρα, που επηρεάζουν τον προσδιορισμό θέσης. Τα τυχαία σφάλματα (random errors), που προφανώς είναι αναπόφευκτα, κατά την εκτέλεση των μετρήσεων, ονομάζονται και ως θόρυβος (white noise). Τα συστηματικά σφάλματα σχετίζονται με τους δορυφόρους είτε τους δέκτες, είτε με τη διάδοση του σήματος. Τα τελευταία είναι αυτά που μας αφορούν στην εκπόνηση της παρούσας, καθώς μελετάμε την πρόβλεψη της ιονοσφαιρικής δραστηριότητας.

Μεταξύ όλων των άλλων τεχνολογιών, η έννοια του GNSS είχε σημαντικό αντίκτυπο στην τεχνολογία πλοήγησης. Πρόσφατα, το GNSS ενσωματώθηκε στην αυτοκινητοβιομηχανία. Η ενσωμάτωση της τεχνολογίας GNSS βοηθά τον οδηγό να περιηγηθεί εύκολα σε άγνωστες διαδρομές για να εξερευνήσει τους δρόμους του κόσμου. Η χρήση του GNSS στα συστήματα πλοήγησης δεν περιορίζεται στα αυτοκίνητα, καθώς η τεχνολογία χρησιμοποιείται πλέον ευρέως και στα αεροσκάφη.

Η προκαταρκτική χαρτογράφηση του εδάφους και η ενημέρωση του εδάφους σε πραγματικό χρόνο από το GNSS επιτρέπουν στους πιλότους να αποφεύγουν συγκρούσεις στην εναέρια κυκλοφορία. Σαφώς πέραν των οχημάτων και τον αεροσκαφών που αναφέρθηκαν ως παραδείγματα εφαρμογών πλοήγησης, τα συστήματα GNSS έχουν εφαρμογή στην πλοήγηση για κάθε κινητό, αφού είναι εφικτός ο δυναμικός εντοπισμός θέσης.

3.2 Ατμόσφαιρα


3.2.1 Εισαγωγικά

Η ατμόσφαιρα [7] είναι ένα στρώμα αερίων που περιβάλλει έναν πλανήτη ή άλλο υλικό σώμα και συγκρατείται από τη βαρύτητα του σώματος. Με τον όρο ατμόσφαιρα της Γης εννοούμε το αέριο στρώμα που περιβάλλει τον πλανήτη Γη και συγκρατείται λόγω της βαρύτητάς της. Η ατμόσφαιρα της Γης αποτελείται από άζωτο (78%), οξυγόνο (21%), αργό (0,9%), διοξείδιο του άνθρακα (0,04%) και ιχνοαέρια. Το όριο ανάμεσα στην ατμόσφαιρα και το διάστημα δεν είναι αυστηρά καθορισμένο. Όσο μεγαλώνει η απόσταση της από τη Γη η ατμόσφαιρα σταδιακά εξασθενεί.

Η πολυεπίπεδη σύνθεση της ατμόσφαιρας ελαχιστοποιεί τις βλαβερές επιπτώσεις του ηλιακού φωτός, της υπεριώδους ακτινοβολίας, του ηλιακού ανέμου και των κοσμικών ακτίνων για την προστασία των οργανισμών από γενετικές βλάβες. Η σημερινή σύνθεση της ατμόσφαιρας της Γης είναι προϊόν δισεκατομμυρίων ετών βιοχημικής τροποποίησης του.

3.2.1 Διαίρεση της ατμόσφαιρας σε στρώματα

Καθώς απομακρυνόμαστε από τη φυσική γήινη επιφάνεια, συναντάμε τα διαφορετικά στρώματα που έχει η ατμόσφαιρα. Το καθένα με τη σύνθεση, την πυκνότητα και τη λειτουργία του. Η ατμόσφαιρα έχει πέντε στρώματα:



- την τροπόσφαιρα,
- τη στρατόσφαιρα,
- τη μεσόσφαιρα,
- τη θερμόσφαιρα - ιονόσφαιρα και
- την εξώσφαιρα

Παράλληλα, μεταξύ των περιοχών αυτών, διακρίνονται και κάποιες μεταβατικές ζώνες, οι οποίες είναι:

- Τροπόπαυση (Tropopause)
- Στρατόπαυση (Stratopause)
- Μεσόπαυση (Mesopause)

Εικόνα 3. Διαίρεση της ατμόσφαιρας σε στρώματα.

Μπορούμε να διακρίνουμε και ένα έκτο στρώμα μετά την εξώσφαιρα, την μαγνητόσφαιρα.

➤ Τροπόσφαιρα (TROPOSPHERE):

Η τροπόσφαιρα αποτελεί το κατώτερο ατμοσφαιρικό στρώμα και εκτείνεται από την επιφάνεια της Γης μέχρι και περίπου τα 12 ± 4 km, με τη θερμοκρασία μέσα στην τροπόσφαιρα να μειώνεται με το ύψος. Τονίζεται ότι η τροπόσφαιρα περιλαμβάνει το 75% της μάζας ολόκληρης της ατμόσφαιρας, ενώ παράλληλα περιλαμβάνει σχεδόν ολόκληρη την ποσότητα των υδρατμών και γι' αυτό τον λόγο αποτελεί το πιο σημαντικό στρώμα της ατμόσφαιρας, αφού μέσα σε αυτή συμβαίνουν σχεδόν όλα τα μετεωρολογικά φαινόμενα που παρατηρούμε.

➤ Τροπόπαυση (TROPopause):

Η τροπόπαυση αποτελεί το διαχωριστικό στρώμα μεταξύ της τροπόσφαιρας και της στρατόσφαιρας και είναι σχεδόν ισόθερμη (δηλαδή η θερμοκρασία δεν παρουσιάζει αξιόλογη μεταβολή με το ύψος). Το ύψος της τροπόπαυσης διαφοροποιείται ανάλογα με το γεωγραφικό πλάτος, με αποτέλεσμα στις τροπικές περιοχές ($0-30^\circ$) η τροπόπαυση να βρίσκεται γύρω στα 14-16 χιλιόμετρα ύψος, ενώ στις εύκρατες/πολικές περιοχές ($40-90^\circ$) να βρίσκεται γύρω στα 7-12 χιλιόμετρα ύψος. Επίσης, το ύψος της τροπόπαυσης μεταβάλλεται βάσει των ατμοσφαιρικών συνθηκών (κυκλωνικών ή αντικυκλωνικών) που επικρατούν πάνω από μια περιοχή, με την τροπόπαυση να βρίσκεται σε μεγαλύτερα ύψη όταν επικρατούν αντικυκλωνικές συνθήκες, αλλά και βάσει της εποχής, αφού η τροπόπαυση γενικότερα βρίσκεται σε υψηλότερο ύψος το καλοκαίρι και σε χαμηλότερο τον χειμώνα, σε όλα τα γεωγραφικά πλάτη. Η θερμοκρασία της τροπόπαυσης κυμαίνεται από περίπου -55 μέχρι -80 βαθμούς Κελσίου και προφανώς η θερμοκρασία της στις τροπικές περιοχές τείνει προς το κατώτερο όριο θερμοκρασίας, αφού η τροπόπαυση βρίσκεται σε υψηλότερο υψόμετρο.

➤ Στρατόσφαιρα (STRATOSPHERE):

Η στρατόσφαιρα αποτελεί το επόμενο ατμοσφαιρικό στρώμα, το οποίο εκτείνεται πάνω από την τροπόπαυση και φτάνει μέχρι περίπου τα 50 χιλιόμετρα ύψος. Η στρατόσφαιρα μπορεί να χωριστεί στην κατώτερη στρατόσφαιρα (μέχρι περίπου το ύψος των 35 χιλιομέτρων) και στην ανώτερη στρατόσφαιρα (ύψος άνω των 35 χιλιομέτρων και μέχρι περίπου τα 50 χιλιόμετρα). Η θερμοκρασία του αέρα από το ύψος της τροπόπαυσης μέχρι και περίπου τα 20 χιλιόμετρα ύψος δεν παρουσιάζει αξιόλογη μεταβολή, ενώ στη συνέχεια η θερμοκρασία αρχίζει να αυξάνει με το ύψος, μέχρι να φτάσει στους 0°C στο ανώτατο σημείο της στρατόσφαιρας. Λόγω του ότι η θερμοκρασία στα πρώτα χιλιόμετρα της στρατόσφαιρας είναι εξαιρετικά χαμηλή (-40 με -50 βαθμούς Κελσίου) και δεν μεταβάλλεται, το κύριο χαρακτηριστικό της

κατώτερης στρατόσφαιρας είναι οι ξηρές συνθήκες, αφού δεν επιτρέπεται η παρουσία υδρατμών σε σημαντικές ποσότητες. Η αύξηση της θερμοκρασίας καθ' ύψος, που παρατηρείται κυρίως από τα 20 χιλιόμετρα ύψος και άνω, οφείλεται στις υψηλές συγκεντρώσεις όζοντος (O_3) που παρατηρούνται στα 15-35 χιλιόμετρα ύψος, αφού αυτό απορροφά έντονα την υπεριώδη ακτινοβολία με μήκη κύματος μεταξύ 200-300nm.

➤ Στρατόπαυση (STRATOPAUSE):

Η στρατόπαυση αποτελεί τη διαχωριστική ζώνη μεταξύ στρατόσφαιρας και μεσόσφαιρας και, από θερμοκρασιακής άποψης, χαρακτηρίζεται σχεδόν ισόθερμη όπως και την τροπόπαυση. Στο ύψος της στρατόπαυσης ο αέρας είναι πάρα πολύ αραιός και η τιμή της ατμοσφαιρικής πίεσης κυμαίνεται γύρω στο 1mbar περίπου. Να σημειώσουμε ότι από την επιφάνεια του εδάφους μέχρι και το ύψος της στρατόπαυσης, βρίσκουμε το 99% όλης της ατμοσφαιρικής μάζας.

➤ Μεσόσφαιρα – μεσόπαυση (MESOSPHERE – MESOPAUSE):

Η μεσόσφαιρα εκτείνεται πάνω από τη στρατόπαυση και φτάνει μέχρι τα 80 χιλιόμετρα ύψος περίπου. Το κύριο χαρακτηριστικό της μεσόσφαιρας είναι η σημαντική ελάττωση της θερμοκρασίας καθ' ύψος, η οποία φτάνει γύρω στους -80 με -90 βαθμούς Κελσίου στο ανώτατο όριο της μεσόσφαιρας (την μεσόπαυση), κάτι που αποτελεί και την πιο ψυχρή περιοχή της ατμόσφαιρας. Αυτή η σημαντική ελάττωση της θερμοκρασίας οφείλεται κατά κύριο λόγο στην απουσία όζοντος μέσα σε αυτό το ατμοσφαιρικό στρώμα.

➤ Θερμόσφαιρα (THERMOSPHERE):

Η θερμόσφαιρα εκτείνεται από τη μεσόπαυση μέχρι το ύψος των 400 χιλιομέτρων περίπου. Η θερμοκρασία της θερμόσφαιρας ποικίλλει μεταξύ νύχτας και ημέρας και μεταξύ των εποχών, όπως και ο αριθμός των ιόντων και των ηλεκτρονίων που υπάρχουν.

Στην περιοχή της ατμόσφαιρας πάνω από περίπου 80 χιλιόμετρα προκαλείται επίσης η «ιονόσφαιρα», αφού η ενεργειακή ηλιακή ακτινοβολία χτυπά τα ηλεκτρόνια από τα μόρια και τα άτομα, μετατρέποντάς τα σε «ιόντα» με θετικό φορτίο. Η ύπαρξη αυτών των ελευθέρων ιόντων, όπως θα διαπιστώσουμε παρακάτω είναι ιδιαίτερης σημασίας. Η ιονόσφαιρα επίσης αντανακλά και απορροφά ραδιοκύματα, επιτρέποντάς μας να λαμβάνουμε ραδιοφωνικές εκπομπές βραχέων κυμάτων στη Νέα Ζηλανδία από άλλα μέρη του κόσμου.

➤ Εξώσφαιρα (EXOSPHERE)

Η εξώσφαιρα εκτείνεται από το ύψος της θερμόπαυσης και άνω (γύρω στα 400-500 χιλιόμετρα ύψος). Παρόλο που κάποιοι ειδικοί θεωρούν πως η θερμόσφαιρα αποτελεί το υψηλότερο ατμοσφαιρικό στρώμα, εντούτοις αρκετοί θεωρούν πως η εξώσφαιρα αποτελεί το τελικό ατμοσφαιρικό στρώμα. Ο αέρας σε αυτό το ύψος είναι

εξαιρετικά αραιός και ξεφεύγει με πάρα πολύ αργούς ρυθμούς προς το διάστημα. Να τονίσουμε ότι δεν υπάρχει κάποιο συγκεκριμένο ανώτατο όριο στο οποίο η εξώσφαιρα τελικά «σβήνει» προς το διάστημα, αλλά διάφορες θεωρίες ορίζουν ως ανώτατο σημείο της εξώσφαιρας το ύψος των 10.000 χιλιομέτρων πάνω από την επιφάνεια της Γης.

➤ Η Μαγνητόσφαιρα

Η γη συμπεριφέρεται σαν ένας τεράστιος μαγνήτης. Παγιδεύει ηλεκτρόνια (αρνητικό φορτίο) και πρωτόνια (θετικά), συγκεντρώνοντάς τα σε δύο ζώνες περίπου 3.000 και 16.000 km πάνω από την υδρόγειο - τις ζώνες «ακτινοβολίας» Van Allen. Αυτή η εξωτερική περιοχή που περιβάλλει τη γη, όπου τα φορτισμένα σωματίδια κινούνται σπειροειδώς κατά μήκος των γραμμών του μαγνητικού πεδίου, ονομάζεται μαγνητόσφαιρα.

3.3 Η Ιονόσφαιρα και τα στρώματά της

3.3.1 Εισαγωγικές Έννοιες

Η ιονόσφαιρα [8] είναι το ιονισμένο τμήμα της ανώτερης ατμόσφαιρας της Γης, από περίπου 48 km (30 mi) έως 965 km (600 mi) υψόμετρο, μια περιοχή που περιλαμβάνει τη θερμόσφαιρα και μέρη της μεσόσφαιρας και της εξώσφαιρας. Η ιονόσφαιρα ιονίζεται από την ηλιακή ακτινοβολία. Παίζει σημαντικό ρόλο στον ατμοσφαιρικό ηλεκτρισμό και σχηματίζει το εσωτερικό άκρο της μαγνητόσφαιρας. Έχει πρακτική σημασία γιατί, μεταξύ άλλων λειτουργιών, επηρεάζει τη διάδοση του ραδιοφώνου σε μακρινά μέρη της Γης.

3.3.2 Τα στρώματα της ιονόσφαιρας και τα χαρακτηριστικά τους

Υπάρχουν τρεις κύριες περιοχές της ιονόσφαιρας, που ονομάζονται στρώμα D, στρώμα E και στρώμα F. Αυτές οι περιοχές δεν έχουν έντονα όρια και τα υψόμετρα στα οποία εμφανίζονται ποικίλλουν κατά τη διάρκεια μιας ημέρας και από εποχή σε εποχή. Η περιοχή D είναι η χαμηλότερη, ξεκινά περίπου 60 ή 70 km (37 ή 43 μίλια) πάνω από το έδαφος και εκτείνεται προς τα πάνω σε περίπου 90 km (56 μίλια). Στη συνέχεια υψηλότερη είναι η περιοχή A, ξεκινώντας από περίπου 90 ή 100 km (56 ή 62 μίλια) και εκτείνεται στα 120 ή 150 km (75 ή 93 μίλια). Το ανώτερο τμήμα της ιονόσφαιρας, η περιοχή F, ξεκινά περίπου 150 km (93 μίλια) και εκτείνεται πολύ προς τα πάνω, μερικές φορές έως και 500 km (311 μίλια) πάνω από την επιφάνεια του πλανήτη μας.

Οι περιοχές της ιονόσφαιρας δεν θεωρούνται ξεχωριστά στρώματα, όπως η πιο οικεία τροπόσφαιρα και στρατόσφαιρα. Αντίθετα, είναι ιονισμένες περιοχές ενσωματωμένες στα τυπικά ατμοσφαιρικά στρώματα. Η περιοχή D συνήθως σχηματίζεται στο πάνω μέρος της μεσόσφαιρας, ενώ η περιοχή E εμφανίζεται

συνήθως στην κάτω θερμόσφαιρα και η περιοχή F βρίσκεται στο ανώτερο τμήμα της θερμόσφαιρας.

Τη νύχτα το στρώμα F είναι το μόνο στρώμα σημαντικού ιονισμού που υπάρχει, ενώ ο ιονισμός στα στρώματα E και Δ είναι εξαιρετικά χαμηλός. Κατά τη διάρκεια της ημέρας, τα στρώματα D και E ιονίζονται πολύ πιο έντονα, όπως και το στρώμα F, το οποίο αναπτύσσει μια πρόσθετη, ασθενέστερη περιοχή ιονισμού γνωστή ως στρώμα F1. Το στρώμα F2 παραμένει μέρα και νύχτα και είναι η κύρια περιοχή που είναι υπεύθυνη για τη διάθλαση και την ανάκλαση των ραδιοκυμάτων.

D στρώμα

Το στρώμα D είναι το πιο εσωτερικό στρώμα, 48 km (30 mi) έως 90 km (56 mi) πάνω από την επιφάνεια της Γης. Ο ιονισμός εδώ οφείλεται στην ακτινοβολία υδρογόνου σειράς άλφα Lyman σε μήκος κύματος 121,6 νανόμετρων (nm) ιονίζοντας μονοξειδίου του αζώτου (NO). Επιπλέον, η υψηλή ηλιακή δραστηριότητα μπορεί να δημιουργήσει σκληρές ακτίνες X (μήκος κύματος < 1 nm) που ιονίζουν N₂ και O₂. Οι ρυθμοί ανασυνδυασμού είναι υψηλοί στο στρώμα D, επομένως υπάρχουν πολύ περισσότερα ουδέτερα μόρια αέρα από ιόντα.

Τα ραδιοκύματα μέσης συχνότητας (MF) και χαμηλότερης υψηλής συχνότητας (HF) εξασθενούν σημαντικά εντός του στρώματος D, καθώς τα ραδιοκύματα που περνούν προκαλούν την κίνηση των ηλεκτρονίων, τα οποία στη συνέχεια συγκρούονται με τα ουδέτερα μόρια, δίνοντας την ενέργειά τους. Οι χαμηλότερες συχνότητες έχουν μεγαλύτερη απορρόφηση επειδή μετακινούν τα ηλεκτρόνια μακρύτερα, οδηγώντας σε μεγαλύτερες πιθανότητες συγκρούσεων. Αυτός είναι ο κύριος λόγος για την απορρόφηση των ραδιοκυμάτων HF, ιδιαίτερα στα 10 MHz και κάτω, με προσθετικά μικρότερη απορρόφηση σε υψηλότερες συχνότητες. Αυτό το φαινόμενο κορυφώνεται γύρω στο μεσημέρι και μειώνεται τη νύχτα λόγω της μείωσης του πάχους του στρώματος D. μόνο ένα μικρό μέρος παραμένει λόγω των κοσμικών ακτίνων. Ένα συνηθισμένο παράδειγμα του επιπέδου D σε δράση είναι η εξαφάνιση των απομακρυσμένων σταθμών ζώνης εκπομπής AM κατά τη διάρκεια της ημέρας. Κατά τη διάρκεια γεγονότων ηλιακών πρωτονίων, ο ιονισμός μπορεί να φτάσει σε ασυνήθιστα υψηλά επίπεδα στην περιοχή D σε μεγάλα και πολικά γεωγραφικά πλάτη. Τέτοια πολύ σπάνια συμβάντα είναι γνωστά ως συμβάντα απορρόφησης πολικού πώματος (ή PCA), επειδή ο αυξημένος ιονισμός ενισχύει σημαντικά την απορρόφηση των ραδιοφωνικών σημάτων που διέρχονται από την περιοχή. Στην πραγματικότητα, τα επίπεδα απορρόφησης μπορούν να αυξηθούν κατά πολλές δεκάδες dB κατά τη διάρκεια έντονων γεγονότων, κάτι που είναι αρκετό για να απορροφήσει τις περισσότερες (αν όχι όλες) διαπολικές μεταδόσεις ραδιοφωνικού σήματος HF. Τέτοια συμβάντα διαρκούν συνήθως λιγότερο από 24 έως 48 ώρες.

E στρώμα

Το στρώμα E είναι το μεσαίο στρώμα, 90 km (60 mi) έως 150 km (90 mi) πάνω από την επιφάνεια της Γης. Ο ιονισμός οφείλεται στον ιονισμό του μοριακού οξυγόνου (O₂) με μαλακές ακτίνες X (1–10 nm) και μακρινή υπεριώδη (UV) ηλιακή ακτινοβολία.

Κανονικά, σε λοξή πρόσπτωση, αυτό το στρώμα μπορεί να αντανακλά μόνο ραδιοκύματα που έχουν συχνότητες χαμηλότερες από περίπου 10 MHz και μπορεί να συμβάλει λίγο στην απορρόφηση στις παραπάνω συχνότητες. Ωστόσο, κατά τη διάρκεια έντονων σποραδικών συμβάντων E, το στρώμα Es μπορεί να αντανακλά συχνότητες έως και 50 MHz και υψηλότερες. Η κατακόρυφη δομή του στρώματος E καθορίζεται κυρίως από τα ανταγωνιστικά αποτελέσματα του ιονισμού και του ανασυνδυασμού. Τη νύχτα το στρώμα E εξασθενεί επειδή η κύρια πηγή ιονισμού δεν είναι πλέον παρούσα. Μετά τη δύση του ηλίου, μια αύξηση στο ύψος του μέγιστου στρώματος E αυξάνει το εύρος στο οποίο τα ραδιοκύματα μπορούν να ταξιδέψουν με ανάκλαση από το στρώμα.

Αυτή η περιοχή είναι επίσης γνωστή ως στρώμα Kennelly–Heaviside ή απλά στρώμα Heaviside. Η ύπαρξή του προβλέφθηκε το 1902 ανεξάρτητα και σχεδόν ταυτόχρονα από τον Αμερικανό ηλεκτρολόγο μηχανικό Arthur Edwin Kennelly (1861–1939) και τον Βρετανό φυσικό Oliver Heaviside (1850–1925). Το 1924 ότι η ύπαρξή του εντοπίστηκε από τους Edward V. Appleton και Miles Barnett.

Es στρώμα

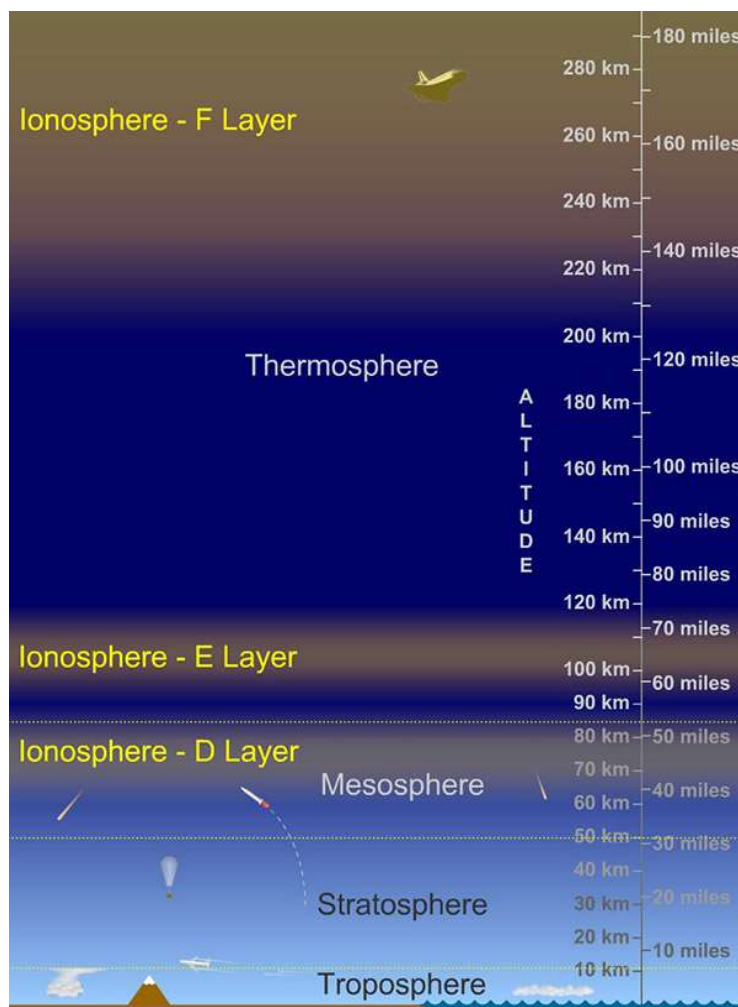
Το στρώμα Es (σποραδικό στρώμα E) χαρακτηρίζεται από μικρά, λεπτά νέφη έντονου ιονισμού, τα οποία μπορούν να υποστηρίξουν την ανάκλαση ραδιοκυμάτων, συχνά έως 50 MHz και σπάνια έως 450 MHz. Τα σποραδικά συμβάντα μπορεί να διαρκέσουν από λίγα λεπτά έως πολλές ώρες. Η σποραδική διάδοση E καθιστά τη λειτουργία VHF από ραδιοερασιτέχνες πολύ συναρπαστική όταν οι διαδρομές διάδοσης μεγάλων αποστάσεων που είναι γενικά απρόσιτες «ανοίγουν» σε αμφίδρομη επικοινωνία. Υπάρχουν πολλές αιτίες του σποραδικού-E που εξακολουθούν να αναζητούνται από τους ερευνητές. Αυτή η διάδοση συμβαίνει καθημερινά τον Ιούνιο και τον Ιούλιο στα μεσαία γεωγραφικά πλάτη του βόρειου ημισφαιρίου, όταν συχνά επιτυγχάνονται υψηλά επίπεδα σήματος. Οι αποστάσεις παράλειψης είναι γενικά περίπου 1.640 km (1.020 mi). Οι αποστάσεις για μια διάδοση λυκίσκου μπορεί να είναι οπουδήποτε από 900 km (560 mi) έως 2.500 km (1.600 mi). Η διάδοση πολλαπλών άλματος πάνω από 3.500 km (2.200 mi) είναι επίσης κοινή, μερικές φορές σε αποστάσεις 15.000 km (9.300 mi) ή περισσότερες.

F Στρώμα

Το στρώμα ή η περιοχή F, επίσης γνωστή ως στρώμα Appleton–Barnett, εκτείνεται από περίπου 150 km (90 mi) σε περισσότερα από 500 km (300 mi) πάνω από την επιφάνεια της Γης. Είναι το στρώμα με την υψηλότερη πυκνότητα ηλεκτρονίων, που σημαίνει ότι τα σήματα που διεισδύουν σε αυτό το στρώμα θα διαφύγουν στο διάστημα. Η παραγωγή ηλεκτρονίων κυριαρχείται από την ακραία υπεριώδη ακτινοβολία (UV, 10–100 nm) που ιονίζει ατομικό οξυγόνο. Το στρώμα F αποτελείται από ένα στρώμα (F2) τη νύχτα, αλλά κατά τη διάρκεια της ημέρας, συχνά σχηματίζεται μια δευτερεύουσα κορυφή (με την ένδειξη F1) στο προφίλ πυκνότητας ηλεκτρονίων. Επειδή το στρώμα F2 παραμένει τη μέρα και τη νύχτα, είναι υπεύθυνο για την πλειονότητα της διάδοσης των κυμάτων ουρανού των ραδιοκυμάτων και των

ραδιοεπικοινωνιών υψηλής συχνότητας μεγάλων αποστάσεων (HF ή βραχέων κυμάτων).

Πάνω από το στρώμα F, ο αριθμός των ιόντων οξυγόνου μειώνεται και τα ελαφρύτερα ιόντα όπως το υδρογόνο και το ήλιο γίνονται κυρίαρχα. Αυτή η περιοχή πάνω από την κορυφή του στρώματος F και κάτω από την πλασμάσφαιρα ονομάζεται ιονόσφαιρα από την κορυφή.



Εικόνα 4. Τα στρώματα της ιονόσφαιρας.

3.4 Οι τιμές TEC (Total Electron Content)

3.4.1 Εισαγωγικές έννοιες

Η συνθήκη ιονόσφαιρας είναι ένα από τα πιο σημαντικά χαρακτηριστικά του διαστημικού καιρού για τους χρήστες συστημάτων που βασίζονται σε ραδιόφωνα, όπως συστήματα πλοήγησης που βασίζονται στο Παγκόσμιο Δορυφορικό Σύστημα Πλοήγησης (GNSS), συστήματα επικοινωνίας υψηλής συχνότητας (HF) και τηλεπισκόπηση με βάση το διάστημα συστήματα. Τα ραδιοκύματα που διαδίδονται στην ιονόσφαιρα παρουσιάζουν καθυστέρηση στην ομαδική ταχύτητα και

προχωρούν στην ταχύτητα φάσης λόγω των ηλεκτρονίων στην ιονόσφαιρα. Η καθυστέρηση της ιονόσφαιρας είναι ανάλογη με το συνολικό περιεχόμενο ηλεκτρονίων της ιονόσφαιρας (TEC) [9], κατά μήκος της διαδρομής διάδοσης, και αντιστρόφως ανάλογη του τετραγώνου της συχνότητας f του φορέα (L1 ή L2). Ο ευκολότερος τρόπος για τη διόρθωση της ιονόσφαιρικής καθυστέρησης είναι η χρήση μοντέλων καθυστέρησης εκπομπής ιονόσφαιρας που βασίζονται σε απλά εμπειρικά μοντέλα TEC όπως τα μοντέλα Klobuchar (1987) και NeQuick (Hochegger et al. 2000, Radicella and Leitinger 2001).

3.4.2 Βασικές αρχές

Η τιμή TEC καθορίζεται από πολλούς παράγοντες, όπως η ηλιακή δραστηριότητα, η εποχή, η τοπική ώρα και η γεωμαγνητική δραστηριότητα. Υπάρχει επίσης γεωγραφική εξάρτηση στις παραλλαγές TEC [9]. Οι διακυμάνσεις του TEC που προκαλούνται από την ηλιακή δραστηριότητα, την εποχή και την τοπική ώρα μπορούν να εκτιμηθούν χρησιμοποιώντας αυτά τα απλά μοντέλα, αλλά αυτές που προκαλούνται από γεωμαγνητικές καταιγίδες και άλλα φαινόμενα δεν μπορούν να αφαιρεθούν πλήρως από αυτά τα μοντέλα. Ως εκ τούτου, οι χρήστες συστημάτων που βασίζονται σε ραδιόφωνα ενδέχεται να επηρεαστούν από θετικές ή/και αρνητικές ιονοσφαιρικές καταιγίδες. Κατά τη διάρκεια αρνητικών ιονοσφαιρικών καταιγίδων, το TEC είναι ≥ 0 TECU ακόμα κι αν η αρνητική καταιγίδα είναι εξαιρετικά σοβαρή. Από την άλλη πλευρά, οι ακραίες τιμές TEC κατά τη διάρκεια θετικών καταιγίδων δεν είναι άγνωστες και πρέπει να μελετηθούν. Μπορεί να μετρηθεί είτε κατακόρυφα είτε λοξά και χαρακτηρίζεται ως VTEC ή STEC αντίστοιχα.

Για το σχεδιασμό και τη λειτουργία συστημάτων που ενδέχεται να επηρεαστούν από διαστημικά καιρικά φαινόμενα, είναι σημαντικό να γνωρίζουμε την πιθανή έκταση της πρόσκρουσης και πόσο συχνά είναι πιθανό να συμβούν τέτοια γεγονότα. Επομένως, είναι σημαντικό να μελετηθούν ακραίες τιμές που σχετίζονται με διάφορα διαστημικά καιρικά φαινόμενα. Για χρήστες ραδιοϊονόσφαιρων συστημάτων, η ακραία τιμή TEC είναι μια βασική τιμή.

Έχουν μελετηθεί ακραίες τιμές ορισμένων παραμέτρων του διαστημικού καιρού. Για παράδειγμα, αυτός του δείκτη Dst διερευνήθηκε χρησιμοποιώντας μοντελοποίηση ακραίων τιμών (Tsubouchi και Omura 2007). Αυτά της ροής ακτίνων X της ηλιακής έκλαμψης, της ταχύτητας εκτόξευσης μάζας στέμματος, του δείκτη Dst και της ενέργειας πρωτονίων σε γεγονότα πρωτονίων μελετήθηκαν από τον Riley (2012) χρησιμοποιώντας συμπληρωματικές συναρτήσεις αθροιστικής κατανομής. Ωστόσο, οι ακραίες τιμές TEC μιας φοράς ανά μεγάλο χρονικό διάστημα δεν έχουν ακόμη εκτιμηθεί ποσοτικά. Αρκετές χώρες έχουν ετοιμάσει έγγραφα με κριτήρια αναφοράς καιρού για το διάστημα. Ο Λευκός Οίκος των ΗΠΑ δημοσίευσε τα «Διαστημικά καιρικά κριτήρια φάσης 1» τον Ιούνιο του 2018 (Λευκός Οίκος ΗΠΑ 2018). Αν και απαριθμεί τρεις παράγοντες που προκαλούν ιονοσφαιρικές διαταραχές, όπως οι

γεωμαγνητικές καταιγίδες, δεν δόθηκαν ποσοτικά κριτήρια αναφοράς επειδή οι ιονόσφαιρες επιδράσεις των γεωμαγνητικών καταιγίδων στην ιονόσφαιρα διαφέρουν σε μεγάλο βαθμό από γεγονός σε γεγονός και ακόμη και ο μηχανισμός τους δεν είναι πλήρως κατανοητός.

Ένας άλλος λόγος για τον οποίο οι ακραίες τιμές TEC δεν έχουν μελετηθεί πλήρως είναι ότι έχουν περάσει μόνο 20 χρόνια από την έναρξη των πλήρως εξελιγμένων παρατηρήσεων TEC. Οι παρατηρήσεις TEC ξεκίνησαν με μετρήσεις της περιστροφής Faraday ή του φαινομένου Doppler πριν από πολλές. Δεδομένου ότι αυτές οι παρατηρήσεις πραγματοποιήθηκαν από λίγους πομπούς και δέκτες, είναι δύσκολο να μελετηθεί η συμπεριφορά του TEC στατιστικά. Με την εξάπλωση του GNSS και των επίγειων δεκτών του, ο αριθμός των παρατηρήσεων TEC αυξήθηκε δραματικά. Χάρη στα συστήματα παρατήρησης GNSS-TEC, μάθαμε πολλά για τη συμπεριφορά του TEC τα τελευταία 20 χρόνια. Ο σκοπός αυτής της μελέτης είναι να εκτιμήσει τις ακραίες τιμές του TEC με τα ποσοστά εμφάνισής τους. Διερευνούμε τα ποσοστά εμφάνισης ακραίων τιμών TEC στην Ιαπωνία βραχυπρόθεσμα, μεσοπρόθεσμα και μακροπρόθεσμα, τα οποία είναι μία φορά το χρόνο, 10 χρόνια και 100 χρόνια, αντίστοιχα.

Για να αξιολογηθεί το TEC που αντιστοιχεί σε ένα ποσοστό εμφάνισης μία φορά ανά 100 χρόνια, τα δεδομένα 20 ετών είναι προφανώς ανεπαρκή. Επιπλέον, η ηλιακή δραστηριότητα τα τελευταία 20 χρόνια ήταν κατά μέσο όρο μέτρια, αν και εμφανίστηκαν αρκετές έντονες γεωμαγνητικές καταιγίδες κατά τη διάρκεια του ηλιακού κύκλου 24. Σε σύγκριση με την παρατήρηση GNSS-TEC, η παρατήρηση ιονοσόνδης έχει πολύ μεγαλύτερη ιστορία. Αυτή η τεχνική αναπτύχθηκε στα τέλη της δεκαετίας του 1920 και άρχισε να εφαρμόζεται στη δεκαετία του 1940 για την παρακολούθηση της διάδοσης βραχέων κυμάτων (Gladden 1959). Στην Ιαπωνία, η παρατήρηση ιονοσόνδης ξεκίνησε το 1931. Μετά από διάφορες αλλαγές, η συνήθης παρατήρηση ιονοσόνδης ξεκίνησε από τον προκάτοχο του Εθνικού Ινστιτούτου Τεχνολογίας Πληροφοριών και Επικοινωνιών (NICT) το 1951 χρησιμοποιώντας ένα αυτόματο σύστημα. Οι ιονόσφαιρες παράμετροι που προέρχονται από τη μακροπρόθεσμη παρατήρηση ιονοσόνδης αρχειοθετούνται από το Παγκόσμιο Κέντρο Δεδομένων για την Ιονόσφαιρα στο NICT. Τα μακροπρόθεσμα δεδομένα ιονοσόνδης έχουν χρησιμοποιηθεί για διάφορες μελέτες, όπως μια μελέτη των μακροπρόθεσμων τάσεων της ιονόσφαιρας (Xu et al. 2004) και για την ανάπτυξη εμπειρικών μοντέλων (Bilitza 2018; Yue et al. 2006; Maruyama 2011). Καθώς το TEC και η μέγιστη πυκνότητα της περιοχής F που προέρχεται από την παρατήρηση ιονοσόνδης ($NmF2$) είναι γνωστό ότι συσχετίζονται, το $NmF2$ μπορεί να είναι ένας αντιπρόσωπος του TEC. Σε αυτή τη μελέτη, χρησιμοποιούνται δεδομένα περίπου 60 ετών ιονοσφαιρικών παραμέτρων που προέρχονται από τη μακροχρόνια παρατήρηση ιονοσόνδης. Αν και η περίοδος δεδομένων είναι ακόμη μικρότερη από 100 χρόνια, διερευνούμε στατιστικά χαρακτηριστικά των ακραίων τιμών TEC προκειμένου να εκτιμήσουμε την ιονόσφαιρα μία φορά ανά 100 χρόνια.

3.5 Παράμετροι επιρροής τιμών Tec

3.5.1 Εισαγωγικές έννοιες

Οι παράμετροι που επηρεάζουν την ιονόσφαιρα παρατίθενται στον Πίνακα 1.

Πίνακας 1. Παράμετροι επιρροής της ιονόσφαιρας.

A/A	Δραστηριότητα	Παράμετρος	Υποπαράμετρος	Περίοδος καταγραφής
1	Μαγνητική δραστηριότητα	Daily geomagnetic activity average (K)	Kp	Ανά 3 ώρες
2			ap	
3			D	
4		Auroral Electrojet (AE)	SML	
5			SMU	
6		Disturbance storm time (Dst)	-	Ωριαία
7	Ηλιακή δραστηριότητα	Solar Radio Flux	Fluxtime	Ανά 3 ώρες
8			Fluxjulian	
9			Fluxcarrington	
10			Fluxobsflux	
11			fluxadjflux	
12			fluxursi	
13		Sunspot Number	Daily Total Sunspot Number	
14			Daily North Sunspot Number	
15			Daily South Sunspot Number	

16			Standard Deviation of Raw Daily Total Sunspot Data	
17			Standard Deviation of Raw Daily North Sunspot Data	
18			Standard Deviation of Raw Daily South Sunspot Data	
19			Number of Observations for Daily Total Sunspot Number	
20			Number of Observations for Daily North Sunspot Number	
21			Number of Observations for Daily South Sunspot Number	
22			Definitive/Provisional Indicator	
23		Energetic Particle Flux	GOES-15 Proton FluEncE >1 MEV	Ημερήσια
24			GOES-15 Proton FluEncE >10 MEV	
25			GOES-15 Proton FluEncE >100 MEV	
26			GOES-15 Electron FluEncE >0.8 MEV	
27			GOES-15 Electron FluEncE >2 MEV	

28			NEutron Monitor % of bkgd	
29		Solar Flares	-	Κατά την εμφάνιση
30		Coronal Mass Ejections	Central PA	
31			Angular	
32			Linear	
33			2nd-order Speed at final height	
34			2nd-order Speed at 20 Rs	
35			Acceleration	
36			Mass	
37			Kinetic Energy	
38			MPA	

3.5.2 Μαγνητική κ Ιονοσφαιρική Καταιγίδα

Απότομες μεταβολές του αριθμού των ηλεκτρονίων κατά μήκος της διαδρομής του σήματος προκαλούν προβλήματα στα κυκλώματα PPL και συνεπώς πολλές απώλειες λήψης του σήματος ή παρουσία κύκλων ολίσθησης, με αποτέλεσμα τη δυσκολία του σωστού προσδιορισμού των αέριων ασαφειών φάσης κατά τη συνόρθωση των παρατηρήσεων. Το φαινόμενο αυτό της **ιονοσφαιρικής έξαρσης** (ionospheric scintillation) που συμβαίνει κυρίως στις πολικές περιοχές και σε μία ζώνη $\sim 30^\circ$ γύρω από τον γεωμαγνητικό ισημερινό διαρκεί έως μερικά λεπτά και μπορεί να συνεχίζεται ανά διαστήματα για αρκετές ώρες. Οι παράγοντες που μπορούν να το προκαλέσουν είναι συνήθως η έντονη δραστηριότητα της ηλιακής δραστηριότητας, που προκαλεί την **μαγνητική και ιονοσφαιρική καταιγίδα**. Οι καταιγίδες αυτές αυξάνουν κατά πολύ τον αριθμό των ηλεκτρονίων, κατά κανόνα στη διάρκεια του χειμώνα ενώ αντιθέτως μειώνουν το TEC στη διάρκεια του καλοκαιριού. Το φαινόμενο της ιονοσφαιρικής έξαρσης αποτελεί κατά κάποιον τρόπο ένα είδος πολυανάκλασης του δορυφορικού σήματος.

3.5.3 Ηλιακές Εκλάμψεις (Solar Flares)

Οι ηλιακές εκλάμψεις είναι ξαφνικές εκρήξεις ακτινοβολιών που προέρχονται από τον ήλιο, οι οποίες μεταβάλλουν σημαντικά διάφορες φυσικές και χημικές διεργασίες στην ανώτερη ατμόσφαιρα της γης. Έχει γίνει σημαντικός αριθμός μελετών στο παρελθόν, για την κατανόηση των επιπτώσεων της ηλιακής έκλαμψης στην

ιονόσφαιρα (π.χ. Le et al. 2013) και στη θερμοσφαιρική (π.χ. Le et al. 2012, 2015· Pawlowski and Ridley 2008, 2011) υψόμετρα. Πλήθος δεδομένων από επίγειες/διαστημικές πλατφόρμες που χρησιμοποιούν κατά κύριο λόγο GPS TEC (Afraimovich 2000, Leonovich et al. 2002, 2010; Liu et al. 2006), ασυνάρτητα ραντάρ διασποράς (Mendillo and Evans 1974) σε συνδυασμό με το Themeberticallinetore al. 2008· Qian et al. 2010) έχουν παράσχει σημαντικά αποτελέσματα σχετικά με τις επιδράσεις που προκαλούνται από εκλάμψεις στην ανώτερη γήινη ατμόσφαιρα.

Πρόσφατα, τα φαινόμενα ηλιακής έκλαμψης και οι επιπτώσεις τους στην ηλεκτροδυναμική της ισημερινής ιονόσφαιρας έχουν λάβει σημαντική έλξη σε όλη την υδρόγειο (π.χ. Zhang et al. 2017· Manju 2016· Manju et al. 2012). Οι Liu et al. (2007) έδειξε ότι η ανωμαλία ιοντισμού του Ισημερινού (EIA) εξασθενούσε σημαντικά κατά τη διάρκεια της έκλαμψης λόγω του κυρίαρχου ρόλου της ηλεκτροδυναμικής παρά της φωτοχημείας. Οι μελέτες προσομοίωσης (Qian et al. 2012) έδειξαν επίσης ότι η μετατόπιση $E \times B$ στον ισημερινό εξασθενεί κατά τη διάρκεια της έκλαμψης. Αυτό είναι σύμφωνο με τις προηγούμενες παρατηρήσεις μείωσης του ηλεκτρικού πεδίου προς τα ανατολικά στην περιοχή του δυναμό κατά τη διάρκεια της έκλαμψης (Manju και Viswanathan 2005). Ωστόσο, στο παρελθόν είχε αναφερθεί τόσο αύξηση (Qian et al. 2012) όσο και μείωση (Manju και Viswanathan 2005) στην αναλογία αγωγιμότητας Hall-to-Pedersen ενσωματωμένη στη γραμμή πεδίου σε σχέση με τον ισημερινό. Από την άλλη πλευρά, οι επιπτώσεις της ηλιακής έκλαμψης στην ουδέτερη θερμόσφαιρα, ιδιαίτερα στα γεωγραφικά πλάτη του ισημερινού, δεν έχουν γίνει σωστά κατανοητές μέχρι στιγμής, κυρίως λόγω της έλλειψης παρατηρήσεων. Αν και οι παρατηρήσεις CHALLENGING Mini Satellite Payload (CHAMP) παρείχαν αρκετές νέες γνώσεις σχετικά με αυτό (Liu et al. 2007), κανονικοποιούνται σε υψηλότερο υψόμετρο 400 km και έχουν κακή χρονική ανάλυση (~ 93 λεπτά) λόγω του εγγενούς χρόνου ώστε ο δορυφόρος να επανεξετάσει το ίδιο γεωγραφικό πλάτος και τοπική ώρα. Επομένως, η ανάγκη για δεδομένα υψηλού ρυθμού από την κατώτερη θερμόσφαιρα εκτιμάται καλά για την ολοκληρωμένη κατανόηση της ιονόσφαιρας-θερμοσφαιρικής σύζευξης κατά τη διάρκεια τέτοιων παροδικών γεγονότων.

Σε αυτό το πλαίσιο, οι επίγειες ουδέτερες θερμοσφαιρικές εκπομπές ημέρας λάμψης OI 630,0 nm είναι ιδανικές για τη διερεύνηση τέτοιων εφήμερων γεγονότων όπως η έκλαμψη, καθώς προέρχονται από τα υψόμετρα, όπου λαμβάνει χώρα η μέγιστη απορρόφηση EUV. Αυτές οι μετρήσεις λάμψης ημέρας στο Trivandrum, τα τελευταία χρόνια, έφεραν πολλά σημαντικά αποτελέσματα που σχετίζονται με διάφορες πτυχές των διαδικασιών σύζευξης στην ανώτερη ατμόσφαιρα του ισημερινού (π.χ., Sumod et al. 2011a, b, 2012, 2014, 2015 και αναφορές σε αυτό). Στην παρούσα εργασία, γίνεται μια προσπάθεια να διερευνηθούν οι επιπτώσεις της ηλιακής έκλαμψης X3.8, που συνέβη στις 17 Ιανουαρίου 2005, στο σύστημα ισημερινής ιονόσφαιρας-θερμοσφαιρας, χρησιμοποιώντας συνδυασμένες μετρήσεις υψηλού ρυθμού θερμοσφαιρικής λάμψης ημέρας OI 630,0 nm, με μέτρηση GPS. Ιονόσφαιρα Ολικό Περιεχόμενο Ηλεκτρονίων (TEC) και η ισχύς του Ισημερινού Ηλεκτρονίου (EEJ). Η

μελέτη παρέχει ίσως την «πρώτη φορά» πειραματική απόδειξη για την αποδυνάμωση της ΕΙΑ κατά τη διάρκεια της έκρηξης στον ινδικό διαμήκη τομέα.

3.5.4 Coronal mass ejection

Αρκετές μελέτες ενδιαφέρθηκαν να διερευνήσουν τον αντίκτυπο των ηλιακών δραστηριοτήτων στο ιονόσφαιρα. Μεταξύ εκείνων των μελετών που ασχολούνται με την απόκριση της ιονόσφαιρας Η κρίσιμη συχνότητα (f_{oF2}) στις CME, έχει γίνει υψίστης σημασίας τα τελευταία χρόνια. Στην πραγματικότητα, η ηλιακή δραστηριότητα είναι η κύρια πηγή διαταραχών και διακυμάνσεις στο περιβάλλον της Γης, ιδιαίτερα στη μαγνητόσφαιρα και στα στρώματα της ιονόσφαιρας.

Η μεταβλητότητα της ιονόσφαιρας μπορεί να αποδοθεί σε συνεισφορές από το χαμηλότερο εσωτερικό της ατμόσφαιρας διακυμάνσεις κυμάτων, γεωμαγνητικής και ηλιακής δραστηριότητας από την υψηλή ατμόσφαιρα επίσης. Στην πραγματικότητα, ηλιακός ιονιστής η ροή ποικίλλει όχι μόνο με μεγαλύτερη χρονική κλίμακα, τον ηλιακό κύκλο, αλλά και με τη μικρότερη χρονική κλίμακα, η σχεδόν 27-ημέρες περιστροφή του Ήλιου και μάλιστα σε καθημερινή βάση. Επιπλέον, προκαλείται από ηλιακή ροή Οι διακυμάνσεις της ουδέτερης θερμοκρασίας, των ανέμων και της ουδέτερης σύνθεσης εκδηλώνονται και στην ιονόσφαιρα πυκνότητες και ύψη πλάσματος.

Τα CME [11] πιστεύεται ότι προκαλούν αύξηση της πυκνότητας ηλεκτρονίων σε μεγάλους όγκους της Γης ιονόσφαιρα. Επιπλέον, τα συμβάντα CME είναι συνήθως η πηγή έντονων γεωμαγνητικών καταιγίδων και εμφανίζονται κυρίως κατά τη διάρκεια της ηλιακής μέγιστης φάσης. Γι' αυτό θεωρούνται ότι είναι η προέλευση των διαστημικών καιρικών φαινομένων. Βασικά, τα CME είναι τεράστιες εκρήξεις πλάσματος και μαγνητικών πεδίων από το στέμμα του ήλιου. Εκτοξεύουν δισεκατομμύρια τόνους στεφαναίου υλικού που έχει παγώσει στο μαγνητικό πεδίο που είναι μεγαλύτερα από το μαγνητικό πεδίο του ηλιακού ανέμου φόντου (IMF). Επιπλέον, είναι ταξιδεύοντας προς τα έξω από τον ήλιο με ταχύτητες που κυμαίνονται από 250 (km/s) έως και κοντά στα 3000 km/s.



Εικόνα 5. Έκρηξη CME στις 31 Αυγούστου 2012 (Πηγή: NASA Goddard Space Flight Center)

3.5.5 Solar Radio Flux

Κατά την περίοδο 2001-2010, αρκετές ισχυρές γεωμαγνητικές καταιγίδες και άμεσες παρεμβολές Solar Radio Flux επιδείνωσαν σοβαρές επιδόσεις GPS. Η εκπομπή Solar Radio Flux [12] της ζώνης L έχει πρόσφατα θεωρηθεί ως πιθανή απειλή για τη σταθερή απόδοση του GPS και του GLONASS. Ωστόσο, η απειλή δεν έχει διερευνηθεί ή αξιολογηθεί πλήρως μέχρι στιγμής. Επιπλέον, η ανωμαλία ιονισμού σε χαμηλά γεωγραφικά πλάτη μαζί με την επίδραση των «φουσαλίδων» του ισημερινού πλάσματος αυξάνουν την πιθανότητα εξασθένησης των μεταιονοσφαιρικών σημάτων, ειδικά κατά τη διάρκεια γεωμαγνητικών καταιγίδων. Οι αστάθειες του ιονοσφαιρικού πλάσματος στα «τοιχώματα» μιας φουσαλίδας με πυκνότητα ηλεκτρονίων μικρότερη από την τιμή του υποβάθρου χαρακτηρίζονται επίσης από έντονες διαβαθμίσεις της πυκνότητας ηλεκτρονίων. Για παράδειγμα, τα τοιχώματα των φουσαλίδων μπορούν επίσης να είναι πηγή ιονοσφαιρικών σπινθηρισμών. Επομένως, ο χωρικός προσανατολισμός της φουσαλίδας πλάσματος παίζει καθοριστικό ρόλο στην ενίσχυση και την αποδυνάμωση του πλάτους και των σπινθηρισμών φάσης των σημάτων δορυφορικών οχημάτων (SV).


Αν και οι αστοχίες εμβέλειας και εντοπισμού θέσης GPS διερευνήθηκαν κάτω από τέτοιες δυσμενείς γεωφυσικές συνθήκες, η ακριβής φύση τους παραμένει ασαφής. Αυτό το κεφάλαιο είναι αφιερωμένο σε ορισμένα χαρακτηριστικά της απόδοσης GPS/GLONASS κάτω από συγκεκριμένα γεωφυσικά γεγονότα, όπως εκρήξεις ηλιακών ραδιοφωνικών εκπομπών και ισχυρή σκέδαση δορυφορικού σήματος από τις «φουσαλίδες» του ισημερινού πλάσματος. Καθώς οι ανωμαλίες επιμηκύνονται στην κατεύθυνση του μαγνητικού πεδίου, μια διαδρομή ακτινών που είναι παράλληλη με το μαγνητικό πεδίο ενσωματώνει μεγαλύτερο μήκος διαδρομής μέσω εξαντλημένων περιοχών που περιέχουν ανωμαλίες στην πυκνότητα του πλάσματος. Προτείνουμε μια μέθοδο GPS για την ανίχνευση ανωμαλιών ευθυγραμμισμένων με το μεσαίο γεωγραφικό πλάτος (FAIs) με γωνιακή σάρωση οπτικής επαφής σχετικά με το διάνυσμα τοπικού μαγνητικού πεδίου. Χρησιμοποιώντας δεδομένα GPS του ιαπωνικού δικτύου GPS (GEONET), αναλύουμε την εμφάνιση ολισθήσεων φάσης GPS και σφαλμάτων θέσης κατά τη διάρκεια της γεωμαγνητικής καταιγίδας της 12ης Φεβρουαρίου 2000.

3.5.6 Sunspot Number

Σε μια πρόσφατη μελέτη, οι ιονόσφαιρες παράμετροι μεσαίου γεωγραφικού πλάτους συγκρίθηκαν με την ηλιακή δραστηριότητα. προτάθηκε ότι η σχέση μεταξύ αυτών, που προηγουμένως θεωρούνταν σταθερή, μπορεί να αλλάζει με το χρόνο (Lastovicka, 2019). Εδώ, οι πληροφορίες επεκτείνονται σε μεγαλύτερο γεωγραφικό πλάτος (69,6°N, 19,2E) και πιο πίσω στο χρόνο. Για την ιονόσφαιρα F-περιοχή (δηλ. η κρίσιμη συχνότητα, FoF2) η ίδια συμπεριφορά παρατηρείται με ένα σημείο αλλαγής γύρω στο 1996. Για την ιονόσφαιρα E-περιοχή (δηλ. η κρίσιμη συχνότητα, foE), τα σημεία

αλλαγής είναι λιγότερο εμφανή παρά στη μελέτη μεσαίου γεωγραφικού πλάτους, πιθανώς λόγω της θέσης παρατήρησης που βρίσκεται κάτω από το οβάλ σέλας.

Με μια ολοένα και πιο μεγάλη χρονική σειρά παραμέτρων από την ανώτερη ατμόσφαιρα, καθίσταται βιώσιμη η διερεύνηση της κλιματολογίας. Οι τάσεις ή οι αλλαγές στην ανώτερη ατμόσφαιρα μπορεί να αντικατοπτρίζουν αντίστοιχες στην τροπόσφαιρα (Hall et al., Reference Hall, Brekke and Cannon2007; Roble & Dickinson, Reference Roble and Dickinson1989), αλλά σε υψόμετρο που δεν επηρεάζεται άμεσα από τις τοπικές βραχυπρόθεσμες επιδράσεις. Κάποιος προσπαθεί να καθιερώσει τους μηχανισμούς που είναι υπεύθυνοι για τις παρατηρούμενες τάσεις, με έναν υποψήφιο να είναι η ηλιακή ισχύς: το επίκεντρο αυτής της μελέτης και εκείνο της Lastovicka (Αναφορά Lastovicka2019). Μόλις εξαλειφθεί αυτή η επίδραση, μπορεί να είναι δυνατός ο εντοπισμός άλλων, συμπεριλαμβανομένων των ανθρωπογενών αιτιών, εάν υπάρχουν.



Εικόνα 6. Οι X2.2 και X9.3 Solar Flares που εξέπεμψε ο Ήλιος στις 6 Σεπτεμβρίου 2017. Οι εικόνες καταγράφηκαν από το Solar Dynamics Observatory της NASA και δείχνουν φως στο μήκος κύματος των 131 angstrom. (Πηγή: NASA/Goddard/SDO)

3.5.7 Ενεργητικές ροές ηλεκτρονίων (Energetic electrons fluxes)

Ροές ενεργειακών ηλεκτρονίων [13] με ενέργειες λίγων δεκάδων keV έχουν παρατηρηθεί στην ιονόσφαιρα από πολυάριθμα πειράματα από την αρχή της διαστημικής εποχής (βλέπε κριτικές των Paulikas (1975) και Voss and Smith (1980)).

Οι ροές ηλεκτρονίων αυξάνονται με το υψόμετρο και επίσης με τη γεωμαγνητική δραστηριότητα (Hill et al., 1970; Goldberg et al., 1974). Τρεις πληθυσμοί ηλεκτρονίων, παγιδευμένων, κατακρημνισμένων και οιονεί παγιδευμένων, τεκμηριώθηκαν επίσης (π.χ. Κοηο, 1973). Αυτή η ταξινόμηση βασίζεται στη φυσική συμπεριφορά των ηλεκτρονίων με διαφορετικές τοπικές ισημερινές γωνίες βήματος (η γωνία μεταξύ της ταχύτητας ενός σωματιδίου και της γραμμής του μαγνητικού πεδίου) (π.χ. Tu et al., 2010). Συγκεκριμένα, τα σωματίδια που ταξινομούνται ως «κατακρημνιζόμενα» ή «μη παγιδευμένα» έχουν τοπικές ισημερινές γωνίες βήματος που κυμαίνονται εντός ενός κώνου απώλειας αναπήδησης, δηλαδή τα σωματίδια χάνονται μέσα σε μία περίοδο αναπήδησης λόγω διασποράς στην ατμόσφαιρα επειδή τα σημεία καθρέφτη τους βρίσκονται κάτω από 100 km. Τα σωματίδια, που κλείνουν τη διαδρομή τους γύρω από τη Γη, ονομάζονται «παγιδευμένα». Τα σωματίδια από έναν «οιονεί παγιδευμένο» πληθυσμό δεν μπορούν να κλείσουν την πλήρη μετατόπιση γύρω από τη Γη και οι γωνίες βήματος των οιονεί παγιδευμένων σωματιδίων κυμαίνονται εντός ενός κώνου απώλειας ολίσθησης. Αυτά τα σωματίδια μπορούν να κάνουν έναν αριθμό αναπηδήσεων, αλλά σε ένα συγκεκριμένο γεωγραφικό μήκος, η τοπική τους ισημερινή γωνία βήματος εμφανίζεται μέσα σε έναν κώνο απώλειας αναπήδησης και, ως εκ τούτου, τα σωματίδια κατακρημνίζονται.

3.5.8 Γεωμαγνητικοί δείκτες K

Ο δείκτης K [14] είναι λογαριθμικός τοπικός δείκτης του εύρους 3 ωρών στη μαγνητική δραστηριότητα σε σχέση με μια υποτιθέμενη καμπύλη ησυχίας για μια μεμονωμένη θέση γεωμαγνητικού παρατηρητηρίου. Εισήχθη για πρώτη φορά από τον J. Bartels το 1938, αποτελείται από ένα μονοψήφιο 0 έως 9 για κάθε διάστημα 3 ωρών της καθολικής ώρας ημέρας (UT).

Ο πλανητικός δείκτης εύρους 3 ωρών K_p είναι ο μέσος τυποποιημένος δείκτης K από 13 γεωμαγνητικά παρατηρητήρια μεταξύ 44 μοιρών και 60 μοιρών βόρειου ή νότιου γεωμαγνητικού γεωγραφικού πλάτους. Η κλίμακα είναι από το 0 έως το 9 που εκφράζεται σε τρίτα μιας μονάδας, π.χ. Το 5- είναι 4 2/3, το 5 είναι 5 και το 5+ είναι 5 1/3. Αυτός ο πλανητικός δείκτης έχει σχεδιαστεί για να μετράει την ηλιακή ακτινοβολία σωματιδίων με τα μαγνητικά του αποτελέσματα. Ο δείκτης 3 ωρών (ισοδύναμο εύρος) προέρχεται από τον δείκτη K_p ως εξής:

K_p	0o	0+	1-	1o	1+	2-	2o	2+	3-	3o	3+	4-	4o	4+
ap	0	2	3	4	5	6	7	9	12	15	18	22	27	32
K_p	5-	5o	5+	6-	6o	6+	7-	7o	7+	8-	8o	8+	9-	9o
ap	39	48	56	67	80	94	111	132	154	179	207	236	300	400

Άλλοι πλανητικοί δείκτες περιλαμβάνουν τους Ap και AA*. Ο δείκτης Ap ορίζεται ως η νωρίτερα εμφανιζόμενη μέγιστη τιμή 24 ωρών που λαμβάνεται με τον υπολογισμό ενός τρέχοντος μέσου όρου 8 σημείων διαδοχικών δεικτών AP 3 ωρών κατά τη

διάρκεια ενός συμβάντος γεωμαγνητικής καταιγίδας και συνδέεται μοναδικά με το γεγονός καταιγίδας.

3.5.9 Auroral Electrojet (AE)

Ο δείκτης Auroral Electrojet (σελαϊκών ηλεκτροχειμάρρων) [14] εισήχθη αρχικά από τους Davis και Sugiura το 1966 ως μέτρο της παγκόσμιας δραστηριότητας των ηλεκτροχειμάρρων στη σελαϊκή ζώνη. Παρέχει μια ποσοτική μέτρηση της μαγνητικής δραστηριότητας στη ζώνης του σέλαος που παράγεται από ενισχυμένα ιονοσφαιρικά ρεύματα που ρέουν κάτω και μέσα στο σέλας (Δαγκλής Ι., Σημειώσεις Διαστημικής Φυσικής, 2018). Προέρχεται από διακυμάνσεις του γεωμαγνητικού πεδίου στη συνιστώσα Η που μετράται σε 12 σταθμούς κατά μήκος της ζώνης του σέλαος στο βόρειο ημισφαίριο. Ο δείκτης Auroral Electrojet $AE(12) = AU(12) - AL(12)$, όπου AU και AL είναι τα ανώτερα και κατώτερα συστατικά του AE (οι μεγαλύτερες και μικρότερες τιμές της συνιστώσας Η μεταξύ των μαγνητικών σταθμών που χρησιμοποιούνται).

Ως εξέλιξη του δείκτη AE που χρησιμοποιείται παραδοσιακά, ο δείκτης SME που εισήχθη από τους συνεργάτες του SuperMAG διαφέρει από τον παραδοσιακό δείκτη AE κυρίως από τον αριθμό των σταθμών που συμμετείχαν (100). Όλα τα δεδομένα μετατρέπονται πρώτα σε συντεταγμένες με τη συνιστώσα Η να δείχνει προς τον τοπικό μαγνητικό βορρά και η γραμμή βάσης αφαιρείται. Τότε ο σταθμός με τη μεγαλύτερη τιμή Η συνεισφέρει στην τιμή SMU, ενώ ο σταθμός με τη μικρότερη τιμή συνεισφέρει στην τιμή SML. Ο δείκτης SME είναι , $SME = SMU - SML$ (Newell and Gjerloev (2012)).

3.5.10 Disturbance storm time (Dst)

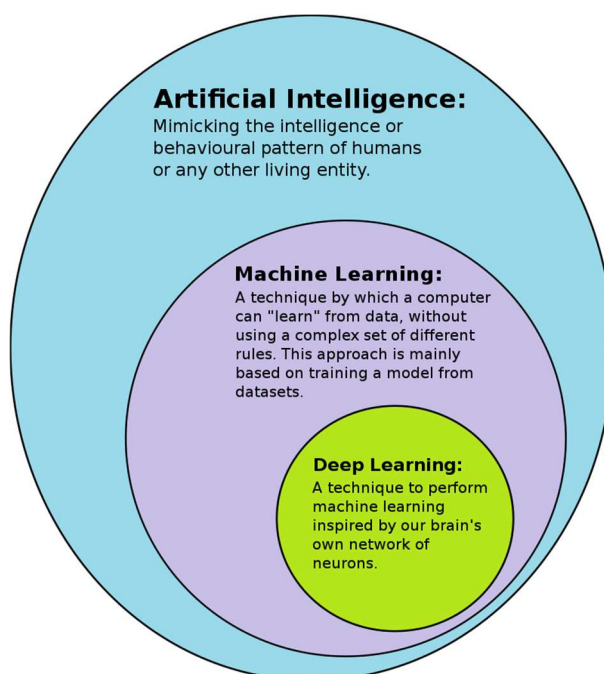
Ο δείκτης χρόνου διαταραχής καταιγίδας (Dst) [15] χρησιμοποιείται για ανάλυση της ισχύος και της διάρκειας των γεωμαγνητικών καταιγίδων. Το Dst είναι ένα μέτρο της μείωσης της οριζόντιας συνιστώσας του μαγνητικού πεδίου της Γης κοντά στον μαγνητικό ισημερινό λόγω της αύξησης του ρεύματος του μαγνητοσφαιρικού δακτυλίου (δείτε τις Συχνές ερωτήσεις παρακάτω). Τιμές μικρότερες από -50 nanotesla (nT) υποδηλώνουν υψηλή γεωμαγνητική δραστηριότητα.

Ο αρχικός δείκτης Dst παρέχεται από το Παγκόσμιο Κέντρο Δεδομένων για τον Γεωμαγνητισμό, Κιότο, Ιαπωνία. Ο δείκτης παράγεται σε ωριαίο ρυθμό χρησιμοποιώντας χρονική και χωρική μέση τιμή από τέσσερις επίγειους σταθμούς παρατήρησης χαμηλού γεωγραφικού πλάτους.

Τεχνητή νοημοσύνη

4. Εισαγωγικά

Η επιβίωση του ανθρώπινου είδους και η θέση του στην τροφική αλυσίδα οφείλεται στο επίπεδο νοημοσύνης που διαθέτει. Για την επίλυση πολύπλοκων μαθηματικών προβλημάτων και εξαγωγή συμπερασμάτων από μελέτη προτύπων, αναπτύχθηκαν συστήματα τεχνητής νοημοσύνης. Στο πλαίσιο της παρούσας μελέτης, όπως και σε άλλες αντίστοιχες που μελετήσαμε στο κεφάλαιο της βιβλιογραφικής ανασκόπησης, εκπαιδεύτηκαν νευρωνικά δίκτυα, για την πρόβλεψη της ιονοσφαιρικής δραστηριότητας, τα οποία αποτελούν βασικά εργαλεία βαθιάς μάθησης.



Εικόνα 7. Τεχνητή νοημοσύνη.

Η βαθιά μάθηση αποτελεί κομμάτι της μηχανικής μάθησης, η οποία αποτελεί κομμάτι της τεχνητής νοημοσύνης. Στο παρόν κεφάλαιο θα κάνουμε μια σύντομη ανασκόπηση σε αυτές τις βασικές έννοιες, ώστε να είμαστε σε θέση εν συνεχεία να αντιληφθούμε και να αξιολογήσουμε τα αποτελέσματα εκπαίδευσης των μοντέλων πρόβλεψης.

4.1 Μηχανική Μάθηση (machine learning)

Η Μάθηση (Learning) είναι μία από τις θεμελιώδεις ιδιότητες της νοήμονος συμπεριφοράς του ανθρώπου. Με κύριο εργαλείο τη μάθηση λαμβάνουμε αποφάσεις για την αντιμετώπιση προβλημάτων που συναντάμε ξανά ή και για πρώτη

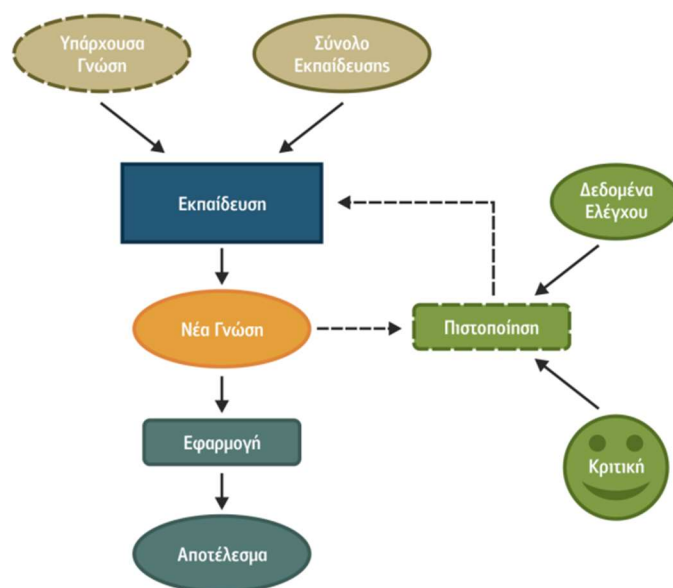
φορά. Εμπνευσμένοι από αυτή μας την ικανότητα, για την αντιμετώπιση δύσκολων υπολογιστικά και προγραμματιστικά προβλημάτων αναπτύξαμε τη Μηχανική Μάθηση (machine learning) [16]. Αυτή μπορεί να οριστεί ως το φαινόμενο κατά το οποίο ένα σύστημα βελτιώνει την απόδοσή του κατά την εκτέλεση μιας συγκεκριμένης εργασίας, χωρίς να υπάρχει ανάγκη να προγραμματιστεί εκ νέου. Βάσει του ορισμού αυτού, η Μηχανική Μάθηση έχει ως σκοπό τη δημιουργία μηχανών ικανών να μαθαίνουν, να βελτιώνουν, δηλαδή, την απόδοσή τους σε κάποιους τομείς μέσω της αξιοποίησης προηγούμενης γνώσης και εμπειρίας.

Ένας αλγόριθμος μηχανικής μάθησης είναι ένας αλγόριθμος που είναι σε θέση να μαθαίνει από δεδομένα. Η εισαγωγή της μηχανικής μάθησης επέτρεψε στους υπολογιστές να αντιμετωπίσουν προβλήματα που αφορούν τη γνώση του πραγματικού κόσμου και να λαμβάνουν αποφάσεις που φαίνονται υποκειμενικές. Μια απλή μηχανή αλγόριθμος μάθησης που ονομάζεται λογιστική παλινδρόμηση μπορεί να καθορίσει αν θα συστήσει καισαρική τομή. Ένας απλός αλγόριθμος μηχανικής μάθησης που ονομάζεται αφελής Bayes μπορεί να διαχωρίσει το νόμιμο ηλεκτρονικό ταχυδρομείο από το ανεπιθύμητο ηλεκτρονικό ταχυδρομείο.

Εν γένει, ο τομέας της Μηχανικής Μάθησης αναπτύσσει τρεις τρόπους μάθησης, ανάλογους με τους τρόπους με τους οποίους μαθαίνει ο άνθρωπος:

- Επιβλεπόμενη Μάθηση (Supervised Learning) είναι η διαδικασία όπου ο αλγόριθμος κατασκευάζει μια συνάρτηση που απεικονίζει δεδομένες εισόδους (σύνολο εκπαίδευσης) σε γνωστές επιθυμητές εξόδους, με απώτερο στόχο τη γενίκευση της συνάρτησης αυτής και για εισόδους με άγνωστη έξοδο
- Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning), όπου ο αλγόριθμος κατασκευάζει ένα μοντέλο για κάποιο σύνολο εισόδων υπό μορφή παρατηρήσεων χωρίς να γνωρίζει τις επιθυμητές εξόδους.
- Ενισχυτική Μάθηση (Reinforcement Learning), όπου ο αλγόριθμος μαθαίνει μια στρατηγική ενεργειών μέσα από άμεση αλληλεπίδραση με το περιβάλλον.

Για κάθε πρόβλημα προς επίλυση στο χώρο της Μηχανικής Μάθησης υπάρχει ένας κατάλληλος τρόπος μάθησης και για κάθε τρόπο μάθησης υπάρχει τουλάχιστον ένας κατάλληλος αλγόριθμος που μπορεί να χρησιμοποιηθεί. Η βασικότερη φάση κάθε αλγόριθμου είναι η εκπαίδευση, όπου ο αλγόριθμος χρησιμοποιεί ως είσοδο ένα σύνολο δεδομένων εκπαίδευσης (training set) προς επίτευξη του σκοπού του, τη δημιουργία νέας γνώσης. Επιπλέον, μπορεί είτε να χρησιμοποιήσει λιγότερο ή περισσότερο την υπάρχουσα γνώση είτε να μην τη χρησιμοποιήσει καθόλου. Την εκπαίδευση ακολουθεί η φάση της πιστοποίησης της παραγόμενης νέας γνώσης. Συνήθως, η πιστοποίηση πραγματοποιείται καταρχάς από τον ίδιο τον αλγόριθμο μέσω διαδικασιών ανάκλησης (recall) με τη βοήθεια δεδομένων ελέγχου (test data) και, στη συνέχεια, μέσω κριτικής που κάνει ο χρήστης βάσει των γνώσεων που διαθέτει για το πρόβλημα που επιχειρεί να λύσει ο αλγόριθμος. Τέλος, η νέα γνώση δίνεται προς χρήση σε εφαρμογές στις οποίες είναι απαραίτητη, για να λυθούν πραγματικά προβλήματα.




Εικόνα 8. Φάσεις αλγορίθμου Μηχανικής Μάθησης.

Οι περισσότεροι αλγόριθμοι μηχανικής μάθησης έχουν διάφορες ρυθμίσεις που μπορούμε να χρησιμοποιήσουμε για να ελέγξουμε τη συμπεριφορά του αλγορίθμου μάθησης. Αυτές οι ρυθμίσεις ονομάζονται **υπερπαράμετροι**. Οι τιμές των υπερπαραμέτρων δεν προσαρμόζονται από τον ίδιο τον αλγόριθμο μάθησης (αν και μπορούμε να σχεδιάσουμε μια ένθετη διαδικασία μάθησης όπου ένας αλγόριθμος μάθησης μαθαίνει τις καλύτερες υπερπαραμέτρους για έναν άλλο αλγόριθμο μάθησης).

4.2 Βαθιά Μάθηση (deep learning)

Η βαθιά μάθηση (deep learning) [17] είναι μια προσέγγιση στη μηχανική μάθηση που έχει αντλήσει σε μεγάλο βαθμό τις γνώσεις μας για τον ανθρώπινο εγκέφαλο, τη στατιστική και τα εφαρμοσμένα μαθηματικά, καθώς αναπτύχθηκε τις τελευταίες δεκαετίες. Τα τελευταία χρόνια, έχει γνωρίσει τεράστια αύξηση της δημοτικότητας και της χρησιμότητάς της, η οποία οφείλεται σε μεγάλο βαθμό στους ισχυρότερους υπολογιστές, στα μεγαλύτερα σύνολα δεδομένων και στις τεχνικές εκπαίδευσης βαθύτερων δικτύων.

Τα θεωρητικά θεμέλια της βαθιάς μάθησης έχουν τις ρίζες τους στην κλασική βιβλιογραφία των νευρωνικών δικτύων (NN). Όμως, σε αντίθεση με την πιο παραδοσιακή χρήση των NN, η βαθιά μάθηση προβλέπει τη χρήση πολλών κρυφών νευρώνων και στρωμάτων - τυπικά περισσότερων από δύο - ως αρχιτεκτονικό πλεονέκτημα σε συνδυασμό με νέα παραδείγματα εκπαίδευσης. Ενώ η προσφυγή σε πολλούς νευρώνες επιτρέπει την εκτεταμένη κάλυψη των ακατέργαστων δεδομένων που βρίσκονται στη διάθεσή μας.



Εικόνα 9. Τυπική δομή πολυεπίπεδων μοντέλων.

Η βαθιά μάθηση επιτρέπει σε υπολογιστικά μοντέλα που αποτελούνται από πολλαπλά επίπεδα επεξεργασίας να μαθαίνουν αναπαραστάσεις δεδομένων με πολλαπλά επίπεδα αφαίρεσης. Αυτές οι μέθοδοι έχουν βελτιώσει δραματικά την κατάσταση στην αναγνώριση ομιλίας, στην οπτική αναγνώριση αντικειμένων, στην ανίχνευση αντικειμένων και σε πολλούς άλλους τομείς, όπως η ανακάλυψη φαρμάκων και η γονιδιωματική. Η βαθιά μάθηση ανακαλύπτει περίπλοκες δομές σε μεγάλα σύνολα δεδομένων.

4.3 Νευρωνικά Δίκτυα (Neural Networks)

Ο όρος Νευρωνικά Δίκτυα (Neural Networks) [18] περιγράφει έναν αριθμό από διαφορετικά μαθηματικά μοντέλα, εμπνευσμένα από αντίστοιχα βιολογικά μοντέλα, δηλαδή μοντέλα που προσπαθούν να μιμηθούν τη συμπεριφορά των νευρώνων του ανθρώπινου εγκεφάλου


Τα μαθηματικά μοντέλα των τεχνητών νευρωνικών δικτύων, αποτελούνται από έναν αριθμό απλών και με υψηλό βαθμό εσωτερικής διασύνδεσης επεξεργαστικών μονάδων, οργανωμένων σε στρώματα. Τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks ANN) επεξεργάζονται πληροφορίες ανταποκρινόμενα δυναμικά σε εξωτερικά ερεθίσματα (εισόδους). Κάθε τεχνητός νευρώνας αποτελείται από πολλές εισόδους x_i και μία μόνο έξοδο y . Κάθε είσοδος x_i "ζυγίζεται" με ένα βάρος w_i και τα αποτελέσματα αθροίζονται μέσω της συνάρτησης αθροίσματος (summation function) F :

$$F = \sum_i^n x_i w_i$$

Ο τεχνητός νευρώνας δίνει έξοδο μέσω της συνάρτησης μετάβασης (transfer function), μόνο όταν το ζυγισμένο άθροισμα των εισόδων είναι μεγαλύτερο μιας ορισμένης τιμής κατωφλίου (threshold value) θ , δηλαδή όταν:

$$\sum_i^n x_i w_i - \theta > 0$$

Τα όσα περιεγράφηκαν για τη λειτουργία του τεχνητού νευρώνα οπτικοποιούνται για καλύτερη κατανόηση στο ακόλουθο σχήμα.




Εικόνα 10. Λειτουργία τεχνητού νευρώνα.

4.4 Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks)

Τα αναδρομικά νευρωνικά δίκτυα ή αλλιώς Recurrent Neural Networks (RNN) [19] επεξεργάζονται μια ακολουθία εισόδου με ένα στοιχείο κάθε φορά και διατηρούν ένα κρυφό διάνυσμα, το οποίο λειτουργεί ως μνήμη για την προηγούμενη πληροφορία. Μαθαίνουν επιλεκτικά σχετικές πληροφορίες από τις ακολουθίες που τους επιτρέπουν να καταλαβαίνουν τις εξαρτήσεις μεταξύ των δεδομένων στο πέρασα του χρόνου. Με αυτόν τον τρόπο, έχοντας ως δεδομένο τις τρέχουσες πληροφορίες, τις προηγούμενες, καθώς και την συσχέτιση αυτών, είναι σε θέση τα δίκτυα αυτά να κάνουν μελλοντικές προβλέψεις και να αντιμετωπίσουν διάφορα προβλήματα που απαιτούν διαδοχική επεξεργασία δεδομένων.

Το αποτέλεσμα που επιτυγχάνεται από το δίκτυο τη χρονική στιγμή $t-1$ επηρεάζει την επιλογή τη χρονική στιγμή t . Με αυτόν τον τρόπο, τα RNN εκμεταλλεύονται δύο πηγές εισόδου, το παρόν και το πρόσφατο παρελθόν, για να παρέχουν την έξοδο των νέων δεδομένων. Για το λόγο αυτό, συχνά λέγεται ότι τα RNN έχουν μνήμη.

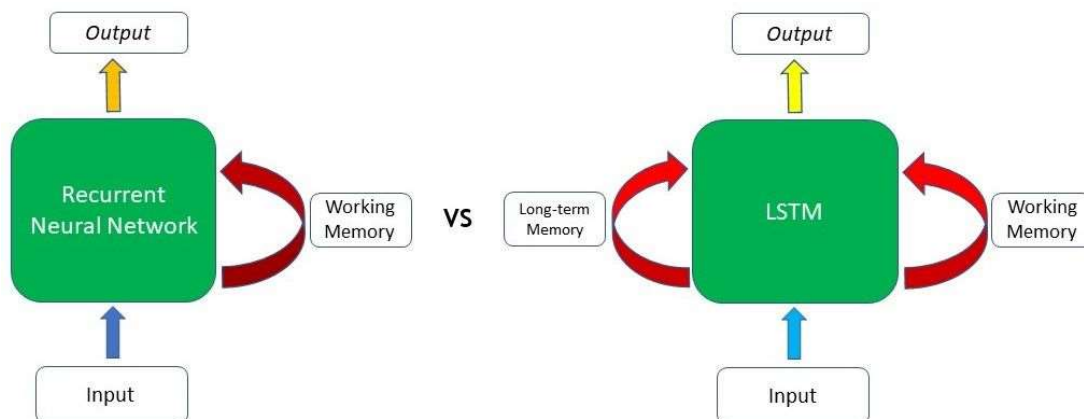


Εικόνα 11. Τυπική δομή αναδρομικού νευρωνικού δικτύου.

Ανάλογα με το εκάστοτε πρόβλημα, υπάρχουν διαφορετικές αρχιτεκτονικές για αντίστοιχες πιθανές εισόδους και αντίστοιχες απαιτούμενες εξόδους. Ωστόσο, όταν ένα RNN εκπαιδεύεται, μετά από λίγο «ξεχνά» τα αρχικά δεδομένα που εισήχθησαν σε αυτό, άρα με κάθε επόμενο βήμα το RNN χάνει μία ποσότητα πληροφορίας. Συνεπώς τα αναδρομικά νευρωνικά δίκτυα παρουσιάζουν αδυναμίες στην εκμάθηση μεγάλων ακολουθιών εξαρτήσεων. Αντίθετα τα δίκτυα βραχυπρόθεσμης μάρκρας μνήμης Long Short-Term Memory (LSTM), έχουν αποδειχθεί πολύ πιο αποτελεσματικά σε αυτές τις περιπτώσεις σε σύγκριση με τα τυπικά RNN.

4.5 Νευρώνες μακράς-βραχείας διάρκειας μνήμης (Long Short-Term Memory - LSTM)

Τα δίκτυα μακράς βραχυπρόθεσμης μνήμης (long short-term memory networks η LSTM) [20] αποτελούν ένα είδος επαναληπτικών δικτύων, τα οποία δημιουργήθηκαν προκειμένου να αντιμετωπίσουν τα προβλήματα της βραχυπρόθεσμης μνήμης και θεμελιωδών μαθηματικών δυσκολιών στη μοντελοποίηση μακρών ακολουθιών.



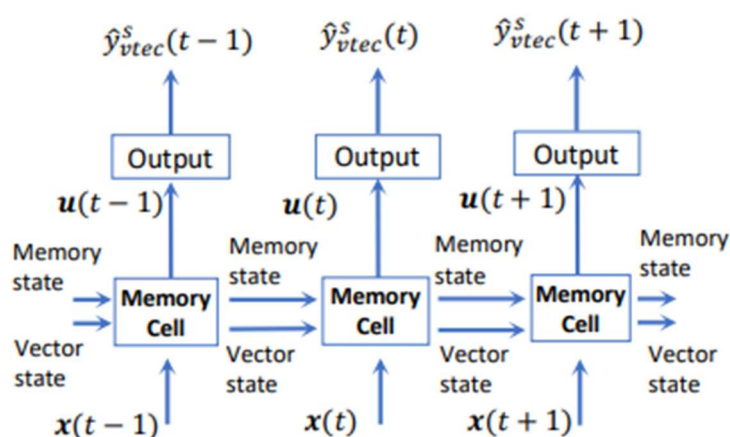
Εικόνα 12. Σύγκριση αναδρομικών μοντέλων.

Ένα δίκτυο LSTM είναι μια παραλλαγή του κλασικού μοντέλου RNN, εμπλουτισμένο με αργά μεταβαλλόμενες βάρη. Τα δίκτυα LSTM έχουν εσωτερικούς μηχανισμούς που ονομάζονται πύλες, οι οποίοι μπορούν να ρυθμίζουν τη ροή των πληροφοριών, να διατηρούν τις πληροφορίες που αξίζει να θυμόμαστε και να ξεχνούν τις περιττές. Τα LSTM έχουν παρόμοια δομή με το μοντέλο επαναλαμβανόμενης παλινδρόμησης, αλλά κάθε κόμβος στο κρυφό στρώμα αντικαθίσταται από μια μνήμη κύτταρο

μνήμης, αντί για έναν απλό νευρώνα. Επεξεργάζεται τα διαθέσιμα δεδομένα μεταβιβάζοντας πληροφορίες καθώς διαδίδεται προς τα εμπρός.

Η υιοθέτηση της μεθόδου LSTM για την πρόβλεψη των μεταβολών της ιονόσφαιρας είναι μια κατάλληλη προσέγγιση, καθώς πρόκειται για μια πρόβλεψη πρόβλεψης χρονικής ακολουθίας. Στην ακόλουθη εικόνα οπτικοποιείται διαγραμματικά παράδειγμα ενός μοντέλου LSTM που χρησιμοποιείται για την εκτίμηση του TEC. Πιο αναλυτικά το κύτταρο μνήμης ενός δικτύου LSTM περιέχει τρία διαφορετικά στοιχεία:

- το την πύλη λήθης
- την πύλη εισόδου και τον κόμβο εισόδου και
- τον κόμβο εξόδου



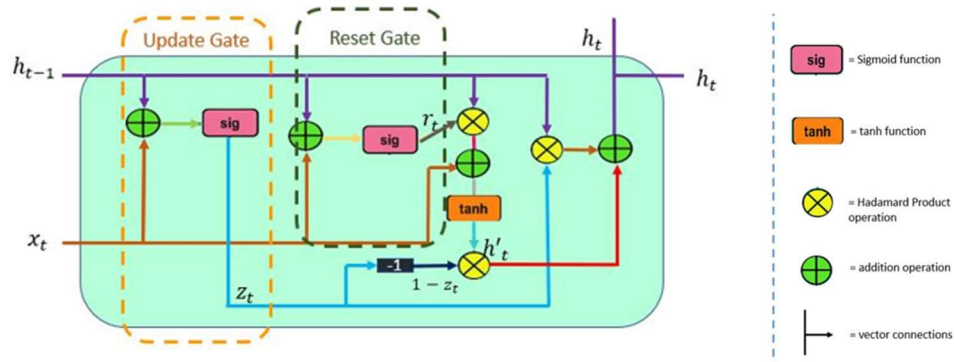
Εικόνα 13. Μοντέλο LSTM που χρησιμοποιείται για την εκτίμηση του TEC.

Θα πρέπει να διευκρινιστεί ότι η ονοματολογία «Μακροπρόθεσμη» που χρησιμοποιείται για τα δίκτυα LSTM, είναι μια βαθιά μάθηση σχετικής ορολογίας και σχετίζεται με την ικανότητα του μοντέλου να μαθαίνει από προηγούμενα ιστορικά, προηγούμενες τιμές και δεν πρέπει να συγχέονται με τις μακροπρόθεσμες χρονικές διακυμάνσεις της ιονόσφαιρας που συνεπάγεται ανάλυση πολλών ετών. Στο πλαίσιο της παρούσας μελέτης θα προσπαθούμε να μοντελοποιήσουμε καθημερινές παραλλαγές της ιονόσφαιρας και όχι αντίστοιχες μακροπρόθεσμες.

4.6 Αναδρομική Μονάδα με Πύλες (Gated Recurrent Units)

Οι λεγόμενες αναδρομικές μονάδες με πύλες ή αλλιώς GRUs (Gated Recurrent Units) [21] είναι απλούστερες μορφές μοντέλων LSTM που έχουν λιγότερες πύλες από τα το κύτταρο μνήμης LSTM καθώς αποτελούν μια γενικευμένη μορφή του LSTM δικτύου. Αναφορικά με την αρχιτεκτονική των Αναδρομικών μονάδων με πύλες είναι παρόμοια με αυτήν των LSTM, με μόνη διαφορά την ύπαρξη συγκεκριμένων πυλών,

οι οποίες ρυθμίζουν τη ροή των πληροφοριών εντός της μονάδας, χωρίς να έχουν ξεχωριστή μονάδα μνήμης. Οι μονάδες αυτές διαθέτουν δύο πύλες, οι οποίες ονομάζονται πύλες ενημέρωσης και επαναφοράς με σκοπό τον έλεγχο των πληροφοριών που εισέρχονται στη μονάδα.



Εικόνα 14. Τυπική δομή αναδρομικού νευρωνικού δικτύου με πύλες.

Πύλη Ενημέρωσης

Αυτή η πύλη ελέγχει το πόση πληροφορία από την προηγούμενη κρυφή κατάσταση h θα μεταδοθεί στην τωρινή.

Πύλη Επαναφοράς

Αυτή η πύλη ελέγχει κατά πόσο είναι σχετική η πληροφορία της προηγούμενης κρυφής κατάστασης. Αν δεν είναι την αντικαθιστά με την τωρινή πληροφορία.

Συνοψίζοντας, το GRU υπερέχει έναντι του παραδοσιακού RNN. Συγκριτικά τα αποτελέσματα με το LSTM, το GRU χρησιμοποιεί λιγότερες πράξεις τανυστών και χρειάζεται λιγότερο χρόνο για να εκπαιδευτεί. Τα αποτελέσματα των δύο είναι σχεδόν τα ίδια. Δεν υπάρχει σαφής απάντηση για το ποια παραλλαγή είχε καλύτερες επιδόσεις. Στην παρούσα μελέτη θα δοκιμάσουμε και τους δύο αλγόριθμους για να συμπεράνουμε ποιος προβλέπει την ιονοσφαιρική δραστηριότητα καλύτερα με τα δεδομένα που θα τους εισάγουμε.

Προγραμματισμός διαδικασιών σε Python

5.1 Η Python ως γλώσσα προγραμματισμού

Η γλώσσα προγραμματισμού Python χρησιμοποιήθηκε για την υλοποίηση του τεχνικού τμήματος της παρούσας μελέτης, καθώς με τη χρήση αυτής προγραμματίστηκαν τα μοντέλα πρόβλεψης ιονοσφαιρικής δραστηριότητας, εκ των οποίων επιλέχθηκε το βέλτιστο.

Η Python είναι μια διερμηνευμένη, διαδραστική, αντικειμενοστραφής γλώσσα προγραμματισμού [22]. Παρέχει δομές δεδομένων υψηλού επιπέδου και αυτό την καθιστά προσιτή και ευνόητη. Διαθέτει ένα εξαιρετικά απλό και κομψό συντακτικό και είναι όμως μια ισχυρή και γενικού σκοπού γλώσσα προγραμματισμού. Σχεδιάστηκε το 1990 από τον Guido van Rossum.

Διακρίνεται λόγω του ότι έχει πολλές βιβλιοθήκες που διευκολύνουν ιδιαίτερα αρκετές συνηθισμένες εργασίες και για την ταχύτητα εκμάθησής της. Μειονεκτεί όμως, στο γεγονός ότι επειδή είναι διερμηνευόμενη είναι πιο αργή από τις μεταγλωττιζόμενες (compiled) γλώσσες, όπως η C και η C++. Για αυτόν τον λόγο δεν είναι κατάλληλη για γραφή λειτουργικών συστημάτων.

Όπως και πολλές άλλες γλώσσες σεναρίων είναι δωρεάν, ακόμη και για εμπορικούς σκοπούς, και μπορεί να εκτελεστεί σε πρακτικά οποιονδήποτε σύγχρονο υπολογιστή. Ένα πρόγραμμα Python μεταγλωττίζεται αυτόματα από τον διερμηνέα σε κώδικα byte ανεξάρτητο από την πλατφόρμα, ο οποίος στη συνέχεια διερμηνεύεται. Εκτελούμε μη τροποποιημένα στοιχεία γραμμένα σε Python κάτω από Linux, Windows NT, 98, 95, IRIX, SunOS, OSF.

Το περιβάλλον που χρησιμοποιήθηκε για την εκμετάλλευση των δυνατοτήτων της γλώσσας προγραμματισμού Python είναι το Google Colab.

5.2 Google Colab

Το Colaborator [23], ή εν συντομία "Colab", είναι ένα προϊόν της Google Research. Το Colab επιτρέπει σε οποιονδήποτε να γράφει και να εκτελεί αυθαίρετο κώδικα Python μέσω του προγράμματος περιήγησης και είναι ιδιαίτερα κατάλληλο για μηχανική μάθηση, ανάλυση δεδομένων και εκπαίδευση. Πιο τεχνικά, το Colab είναι μια φιλοξενούμενη υπηρεσία σημειωματάρου Jupyter που δεν απαιτεί καμία εγκατάσταση για να χρησιμοποιηθεί, ενώ παρέχει δωρεάν πρόσβαση σε υπολογιστικούς πόρους, συμπεριλαμβανομένων των GPU.

Επιπροσθέτως, το Google Colab έχει ήδη εγκατεστημένες σχεδόν όλες τις απαραίτητες βιβλιοθήκες, οι οποίες είναι διαθέσιμες ανά πάσα στιγμή. Ένα ιδιαίτερο χαρακτηριστικό του προγράμματος είναι πως πραγματοποιεί αυτόματη αποθήκευση

στο Cloud και έτσι δεν υπάρχει κίνδυνος να καταστραφεί ο αλγόριθμος που έχει ήδη υλοποιηθεί. Ακόμα, το Google Colab, επιτρέπει τη συνεργασία μεταξύ των προγραμματιστών για μία κοινή εργασία.

5.3 Βιβλιοθήκες που χρησιμοποιήθηκαν

Το TensorFlow [24], είναι μια ολοκληρωμένη πλατφόρμα ανοιχτού κώδικα για μηχανική μάθηση. Διαθέτει ένα ολοκληρωμένο, ευέλικτο σύστημα εργαλείων, βιβλιοθηκών και πόρων που επιτρέπει στους ερευνητές να προωθήσουν την τελευταία λέξη της τεχνολογίας στη μηχανική μάθηση και οι προγραμματιστές να κατασκευάζουν και να αναπτύσσουν εύκολα εφαρμογές με υποστήριξη μηχανικής μάθησης.

Το Keras [25], είναι ένα API βαθιάς μάθησης γραμμένο σε γλώσσα προγραμματισμού Python, που τρέχει πάνω στην πλατφόρμα μηχανικής μάθησης TensorFlow. Αναπτύχθηκε με έμφαση στη δυνατότητα γρήγορης δημιουργίας αλγορίθμων και πειραματισμού αυτών. Με βασικό στόχο, να είσαι σε θέση να πηγαίνει από την ιδέα στο αποτέλεσμα όσο το δυνατόν γρηγορότερα, ένας στόχος που αποτελεί καίριος στην σωστή και ορθολογική έρευνα.

Η βιβλιοθήκη Pandas, [26] αποτελεί μια βιβλιοθήκη της Python η οποία προσφέρει δομές δεδομένων και λειτουργίες για το χειρισμό αριθμητικών πινάκων και χρονοσειρών. Είναι δωρεάν λογισμικό που κυκλοφορεί με την άδεια BSD τριών ρητρών. Το όνομα προέρχεται από τον όρο "Panel Data", ένας όρος οικονομετρίας για σύνολα δεδομένων που περιλαμβάνουν παρατηρήσεις σε πολλαπλές χρονικές περιόδους για τα ίδια άτομα. Υπάρχει η δυνατότητα εισαγωγής δεδομένων από διάφορες μορφές αρχείων, όπως CSV, JSON, πίνακες ή ερωτήματα βάσεων δεδομένων SQL και Microsoft Excel. Επιτρέπει διάφορες λειτουργίες χειρισμού δεδομένων, όπως συγχώνευση, αναμόρφωση, επιλογή, καθώς και λειτουργίες καθαρισμού δεδομένων και σύγχυσης δεδομένων.

Η NumPy, αποτελεί μια βιβλιοθήκη της Python η οποία υλοποιήθηκε με στόχο την επεξεργασία και την διαχείριση μαθηματικών προβλημάτων μέσω της δομής πινάκων [27]. Η NumPy βρίσκει πληθώρα εφαρμογών σε προβλήματα γραμμικής άλγεβρας, μετασχηματισμού Fourier και υλοποίηση πράξεων μεταξύ πινάκων. Η NumPy δημιουργήθηκε το 2005 από τον Travis Oliphant και είναι ένα εργαλείο ανοιχτού κώδικα που μπορεί να χρησιμοποιηθεί ελεύθερα. Ο λόγος που χρησιμοποιείται η συγκεκριμένη βιβλιοθήκη είναι γιατί στην Python υπάρχουν οι λίστες που εξυπηρετούν το σκοπό των πινάκων, αλλά είναι αργές στην επεξεργασία τους. Η NumPy στοχεύει στην παροχή ενός πίνακα που για οποιαδήποτε πράξη είναι αρκετά πιο γρήγορος από μια παραδοσιακή λίστα.

Τέλος η βιβλιοθήκη Matplotlib είναι μία βιβλιοθήκη της Python που έχει σχεδιαστεί για την παραγωγή διαγραμμάτων. Παρέχει αντικειμενοστραφή API, για ενσωματωμένα γραφήματα σε εφαρμογές χρησιμοποιώντας τις εργαλειοθήκες γενικής χρήσης του GUI. Η Matplotlib δημιουργήθηκε από τον John D. Hunter και

έκτοτε έχει ενεργή κοινότητα ανάπτυξης και είναι διαθέσιμη με την άδεια ανοιχτού λογισμικού BSD. Στην εργασία, χρησιμοποιείται με σκοπό να αποδοθούν τα απαραίτητα γραφήματα.

5.4 Υλοποίηση σε Python

Στο παρόν υποκεφάλαιο αναλύεται τμηματικά το σύνολο του κώδικα που συντέθηκε για την εκπόνηση της μελέτης. Συνοπτικά θα αναφέρουμε ότι, μετά την προετοιμασία των δεδομένων, όπως θα αναλύσουμε στο επόμενο κεφάλαιο, αυτά εισήχθησαν στα μοντέλα για την εκπαίδευσή και την αξιολόγησή τους με σκοπό την ανάδειξη του βέλτιστου μοντέλου πρόβλεψης.

Αρχικά εισάγουμε τις βιβλιοθήκες που χρειάστηκαν για την κλήση των κατάλληλων αλγορίθμων.

```
import pandas as pd
import numpy as np
import tensorflow
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Flatten, InputLayer, Reshape
from tensorflow.keras.layers import LSTM, TimeDistributed, Bidirectional, Conv1D, SimpleRNN, GRU, Conv2D
import os
```

Εικόνα 15. Εισαγωγή βιβλιοθηκών.

Στη συνέχεια γίνεται εισαγωγή επιλεγμένου δεδομένων, συγκεκριμένων παραμέτρων, καθώς όπως θα αναφέρουμε και σε ακόλουθο κεφάλαιο, από προγενέστερη της παρούσης μελέτη εξήχθη το συμπέρασμα πως βέλτιστο σενάριο αποτελεί εκείνο στο οποίο συνδυάζονται οι Γεωμαγνητικές και οι Solar Radio Flux παράμετροι επιρροής των τιμών TEC.

```
InputDataFrame = Data[['kp', 'ap', 'D', 'SML', 'SMU', 'fluxtime', 'fluxjulian', 'fluxcarrington',
                      'fluxobsflux', 'fluxadjflux', 'fluxursi', 'dts']]
```

Εικόνα 16. Επιλογή παραμέτρων εκπαίδευσης.

Έπειτα επιλέξουμε τα δεδομένα πρόβλεψης, για την παρούσα μελέτη τιμές STEC ή VTEC, και ακολούθως εντοπίζονται οι μέγιστες τιμές των δεδομένων, δημιουργούνται οι πίνακες και τα δεδομένα κανονικοποιούνται για αποφυγή αρνητικών τιμών κατά τους υπολογισμούς.

```
InputArrayNormalized = np.empty([InputArray.shape[0], InputArray.shape[1]])
OutputArrayNormalized = np.empty([OutputArray.shape[0], OutputArray.shape[1]])
for i in range(0,12):
    invar = InputVariables[i]
    InputArrayNormalized[:,i] = InputArray[:,i]/max_values[invar]

OutputArrayNormalized[:] = OutputArray[:]/np.amax(OutputArray)
```

Εικόνα 17.Κανονικοποίηση δεδομένων.

Τα δεδομένα στη συνέχεια φορτώνονται σε τρισδιάστατους ταυστές με βάθος 7 ημερών και ακολουθεί μια διαδικασία τυχαίου «ανακατέματος» των δεδομένων, καθώς αποτελούν συνεχόμενα δεδομένα χρονοσειράς και θέλουμε να αποφύγουμε την υπερπροσαρμογή των μοντέλων στα δεδομένα εκπαίδευσης.

```
randomize_idx = np.asarray(range(0, len(X)-1))
np.random.shuffle(randomize_idx)
train_index = randomize_idx[0:round(0.85*len(randomize_idx))]
test_index = randomize_idx[len(train_index):len(randomize_idx)]
print("TRAIN:", train_index, "TEST:", test_index)
X_train = X[train_index]
y_train = Y[train_index]
X_test = X[test_index]
y_test = Y[test_index]
```

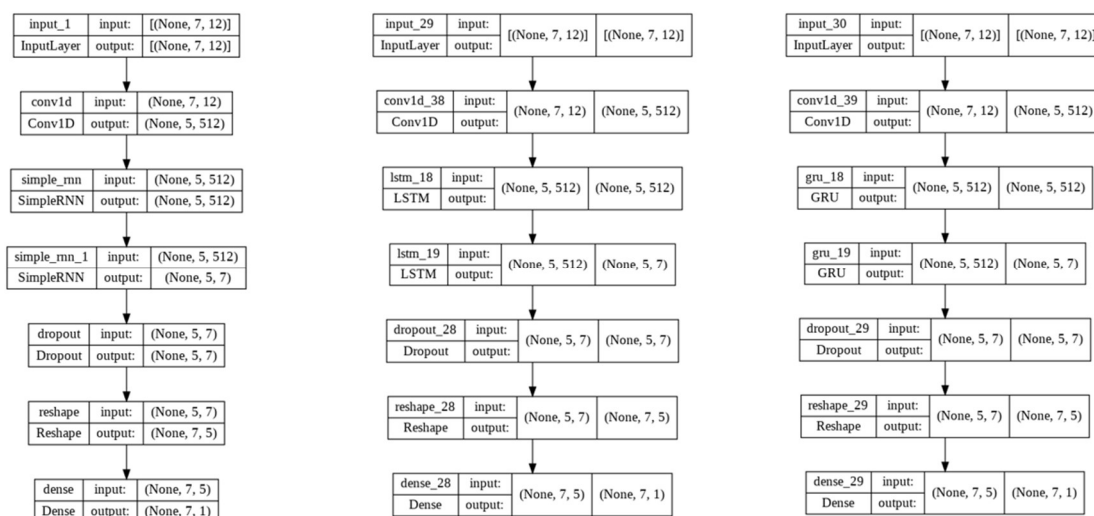
Εικόνα 18. Τυχαίο "ανακάτεμα" δεδομένων.

Σε αυτό το σημείο έχει εισαχθεί η επιλογή πλήθους εποχών και πλήθους φίλτρων (υπερπαράμετροι) που θα εφαρμοστούν στα δεδομένα εισόδου. Αναφορικά να πούμε ότι για τα τέσσερα μοντέλα (RNN, LSTM & GRU) προσπελάστηκαν σενάρια με πλήθος φίλτρων 64, 128, 256 και 512 όπως φαίνεται και στα σχόλια του κώδικα της εικόνας.

```
[ ] hidden_units= 512 #64 128 256 512
conv_filters = 512 #64 128 256 512
epochs = 100
```

Εικόνα 19. Δυνατότητα τροποποίησης υπερπαραμέτρων.

Ακολουθεί η αρχιτεκτονική των μοντέλων πρόβλεψης ιονοσφαιρικής δραστηριότητας, στην προκειμένη περίπτωση για το βέλτιστο σενάριο συνδυασμού των δώδεκα παραμέτρων και πλήθος φίλτρων δεδομένων εισόδου 512.



Εικόνα 20. Αρχιτεκτονική μοντέλων RNN, LSTM & GRU από αριστερά προς τα δεξιά.

Ξεκινώντας, υπάρχει το επίπεδο εισόδου το οποίο δέχεται sequences με τη μορφή τρισδιάστατου τανυστή (3D tensor). Οι συγκεκριμένες διαστάσεις αφορούν πρώτα τον αριθμό συστάδων σειρών, δεύτερον τον παρελθοντικό αριθμό ημερών που συγκεντρώνει τα δεδομένα και τρίτον ο αριθμός παραμέτρων.

Έπειτα, πραγματοποιείται ένα επίπεδο μονοδιάστατης συνέλιξης (1D – Convolution) το οποίο είναι υπεύθυνο για την εξαγωγή επιπλέον χαρακτηριστικών. Βασικά ορίσματα του block 1D – Convolution είναι ο βασικός αριθμός φίλτρων, το μέγεθος του φίλτρου και τέλος η συνάρτηση ενεργοποίησης. Σημειώνεται πως για την παρούσα διπλωματική ο αριθμός των φίλτρων αλλάζει κάθε φορά με σκοπό την εύρεση του καλύτερου συνδυασμού για κάθε σενάριο μελέτης. Η συνάρτηση ενεργοποίησης είναι η ReLU.

Η διαφορά των δυο αρχιτεκτονικών έγκειται στα δυο επόμενα block τα οποία διαχειρίζονται την πληροφορία και αυτά είναι το simple - RNN το LSTM και το GRU, δηλαδή μετά την διαδικασία συνέλιξης η πληροφορία περνάει ως είσοδο σε δυο διαδοχικά επαναλαμβανόμενα μπλοκ νευρωνικών δικτύων.

Τα δυο επόμενα layers είναι το dropout και το reshape. Ξεκινώντας από το πρώτο επίπεδο το dropout θέτει μερικά δεδομένα εισόδου ίσα με το 0 σύμφωνα με ένα ποσοστό κατά τη διάρκεια εκπαίδευσης, βοηθώντας το μοντέλο να αποφύγει την υπερπροσαρμογή του. Το δεύτερο επίπεδο reshape αναδημιουργεί την δομή εξόδου πριν το τελικό layer που είναι το υπεύθυνο για την διαδικασία της παλινδρόμησης Dense layer. Όπως φαίνεται και στις αρχιτεκτονικές η τελική δομή, δηλαδή η έξοδος του δικτύου έχει διαστάσεις 7,1 δηλαδή βλέπει για τις επόμενες 7 μέρες τι τιμές θα πάρουν οι παράμετροι STEC & VTEC αντίστοιχα.

Με το πέρας προσπέλασης αλγορίθμου κάθε μοντέλου γίνεται συγκεντρωτικά υπολογισμός των μέτρων μετρητικών δεικτών αξιολόγησης MAE και MSE, των οποίων τα αποτελέσματα καταγράφονται σε πίνακα για την αξιολόγηση των αποτελεσμάτων και τελικώς ανάδειξη βέλτιστου μοντέλου.

```
plt.rcParams["figure.figsize"] = [5.00, 5.50]
plt.rcParams["figure.autolayout"] = True
fig, ax = plt.subplots(1,1)
data=[[MSE_RNN,MAE_RNN],
      [MSE_LSTM,MAE_LSTM],
      [MSE_GRU,MAE_GRU]]
column_labels=["MSE", "MAE"]
row=["RNN", "LSTM", "GRU"]
df=pd.DataFrame(data,columns=column_labels)
df.update(df.applymap('{:,.4f}'.format))
ax.axis('tight')
ax.axis('off')
the_table = ax.table(cellText=df.values, colLabels=df.columns, rowLabels=row, fontsize=15, loc="center", cellLoc='center')
the_table.auto_set_font_size(False)
the_table.set_fontsize(14)
plt.show()
```

Εικόνα 21. Υπολογισμός των μέτρων μετρητικών δεικτών αξιολόγησης MAE και MSE.

Διαχείριση δεδομένων

6.1 Εισαγωγικές έννοιες

Στο ακόλουθο κεφάλαιο θα γίνει αναλυτική περιγραφή της πηγής συλλογής των δεδομένων από κάθε διαθέσιμο φορέα. Πιο συγκεκριμένα συλλέχτηκαν Observation Files από το σταθμό COTE00ATA και δεδομένα για τις παραμέτρους επιρροής τιμών TEC, οι οποίες αναλύθηκαν στο Κεφάλαιο 3.

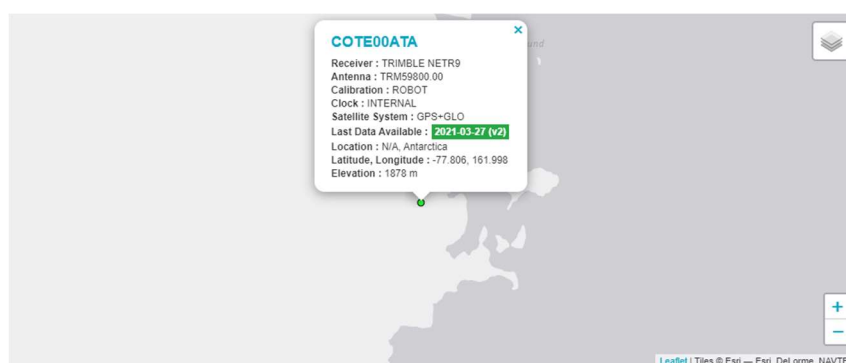
6.2 Περιγραφή των δεδομένων

6.2.1 Observation Files του σταθμού COTE00ATA

Για την εκπαίδευση των μοντέλων πρόβλεψης ιονοσφαιρικής δραστηριότητας, χρησιμοποιήθηκαν δεδομένα γνωστών ιονοσφαιρικών μεταβολών σε συνεχείς χρονοσειρές. Για την άντληση των δεδομένων αυτών υλοποιήθηκαν οι παρακάτω διαδικασίες.

Αρχικά επιλέχθηκε ο δορυφορικός σταθμός COTE00ATA, ο οποίος βρίσκεται στην Ανταρκτική και επιλέχθηκαν να αποθηκευτούν οι ημερήσιες μετρήσεις του κατά τους μήνες Ιανουάριο, Φεβρουάριο, Μάρτιο και Απρίλιο του έτους 2018.

Πιο συγκεκριμένα πραγματοποιήθηκε download στα Rinx Observation files του σταθμού.

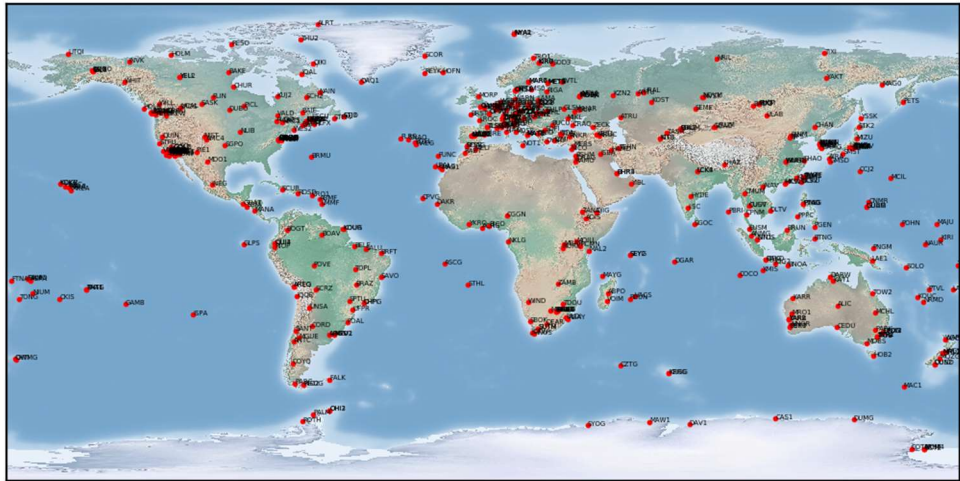


Εικόνα 22. Σταθμός COTE00ATA (Πηγή: IGS)

Η επιλογή του συγκεκριμένου σταθμού έγινε για τους εξής λόγους:

- Το φαινόμενο της ιονοσφαιρικής έξαρσης (ionospheric scintillation) συμβαίνει κυρίως στις πολικές περιοχές και σε μία ζώνη $\pm 30^\circ$ γύρω από το γεωμαγνητικό ισημερινό και διαρκεί έως μερικά λεπτά.
- Ήταν από τους λίγους σταθμούς που είχε συνεχή δεδομένα

- Θεωρήθηκε ότι δεν επηρεάζεται από κανενός είδους ανθρώπινες παρεμβάσεις (κατασκευές, δίκτυα τηλεφωνίας κτλ)



Εικόνα 23. Όλοι οι διαθέσιμοι σταθμοί του συστήματος GNSS (Πηγή: IGS)

Για το σταθμό αυτό ελήφθησαν τα observation files για τους μήνες Ιανουάριο – Απρίλιο του έτους 2018. Η επιλογή των συγκεκριμένων μηνών έγινε εξαιτίας της ύπαρξης ημερών με έντονη ηλιακή δραστηριότητα.

Τα αρχεία ήταν τύπου RINEX (βλ. 6.2.1.3).όπως φαίνεται και στην παρακάτω εικόνα και για την επίλυση τους και την εξαγωγή των δεδομένων TEC που απαιτούνταν για την εκτέλεση της παρούσας διπλωματικής έγινε χρήση του λογισμικού GPS GOPI (βλ. 6.2.1.4).

```

2.11      OBSERVATION DATA      M (MIXED)      RINEX VERSION / TYPE
teqc 2018Jan30 UNAVCO Archive Ops 20180201 01:02:11UTC/PGM / RUN BY / DATE
Solaris x86_64 AMD64 cc SC5.8 -xarch=amd64 [+]++ COMMENT
0.000 (antenna height) COMMENT
-77.80590314 (latitude) COMMENT
+161.99781078 (longitude) COMMENT
1878.374 (elevation) COMMENT
BIT 2 OF LLI FLAGS DATA COLLECTED UNDER A/S CONDITION COMMENT
COTE MARKER NAME
560960001 MARKER NUMBER
Terry Wilson Ohio State University OBSERVER / AGENCY
5034K69672 TRIMBLE NETR9 5.10 REC # / TYPE / VERS
4852A62823 TRM59800.00 SCIS ANT # / TYPE
-1285757.4165 417822.4915 -6214230.8474 APPROX POSITION XYZ
0.00000 0.00000 0.00000 ANTENNA: DELTA H/E/N
1 1 WAVELENGTH FACT L1/2
7 L1 L2 C1 P2 P1 S1 S2 # / TYPES OF OBSERV
30.0000 INTERVAL
18 LEAP SECONDS
Input file: cote201801310000a.tgd COMMENT
Forced Modulo Declaration to 30 seconds COMMENT
RINEX file created by UNAVCO GPS Archive. COMMENT
For more information contact archive-gps@unavco.org COMMENT
Monument ID: 21831 COMMENT
UNAVCO 4-char name: COTE COMMENT
4-char name from Log on data file: COTE COMMENT
Monument location: -77.8059 161.9978 1878.1 COMMENT
visit ID: 117469 COMMENT
POLENET-NSF/OSU/UNAVCO COMMENT
doi:10.7283/TS6TSKGN COMMENT
End of DB comments COMMENT
SNR is mapped to RINEX snr flag value [0-9] COMMENT
L1 & L2: min(max(int(snr_dBHz/6), 0), 9) COMMENT
2018 1 31 0 0 0.0000000 GPS TIME OF FIRST OBS
END OF HEADER
18 1 31 0 0 0.0000000 0 23R17R06R08R24G22G32R01G17R07G31G14R15
G25R23G01G19G12R16G02G06R14G24G03
112379164.792 8 87406084.335 7 21000737.836 21000740.309 21000736.313
46.500 46.000
127147974.451 5 98892907.495 4 23827481.977 23827484.516 23827480.402
32.400 27.400
114161736.087 7 88792544.948 7 21318910.219 21318913.691 21318909.824
45.600 45.900
104291009.446 7 81115254.573 6 19502946.250 19502946.688 19502944.441
47.200 38.000
119202007.791 7 92884700.20245 22683386.516 22683388.270
46.900 33.000

```

Εικόνα 24. Τυπική μορφή αρχείου RINEX.

6.2.1.1 CDDIS

Το Crustal Dynamics Data Information System (CDDIS) [29] αναπτύχθηκε αρχικά για να παρέχει μια κεντρική τράπεζα δεδομένων για το Crustal Dynamics Project (CDP) της NASA. Το σύστημα συνεχίζει να υποστηρίζει την κοινότητα διαστημικής γεωδαισίας και γεωδυναμικής μέσω του Έργου Διαστημικής Γεωδαισίας της NASA καθώς και της Επιχείρησης Earth Science Enterprise της NASA. Το CDDIS ιδρύθηκε το 1982 ως ειδική τράπεζα δεδομένων για την αρχειοθέτηση και τη διανομή συνόλων δεδομένων που σχετίζονται με τη γεωδαισία του διαστήματος. Σήμερα, το CDDIS αρχειοθετεί και διανέμει κυρίως δεδομένα GNSS (GNSS, επί του παρόντος Παγκόσμιο Σύστημα Εντοπισμού Θέσης GPS και Παγκόσμιο Δορυφορικό Σύστημα Πλοήγησης GLONASS), SLR (τόσο σε τεχνητούς δορυφόρους, SLR, και σε σεληνιακό, LLR), Very Long Baseline Interferometry (VLBI), και Doppler Orbitography and Radio-positioning Integrated by Satellite (DORIS) για μία συνεχώς αυξανόμενη κοινότητα χρηστών γεωφυσικών.

Το CDDIS έχει χρησιμεύσει ως παγκόσμιο κέντρο δεδομένων για τη Διεθνή Υπηρεσία GNSS (IGS) από το 1992. Υποστηρίζει επίσης ενεργά τη International Laser Ranging Service (ILRS), τη International VLBI Service for Geodesy and Astrometry (IVS), τη Διεθνή Υπηρεσία DORIS (IDS) και τη Διεθνή Υπηρεσία Συστημάτων Περιστροφής και Αναφοράς Γης (IERS) ως παγκόσμιο κέντρο δεδομένων.

6.2.1.2 IGS

Η Διεθνής Υπηρεσία GNSS (IGS) [30] έχει εξασφαλίσει ανοιχτή πρόσβαση σε προϊόντα δεδομένων GNSS υψηλής ποιότητας από το 1994. Αυτά τα προϊόντα επιτρέπουν την πρόσβαση στο οριστικό παγκόσμιο πλαίσιο αναφοράς για επιστημονικές, εκπαιδευτικές και εμπορικές εφαρμογές πράγμα που είναι ένα τεράστιο όφελος για το κοινό και ένα βασικό στοιχείο υποστήριξης για την επιστημονική πρόοδο.

- Μια εθελοντική ομοσπονδία περισσότερων από 200 αυτοχρηματοδοτούμενων φορέων, πανεπιστημίων και ερευνητικών ιδρυμάτων σε περισσότερες από 100 χώρες/περιοχές. συνεργάζονται για να παρέχουν τις δορυφορικές τροχιές GPS υψηλότερης ακρίβειας στον κόσμο.
- Παροχή δωρεάν και ανοιχτής πρόσβασης στα προϊόντα υψηλότερης ακρίβειας που είναι διαθέσιμα για επιστημονική πρόοδο και δημόσιο όφελος. Αυτά τα προϊόντα υποστηρίζουν μια μεγάλη ποικιλία εφαρμογών που αγγίζουν εκατομμύρια χρήστες σε σχεδόν όλα τα τμήματα της παγκόσμιας οικονομίας.
- Παραγωγή προϊόντων που υποστηρίζουν την υλοποίηση του Διεθνούς Επίγειου Πλαισίου Αναφοράς παρέχοντας παράλληλα πρόσβαση σε δεδομένα παρακολούθησης από περισσότερους από 400 σταθμούς αναφοράς παγκοσμίως.

- Εργασία για τη συνεχή ανάπτυξη νέων εφαρμογών και προϊόντων μέσω Ομάδων Εργασίας και Πιλοτικών Έργων
- Υποστήριξη γεωδαιτικής έρευνας και επιστημονικών δημοσιεύσεων
- Λειτουργία ως στοιχείο του Παγκόσμιου Συστήματος Γεωδαιτικής Παρατήρησης (GGOS) και μέλος του Παγκόσμιου Συστήματος Δεδομένων (WDS)

6.2.1.3 RINEX

Στον τομέα της γεωδαισίας, το Receiver Independent Exchange Format (RINEX) [31] είναι μια μορφή ανταλλαγής δεδομένων για ακατέργαστα δεδομένα συστήματος δορυφορικής πλοήγησης. Αυτό επιτρέπει στον χρήστη να επεξεργάζεται εκ των υστέρων τα δεδομένα που λαμβάνονται για να παράγει ένα πιο ακριβές αποτέλεσμα — συνήθως με άλλα δεδομένα άγνωστα στον αρχικό δέκτη, όπως καλύτερα μοντέλα των ατμοσφαιρικών συνθηκών τη στιγμή της μέτρησης.

Η τελική έξοδος ενός δέκτη πλοήγησης είναι συνήθως η θέση, η ταχύτητά του ή άλλα σχετικά φυσικά μεγέθη. Ωστόσο, ο υπολογισμός αυτών των ποσοτήτων βασίζεται σε μια σειρά μετρήσεων από έναν ή περισσότερους δορυφορικούς αστερισμούς. Αν και οι δέκτες υπολογίζουν τις θέσεις σε πραγματικό χρόνο, σε πολλές περιπτώσεις είναι ενδιαφέρον να αποθηκεύονται ενδιάμεσα μέτρα για μελλοντική χρήση. Το RINEX είναι η τυπική μορφή που επιτρέπει τη διαχείριση και τη διάθεση των μέτρων που παράγονται από έναν δέκτη, καθώς και την off-line επεξεργασία τους από πληθώρα εφαρμογών, ανεξάρτητα από τον κατασκευαστή του δέκτη και της εφαρμογής υπολογιστή.

Η μορφή RINEX έχει σχεδιαστεί για να εξελίσσεται με την πάροδο του χρόνου, προσαρμοζόμενη σε νέους τύπους μετρήσεων και νέα συστήματα δορυφορικής πλοήγησης. Η πρώτη έκδοση RINEX αναπτύχθηκε από τον W. Gurtner το 1989 και δημοσιεύτηκε από τους W. Gurtner και G. Mader στο CSTG GPS Bulletin του Σεπτεμβρίου/Οκτωβρίου 1990. Από το 1993 το RINEX 2 είναι διαθέσιμο, το οποίο έχει αναθεωρηθεί και υιοθετηθεί πολλές φορές. Το RINEX επιτρέπει την αποθήκευση των μετρήσεων ψευδοαπόστασης, φάσης φορέα, Doppler και σήματος προς θόρυβο από GPS (συμπεριλαμβανομένων σημάτων εκσυγχρονισμού GPS, π.χ. L5 και L2C), GLONASS, Galileo, Beidou, μαζί με δεδομένα από δορυφόρους EGNOS και WAAS συστήματα αύξησης (SBAS), QZSS, ταυτόχρονα. Η έκδοση 3.02 του RINEX υποβλήθηκε τον Απρίλιο του 2013 και περιέχει νέους κωδικούς παρατήρησης από συστήματα GPS ή Galileo. Η πιο πρόσφατη έκδοση είναι το RINEX 4.00 από τον Δεκέμβριο του 2021.

Αν και δεν αποτελεί μέρος της μορφής RINEX, το σχήμα συμπίεσης Hatanaκα χρησιμοποιείται συνήθως για τη μείωση του μεγέθους των αρχείων RINEX, με αποτέλεσμα μια μορφή CompactRINEX ή CRINEX που βασίζεται σε ASCII. Χρησιμοποιεί χρονικές διαφορές υψηλότερης τάξης για να μειώσει τον αριθμό των χαρακτήρων που απαιτούνται για την αποθήκευση δεδομένων χρόνου.

6.2.1.4 Πρόγραμμα GPS_GOP1


Εν συνεχεία με τη χρήση του προγράμματος GBS_GOP1, [32] πραγματοποιήθηκε η ανάλυση των αρχείων και η επεξεργασία τους για την εξαγωγή δεδομένων TEC.

Πιο συγκεκριμένα στο συγκεκριμένο πρόγραμμα υπάρχει η δυνατότητα ομαδικής επεξεργασίας των αρχείων εισόδου (μορφές RINEX 2 & 3 κ.λπ.) για παράδειγμα: όλα τα αρχεία του μήνα, έτος, όλοι οι σταθμοί και όλα τα αρχεία στον κατάλογο.

- Λαμβάνει ephemeris από το αρχείο πλοήγησης IGS, έχει τη δυνατότητα αυτόματης λήψης του αρχείου πλοήγησης εάν είναι συνδεδεμένο στο διαδίκτυο εκτός αν βρει το αρχείο στον ίδιο κατάλογο με τα δεδομένα.
- Υπολογίζει το TEC από τα δεδομένα παρατήρησης του GPS Rinex, Novatel SCINDA και Leica.
- Ολισθήσεις κύκλου διεργασίας σε δεδομένα φάσης
- Ανάγνωση δορυφορικών προκαταλήψεων από αρχεία κωδικών DCB IGS, αν δεν είναι διαθέσιμα, τα υπολογίζει.
- Υπολογίζει την προκατάληψη του δέκτη
- Υπολογίζει τις διακαναλικές προκαταλήψεις για διαφορετικούς δορυφόρους στον δέκτη.
- Σχεδιάζει τις κάθετες τιμές TEC στην οθόνη και εγγράφει αρχεία εξόδου ascii (*.CMN & *.STD) στο ίδιο κατάλογο του αρχείου δεδομένων.


Τα δεδομένα TEC που παρήχθησαν στη συγκεκριμένη διπλωματική εργασία είναι ανά 30 sec.

Τα αποτελέσματα του συγκεκριμένου προγράμματος γίνονται στις παρακάτω εικόνες. Ενδεικτικά παρατίθενται τα αποτελέσματα του εν λόγω προγράμματος για την 01 Ιανουαρίου 2018. Πιο συγκεκριμένα στην ακολούθως παρουσιάζεται η συμπεριφορά των τιμών TEC ανά ώρα με βάση το γεωγραφικό πλάτος.



Εικόνα 25. Συμπεριφορά των τιμών TEC ανά ώρα με βάση το γεωγραφικό πλάτος

Στη συνέχεια της επεξεργασίας των δεδομένων προκύπτουν τα αποτελέσματα της εικόνας. Χαρακτηριστικά με την κόκκινη γραμμή απεικονίζεται ο μέσος όρος (μ.ο) της τιμής TEC για όλους τους δορυφόρους (Δ/Φ) ενώ με τις πράσινες γραμμές παρουσιάζεται η τιμή VTEC (vertical tec) για κάθε Δ/Φ ξεχωριστά. Η διαφορά των δύο διαγραμμάτων είναι πως στο δεξιά διάγραμμα έχουν αφαιρεθεί οι «επιρροές» των RX ανά Δ/Φ.

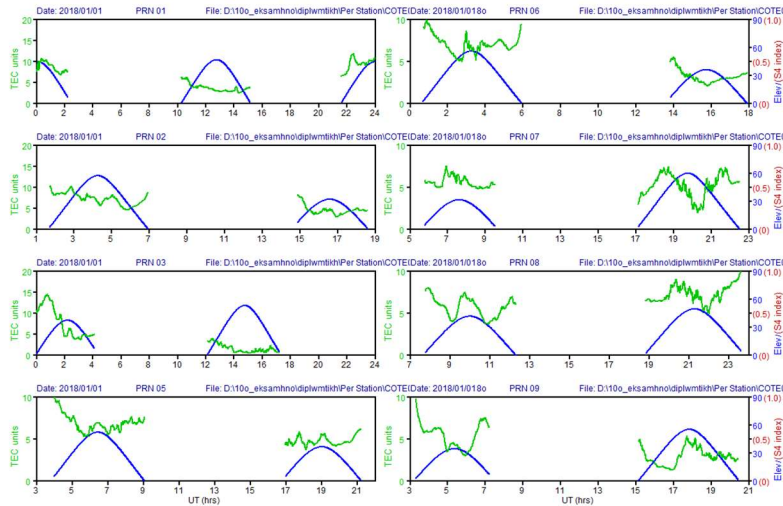


Εικόνα 26. Τιμές TEC ανά Δορυφόρο

Η επεξεργασία δεδομένων GPS για απόλυτη απόδοση τιμών TEC απαιτεί καλό υπολογισμό της «επιρροής» RX, τα οποία όμως περιλαμβάνουν ορισμένες υποθέσεις που μπορεί να θέσουν σε κίνδυνο την πραγματική ποιότητα των δεδομένων.

Γι αυτό το λόγο προτιμητέο είναι το αποτέλεσμα της διακύμανσης της τιμής TEC του πρώτου διαγράμματος, το οποίο αποδίδει την απόλυτη διακύμανση της τιμής TEC σε σχέση με την ώρα.

Τέλος η τελική οπτικοποίηση της φάσης της επεξεργασίας των δομένων του επιλεγμένου σταθμού, είναι τα διαγράμματα της εικόνας. Σε αυτήν φαίνεται η διακύμανση της τιμής TEC (πράσινες γραμμές) την 01 Ιανουαρίου 2018, ανά Δ/Φ (PRN 01, 02 κλπ) σε κάποιο εύρος υψομέτρων.



Εικόνα 27. Η διακύμανση της τιμής TEC την 01 Ιανουαρίου 2018, ανά Δ/Φ (PRN 01, 02 κλπ) σε κάποιο εύρος υψομέτρων.

6.2.2 Παράμετροι επιρροής τιμών Tec

Για την πρόβλεψη της ιονοσφαιρικής δραστηριότητας, χρησιμοποιήθηκαν ως τιμές εισόδου, τιμές συγκεκριμένων παραμέτρων επιρροής τιμών TEC, οι οποίες αναλύθηκαν στο Κεφάλαιο 3. Δεδομένα για αυτές τις παραμέτρους συλλέχθηκαν από τις δομές που θα περιγραφούν στα ακόλουθα υποκεφάλαια.. Όλα τα δεδομένα που συλλέχθηκαν, καταγράφηκαν σε ένα αρχείο excel, το οποίο αποτέλεσε την κύρια πηγή δεδομένων εισόδου για το προς εκπαίδευση νευρωνικό δίκτυο. Παρακάτω παρατίθεται ενδεικτική εικόνα από το εν λόγω πρόγραμμα εργασίας. Όλα τα δεδομένα που χρησιμοποιήθηκαν σαν είσοδο στο νευρωνικό δίκτυο παρατίθενται στο Παράρτημα Α της παρούσας διπλωματικής εργασίας.

Πίνακας 2. Excel με τα δεδομένα των παραμέτρων που χρησιμοποιήθηκαν

Date	Time	STEC	VTEC	DST	GEOMAGNETIC		Solar Radio Flux						Sunspot Number (3 hours)											
					Kp (3 hour)	AE (3 hours)	f _{min}	f _{min} Jan	f _{min} Carington	f _{min} Robust	f _{min} Flux	f _{min} SI	Daily Total Sunspot Number	Daily North Sunspot Number	Daily South Sunspot Number	Standard Deviation of Raw Daily Total Sunspot Data	Standard Deviation of Raw Daily North Sunspot Data	Standard Deviation of Raw Daily South Sunspot Data	Number of Observations for Daily Total Sunspot	Number of Observations for Daily North Sunspot	Number of Observations for Daily South Sunspot			
2/1/2018	0	11.157	1.023296	4	2.687	12	1	-98.39444	53.3	0	2458149.9875	2200.45	89.15	79.25	62.825	12	12	0	1.1	0.3	0	0	39	6
	3	10.93084	0.92052	4	0.333	2	1	-98.03033	39.088889	3	2458149.9875	2200.4275	86.675	79.125	77.1	12	12	0	1.1	0.3	0	0	39	6
	6	12.55002	1.297052	4	0.333	2	1	-92.05667	40.488889	6	2458149.9875	2200.405	84.2	74	75.45	12	12	0	1.1	0.3	0	0	39	6
	9	8.89071	0.917163	4	0.333	2	1	-26.28111	45.716667	9	2458150.11375	2200.3825	81.725	77.875	78.8	12	12	0	1.1	0.3	0	0	39	6
	12	7.12049	0.99661	4	0.333	2	1	-26.38889	45.016667	12	2458150.44875	2200.36	79.25	76.75	72.15	12	12	0	1.1	0.3	0	0	39	6
	15	7.44646	1.124225	4	0	0	1	-21.57222	41.388889	15	2458150.86375	2200.3375	76.775	75.625	70.5	12	12	0	1.1	0.3	0	0	39	6
	18	10.1994	1.74801	4	1.333	5	1	-70.35556	44.488889	18	2458151.239	2200.205	69.3	67.3	60.5	12	12	0	1.1	0.3	0	0	39	6
	21	12.48307	1.946076	4	1.333	5	1	-98.43889	52.066667	21	2458151.364	2200.2095	69.15	67.15	60.6	12	12	0	1.1	0.3	0	0	39	6
	0	10.05451	1.127965	4	2	7	1	-114.7	56.794444	0	2457985.548	2194.12445	84.15	79.95	72.6	15	15	0	1.3	0.6	0	0	42	5
	3	14.50009	1.71057	4	1	4	1	-47.8	64.133333	3	2458008.165	2194.947525	82.125	78.225	70.95	15	15	0	1.3	0.6	0	0	42	5
	6	13.3739	1.395511	4	0.667	3	1	-45.22222	70.833333	6	2458009.782	2195.7986	80.1	76.5	69.3	15	15	0	1.3	0.6	0	0	42	5
	9	10.28784	1.046613	4	0.667	3	1	-60.60556	47.805556	9	2458033.399	2196.609675	78.075	74.775	67.65	15	15	0	1.3	0.6	0	0	42	5
	12	7.444071	1.445722	4	0.667	3	1	-98.83333	32.05	12	2458076.056	2197.44075	76.05	73.05	66	15	15	0	1.3	0.6	0	0	42	5
	15	7.84778	1.405564	4	0.333	2	1	-35.77778	29.83333	15	2458098.633	2198.271825	74.025	71.325	64.35	15	15	0	1.3	0.6	0	0	42	5
	18	10.48158	1.009056	4	0.333	2	1	-48.37222	39.488889	18	2458121.25	2199.1029	72	69.6	62.7	15	15	0	1.3	0.6	0	0	42	5
	21	12.7279	1.57182	4	0	0	1	-17.06667	27.016667	21	2458125.364	2200.2095	69.15	67.15	60.6	15	15	0	1.3	0.6	0	0	42	5
	0	14.90046	1.899349	3	0.333	2	1	-20.86667	28.45	0	2458156.988	2200.413	75.75	74.3	66.6	16	16	0	2.1	0	0	0	39	9
	3	16.25384	1.33952	3	0.333	2	1	-23.86667	27.311111	3	2458156.363	2200.3905	74.775	73.25	65.7	16	16	0	2.1	0	0	0	39	9
	6	16.26789	1.417123	3	1	4	1	-51.66667	27.4	6	2458155.788	2200.388	73.8	72.2	64.8	16	16	0	2.1	0	0	0	39	9
	9	12.49902	1.861206	3	1	4	1	-93.86667	30.4	9	2458155.113	2200.3455	72.825	71.15	63.9	16	16	0	2.1	0	0	0	39	9
	12	9.00854	1.98727	3	0.333	2	1	-28.51667	28.327778	12	2458154.489	2200.323	71.85	70.1	63	16	16	0	2.1	0	0	0	39	9
	15	8.07335	1.320619	3	0.333	2	1	-49.22778	20.411111	15	2458159.864	2200.2005	70.875	69.05	62.1	16	16	0	2.1	0	0	0	39	9
	18	11.09977	1.05291	3	1.667	6	1	-92.10556	35.522222	18	2458153.239	2200.278	69.9	68	61.2	16	16	0	2.1	0	0	0	39	9
	21	14.01269	1.02707	3	1.333	5	1	-54.03333	31.408889	21	2458152.614	2200.2555	68.925	66.95	60.3	16	16	0	2.1	0	0	0	39	9
	0	15.02041	1.494246	3	0.667	3	1	-63.10889	25.911111	0	2458157.988	2200.45	71.1	69.4	62.6	0	0	0	0	0	0	0	0	33
	3	16.34064	1.312741	3	0	0	1	-23.27222	27.166667	3	2458157.363	2200.4275	71.25	69.25	62.45	0	0	0	0	0	0	0	0	33
	6	15.68616	1.21861	3	0	0	1	-22.72222	28.388889	6	2458156.788	2200.405	71.1	69.1	62.3	0	0	0	0	0	0	0	0	33
	9	11.46995	1.051058	3	0.333	2	1	-25.20556	29.488889	9	2458156.113	2200.3825	70.95	68.95	62.15	0	0	0	0	0	0	0	0	33
	12	7.88413	1.244263	3	0.333	2	1	-16.47778	26.272222	12	2458155.489	2200.36	70.8	68.8	62	0	0	0	0	0	0	0	0	33
	15	8.82079	1.718611	3	1	4	1	-33.10889	26.311111	15	2458154.864	2200.3175	70.65	68.65	61.85	0	0	0	0	0	0	0	0	33
	18	9.86478	1.451939	3	2.333	9	1	-128.5611	48.594444	18	2458154.239	2200.315	70.5	68.5	61.7	0	0	0	0	0	0	0	0	33
	21	13.93466	1.070819	3	1	4	1	-16.06667	26.294444	21	2458153.614	2200.2925	70.35	68.35	61.55	0	0	0	0	0	0	0	0	33
	0	18.50059	1.022066	8	2.667	12	1	-138.07778	46.494444	0	2458159.988	2200.4915	89.25	85.8	78.05	0	0	0	0	0	0	0	0	41
	3	18.83093	1.931878	8	2	7	1	-57.3	42.216667	3	2458158.363	2200.4625	86.675	84.2	75.975	0	0	0	0	0	0	0	0	41
	6	17.3898	1.877552	8	2	7	1	-136.3989	53.166667	6	2458157.788	2200.445	84.2	81.8	73.7	0	0	0	0	0	0	0	0	41
	9	19.80384	1.100525	8	1.667	6	1	-143.77778	51.066667	9	2458153.113	2200.4125	81.725	79.4	71.625	0	0	0	0	0	0	0	0	41
	12	7.43551	1.275282	8	3	15	1	-35.45	77.827778	12	2458156.489	2200.3985	79.25	77	69.35	0	0	0	0	0	0	0	0	41
	15	6.83048	1.891059	8	2.333	9	1	-121.7944	31.361111	15	2458155.864	2200.3725	76.775	74.6	67.175	0	0	0	0	0	0	0	0	41
	18	9.19237	1.176892	8	1	4	1	-38.27778	34.655556	18	2458155.239	2200.352	74.3	72.2	65	0	0	0	0	0	0	0	0	41
	21	12.25933	1.084631	8	0.333	2	1	-14.33333	23.4	21	2458154.614	2200.32875	71.825	69.8	64.8	0	0	0	0	0	0	0	0	41

Για το σωστό έλεγχο και την αξιοπιστία του προς εκπαίδευση νευρωνικού δικτύου αποφασίστηκε η πραγματοποίηση παραδοχικών σεναρίων, κατά τα οποία θα προστίθενται κάθε φορά ή θα αφαιρούνταν κάποιες από τις παραμέτρους που

προαναφέρθηκαν, προκειμένου να προσδιοριστεί ποιες από αυτές έχουν το μεγαλύτερο βάρος ή αλλιώς διαδραματίζουν τον πιο καθοριστικό ρόλο για την καλύτερη πρόβλεψη της ιονόσφαιρας (τιμές STEC, VTEC).

6.2.2.1 Geomagnetic activity (K)

Τα δεδομένα γεωμαγνητικής δραστηριότητας, παράμετρος K (δείκτες Kp, Ap, ap και D), ελήφθησαν από το Γεωμαγνητικό Παρατηρητήριο Niemegk, GFZ Γερμανικό Ερευνητικό Κέντρο Γεωεπιστημών (Geomagnetic Observatory Niemegk, GFZ German Research Centre for Geosciences). Τα δεδομένα είναι μία δημοσίευση των Matzka J., Stolle C., Yamazaki Y., Bronkalla O. και Morschhauser A..


```
# The format for each line is (i stands for integer, f for float):
#iiii ii ii ff,f ff,ff fffff,fffff fffff,fffff ff,fff iiii i
# The parameters in each line are:
#YYY MM DD hh,h hh,m days days_m Kp ap D
2018 01 01 00,0 01,50 31412,00000 31412,06250 3,333 18 1
2018 01 01 03,0 04,50 31412,12500 31412,18750 3,667 22 1
2018 01 01 06,0 07,50 31412,25000 31412,31250 2,333 9 1
2018 01 01 09,0 10,50 31412,37500 31412,43750 2,333 9 1
2018 01 01 12,0 13,50 31412,50000 31412,56250 2,667 12 1
2018 01 01 15,0 16,50 31412,62500 31412,68750 1,000 4 1
2018 01 01 18,0 19,50 31412,75000 31412,81250 1,000 4 1
2018 01 01 21,0 22,50 31412,87500 31412,93750 1,333 5 1
2018 01 02 00,0 01,50 31413,00000 31413,06250 1,667 6 1
2018 01 02 03,0 04,50 31413,12500 31413,18750 0,667 3 1
2018 01 02 06,0 07,50 31413,25000 31413,31250 0,333 2 1
2018 01 02 09,0 10,50 31413,37500 31413,43750 0,667 3 1
2018 01 02 12,0 13,50 31413,50000 31413,56250 1,667 6 1
2018 01 02 15,0 16,50 31413,62500 31413,68750 1,000 4 1
2018 01 02 18,0 19,50 31413,75000 31413,81250 2,000 7 1
2018 01 02 21,0 22,50 31413,87500 31413,93750 1,000 4 1
2018 01 03 00,0 01,50 31414,00000 31414,06250 0,000 0 1
2018 01 03 03,0 04,50 31414,12500 31414,18750 0,667 3 1
2018 01 03 06,0 07,50 31414,25000 31414,31250 1,000 4 1
2018 01 03 09,0 10,50 31414,37500 31414,43750 0,667 3 1
2018 01 03 12,0 13,50 31414,50000 31414,56250 0,333 2 1
2018 01 03 15,0 16,50 31414,62500 31414,68750 1,000 4 1
2018 01 03 18,0 19,50 31414,75000 31414,81250 0,333 2 1
2018 01 03 21,0 22,50 31414,87500 31414,93750 0,000 0 1
2018 01 04 00,0 01,50 31415,00000 31415,06250 0,667 3 1
2018 01 04 03,0 04,50 31415,12500 31415,18750 0,000 0 1
```

Εικόνα 28. Υπόδειγμα δεδομένων γεωμαγνητικής δραστηριότητας (K)

Το τρίωρο ισοδύναμο πλανητικό πλάτος ap προέρχεται από το Kp και το ημερήσιο ισοδύναμο πλανητικό πλάτος Ap είναι ο ημερήσιος μέσος όρος του ap. Το Kp είναι χωρίς μονάδες, το Ap και το ap είναι χωρίς μονάδες και μπορούν να πολλαπλασιαστούν με 2 nT για να προκύψει η μέση γεωμαγνητική διαταραχή σε γεωμαγνητικό γεωγραφικό πλάτος 50 μοιρών. Τα Kp, ap και Ap εισήχθησαν από τον Bartels (1949, 1957). Το D υποδεικνύει εάν οι τιμές Kp και ap είναι οριστικές (D = 1) ή προκαταρκτικές (D=0) (Matzka et al, (2021)).

6.2.2.2 Auroral Electrojet (AE)

Για τα δεδομένα που αφορούσαν την παράμετρο AE, αποφασίστηκε η λήψη δεδομένων SME ως ποιο ακριβή λόγω του πλήθους των σταθμών από τους οποίους προέρχονται και τις καλύτερης ανταπόκρισης που έχουν στις γεωμαγνητικές καταιγίδες.



Εικόνα 29. Ανταπόκριση παραμέτρων AE και SME σε γεγονός την 30 Ιανουαρίου 1997 (Πηγή: Newell and Gjerloev, Evaluation of SuperMAG auroral electrojet indices as indicators of substorms and auroral power, 2011)

Τα δεδομένα SME χορηγήθηκαν από τον οργανισμό SuperMAG για τους μήνες Ιανουάριο – Απρίλιο του έτους 2018. Η επιλογή των συγκεκριμένων μηνών έγινε εξαιτίας της ύπαρξης ημερών με έντονη ηλιακή δραστηριότητα. Τα αρχεία ήταν τύπου txt με μορφή όπως φαίνεται στην εικόνα.

<year>	<month>	<day>	<hour>	<min>	<sec>	<SML (nT)>	<SMU (nT)>
2018	01	01	00	00	00	-187	81
2018	01	01	00	01	00	-188	84
2018	01	01	00	02	00	-185	83
2018	01	01	00	03	00	-187	85
2018	01	01	00	04	00	-187	83
2018	01	01	00	05	00	-181	82
2018	01	01	00	06	00	-181	82
2018	01	01	00	07	00	-180	85
2018	01	01	00	08	00	-174	91
2018	01	01	00	09	00	-178	96
2018	01	01	00	10	00	-183	99
2018	01	01	00	11	00	-189	99
2018	01	01	00	12	00	-198	96
2018	01	01	00	13	00	-207	94
2018	01	01	00	14	00	-210	93
2018	01	01	00	15	00	-210	95
2018	01	01	00	16	00	-197	103
2018	01	01	00	17	00	-191	102
2018	01	01	00	18	00	-194	98
2018	01	01	00	19	00	-198	95

Εικόνα 30. Υπόδειγμα δεδομένων SME

Το SuperMAG είναι μια παγκόσμια συνεργασία οργανισμών και εθνικών φορέων που σήμερα λειτουργούν πάνω από 300 επίγεια μαγνητόμετρα. Παρέχει εύκολη πρόσβαση σε επικυρωμένες διαταραχές μαγνητικού πεδίου στο ίδιο σύστημα συντεταγμένων, ταυτόσημη χρονική ανάλυση και με μια κοινή προσέγγιση αφαίρεσης γραμμής βάσης. Χρησιμοποιεί τρισδιάστατες διανυσματικές μετρήσεις του μαγνητικού πεδίου που λαμβάνονται από μαγνητόμετρα βάσεων εδάφους. Συμπεριλαμβάνονται σταθμοί που παρέχουν απόλυτες μετρήσεις (π.χ. Διαμαγνητικά Παρατηρητήρια) καθώς και σταθμοί που παρέχουν σχετικές μετρήσεις. Το SuperMAG εστιάζει στις διακυμάνσεις που προκαλούνται από τα ηλεκτρικά ρεύματα που ρέουν

στην ιονόσφαιρα και τη μαγνητόσφαιρα και ως εκ τούτου αφαιρεί το κυρίαρχο και αργά μεταβαλλόμενο κύριο πεδίο της Γης.

6.2.2.3 Disturbance storm time (Dst)

Για τα δεδομένα που αφορούσαν την παράμετρο Dst, έγινε λήψη τους από World Data Center for Geomagnetism του Κγιοτο. Ο δείκτης Dst υπολογίζεται από δεδομένα γεωμαγνητικού πεδίου που εξετάστηκαν οπτικά για τεχνητούς θορύβους (M. Nose, T. Iyemori, M. Sugiura, T. Kamei (2015)). Τα δεδομένα ήταν της μορφής IAGA-2002 Αυτή η μορφή προορίζεται ως μορφή ανταλλαγής δεδομένων για γεωμαγνητικά δεδομένα (δείγματα και μέσους) από παρατηρητήρια και σταθμούς σε χρονικά διαστήματα από χλιοστά του δευτερολέπτου έως και μηνιαίων μέσων. Η μορφή περιλαμβάνει:

- Δώδεκα (12) υποχρεωτικές και μία (1) προαιρετική εγγραφή κεφαλίδας αρχείου
- Απεριόριστες προαιρετικές εγγραφές σχολίων
- Μία (1) υποχρεωτική εγγραφή κεφαλίδας δεδομένων
- Μια σειρά από αρχεία δεδομένων.
- Κάθε εγγραφή έχει μήκος 70 χαρακτήρες συν την επιστροφή / τροφοδοσία γραμμής που εξαρτάται από το μηχάνημα.

DATE	TIME	DOY	DST
1/1/2018	12:00:00 πμ	1	-5
1/1/2018	1:00:00 πμ	1	-7
1/1/2018	2:00:00 πμ	1	-13
1/1/2018	3:00:00 πμ	1	-9
1/1/2018	4:00:00 πμ	1	-12
1/1/2018	5:00:00 πμ	1	-18
1/1/2018	6:00:00 πμ	1	-20
1/1/2018	7:00:00 πμ	1	-20
1/1/2018	8:00:00 πμ	1	-17
1/1/2018	9:00:00 πμ	1	-18
1/1/2018	10:00:00 πμ	1	-16
1/1/2018	11:00:00 πμ	1	-12
1/1/2018	12:00:00 μμ	1	-9
1/1/2018	1:00:00 μμ	1	-9
1/1/2018	2:00:00 μμ	1	-15
1/1/2018	3:00:00 μμ	1	-17
1/1/2018	4:00:00 μμ	1	-15
1/1/2018	5:00:00 μμ	1	-13
1/1/2018	6:00:00 μμ	1	-12
1/1/2018	7:00:00 μμ	1	-10
1/1/2018	8:00:00 μμ	1	-9
1/1/2018	9:00:00 μμ	1	-9
1/1/2018	10:00:00 μμ	1	-8
1/1/2018	11:00:00 μμ	1	-7

Εικόνα 31. Υπόδειγμα δεδομένων Dst

6.2.2.4 Solar Radio Flux

Τα δεδομένα που αφορούν το Solar Radio Flux (ηλιακή ροή), ήταν διαθέσιμα από την κυβέρνηση του Καναδά, στο site www.spaceweather.gc.ca.

Η βάση δεδομένων που είναι διαθέσιμη εδώ περιλαμβάνει δύο στοιχεία: μετρήσεις του Solar Radio Flux των 10,7 cm και ημερήσιες καταγραφές του Solar Radio Flux. Κάθε μέτρηση της ηλιακής ροής 10,7 cm εκφράζεται σε τρεις τιμές: τις τιμές που παρατηρήθηκαν, τις προσαρμοσμένες και τιμές URSI σειράς D.

Η παρατηρούμενη τιμή είναι ο αριθμός που μετράται από το ηλιακό ραδιοτηλεσκόπιο. Αυτό διαμορφώνεται από δύο μεγέθη: το επίπεδο της ηλιακής δραστηριότητας και τη μεταβαλλόμενη απόσταση μεταξύ της Γης και του Ήλιου. Δεδομένου ότι είναι ένα μέτρο των εκπομπών που οφείλονται στην ηλιακή δραστηριότητα που χτυπά τη Γη, αυτή είναι η ποσότητα που πρέπει να χρησιμοποιείται όταν μελετώνται επίγεια φαινόμενα.

Όταν μελετάται ο Ήλιος, η ετήσια διαμόρφωση της ηλιακής ροής των 10,7 cm από τη μεταβαλλόμενη απόσταση μεταξύ της Γης και του Ήλιου είναι ανεπιθύμητη. Ωστόσο, ένα υποπροϊόν των υπολογισμών που απαιτούνται από τους δέκτες ώστε να αποκτήσουν και να παρακολουθήσουν σωστά τον Ήλιο είναι η απόσταση μεταξύ του Ήλιου και της Γης. Επομένως, παράγεται μια πρόσθετη ποσότητα, διορθωμένη από διακυμάνσεις στην απόσταση Γης-Ήλιου και δίνεται για τη μέση απόσταση. Αυτό ονομάζεται προσαρμοσμένη τιμή. Οι απόλυτες μετρήσεις της πυκνότητας της ροής είναι αρκετά δύσκολες, και στα πρώτα χρόνια της ηλιακής ραδιοαστρονομίας, καταβλήθηκε σημαντική προσπάθεια σε όλο τον κόσμο για να γίνουν απόλυτες μετρήσεις της πυκνότητας της ηλιακής ροής σε πολλές διαφορετικές συχνότητες. Έγινε τότε μια προσπάθεια να χωρέσουν όλα αυτά τα διάφορα δεδομένα σε ένα φάσμα. Σε κάθε σύνολο μετρήσεων δόθηκε στη συνέχεια ένας παράγοντας κλιμάκωσης που θα τις μετακινούσε απευθείας στο προσαρμοσμένο φάσμα. Για την ηλιακή ροή 10,7 cm υπολογίστηκε ένας συντελεστής κλιμάκωσης 0,9. Έτσι, δίνεται επίσης στη βάση δεδομένων το Series D Flux, που είναι η προσαρμοσμένη τιμή πολλαπλασιαζόμενη επί 0,9.

Τρεις προσδιορισμοί ροής γίνονται κάθε μέρα. Μεταξύ Μαρτίου και Οκτωβρίου οι μετρήσεις γίνονται στις 17.00, 20.00 και 23.00 UT. Από τον Νοέμβριο έως τον Φεβρουάριο, οι χρόνοι προσδιορισμού της ροής αλλάζουν σε 1800, 2000 και 2200, έτσι ώστε ο Ήλιος να βρίσκεται αρκετά ψηλά πάνω από τον ορίζοντα για να γίνει μια καλή μέτρηση.

Η ηλιακή ροή 10,7 cm δίνεται σε μονάδες ηλιακής ροής (ένα sfu = $10^{-22} \text{ W m}^{-2} \text{ Hz}^{-1}$). Τα αρχεία είναι txt της μορφής:

- Ημερομηνία καταγραφής
- Ώρα
- Ιουλιανή ημερομηνία
- Αριθμός περιστροφής Carrington
- παρατηρούμενη ροή
- προσαρμοσμένη ροή
- ροή της σειράς D.

Solar Radio Flux					
fluxtime	fluxjulian	fluxcarrington	fluxobsflux	fluxadjflux	fluxursi
0	2458149.9875	2200.45	89.15	73.25	62.825
3	2458149.96275	2200.4275	86.675	73.125	77.1
6	2458149.738	2200.405	84.2	74	75.45
9	2458150.11325	2200.3825	81.725	77.875	73.8
12	2458150.4885	2200.36	79.25	76.75	72.15
15	2458150.86375	2200.3375	76.775	75.625	70.5
18	2458151.239	2200.205	69.3	67.3	60.5
21	2458151.364	2200.2095	69.15	67.15	60.4
0	2457985.548	2194.11645	84.15	79.95	72.6
3	2458008.165	2194.947525	82.125	78.225	70.95
6	2458030.782	2195.7786	80.1	76.5	69.3
9	2458053.399	2196.609675	78.075	74.775	67.65
12	2458076.016	2197.44075	76.05	73.05	66
15	2458098.633	2198.271825	74.025	71.325	64.35
18	2458121.25	2199.1029	72	69.6	62.7
21	2458151.364	2200.2095	69.15	67.15	60.4
0	2458156.988	2200.413	75.75	74.3	66.6
3	2458156.363	2200.3905	74.775	73.25	65.7
6	2458155.738	2200.368	73.8	72.2	64.8
9	2458155.113	2200.3455	72.825	71.15	63.9
12	2458154.489	2200.323	71.85	70.1	63
15	2458153.864	2200.3005	70.875	69.05	62.1
18	2458153.239	2200.278	69.9	68	61.2
21	2458152.614	2200.2555	68.925	66.95	60.3
0	2458157.988	2200.45	71.4	69.4	62.6
3	2458157.363	2200.4275	71.25	69.25	62.45
6	2458156.738	2200.405	71.1	69.1	62.3
9	2458156.113	2200.3825	70.95	68.95	62.15
12	2458155.489	2200.36	70.8	68.8	62
15	2458154.864	2200.3375	70.65	68.65	61.85
18	2458154.239	2200.315	70.5	68.5	61.7
21	2458153.614	2200.2925	70.35	68.35	61.55
0	2458158.988	2200.4915	89.15	86.6	78.05
3	2458158.363	2200.46825	86.675	84.2	75.875
6	2458157.738	2200.445	84.2	81.8	73.7
9	2458157.113	2200.42175	81.725	79.4	71.525
12	2458156.489	2200.3985	79.25	77	69.35
15	2458155.864	2200.37525	76.775	74.6	67.175

Εικόνα 32. Υπόδειγμα δεδομένων Solar Radio Flux

6.2.2.5 Sunspot Number

Τα δεδομένα που αφορούσαν το Sunspot Number (ηλιακή κηλίδα), ελήφθησαν από WDC-SILSO, Βασιλικό Αστεροσκοπείο του Βελγίου στις Βρυξέλλες. Ο ημερήσιος συνολικός αριθμός ηλιακών κηλίδων προκύπτει από τον τύπο: $R = N_s + 10 * N_g$, με N_s τον αριθμό των κηλίδων και N_g τον αριθμό των ομάδων που υπολογίζονται σε ολόκληρο τον ηλιακό δίσκο. Το αρχείο είναι μορφής txt και περιλάμβανε όλα τα δεδομένα από το 1992 έως το 2020 ως ακολούθως:

- Ημερομηνία
- Ημερήσιος συνολικός αριθμός ηλιακών κηλίδων
- Ημερήσιος αριθμός βόρειων ηλιακών κηλίδων
- Ημερήσιος αριθμός νότιων ηλιακών κηλίδων
- Τυπική απόκλιση των ακατέργαστων ημερήσιων συνολικών δεδομένων ηλιακών κηλίδων
- Τυπική απόκλιση ακατέργαστων ημερήσιων δεδομένων βόρειων ηλιακών κηλίδων
- Τυπική απόκλιση ακατέργαστων ημερήσιων δεδομένων νότιων ηλιακών κηλίδων
- Αριθμός παρατηρήσεων για ημερήσιο συνολικό αριθμό ηλιακών κηλίδων
- Αριθμός παρατηρήσεων για ημερήσιο αριθμό βόρειων ηλιακών κηλίδων
- Αριθμός παρατηρήσεων για τον ημερήσιο αριθμό νότιων ηλιακών κηλίδων
- Οριστικός / Προσωρινός Δείκτης


```

Date,Daily Total Sunspot Number,Daily North Sunspot Number,
2020-04-30,20.0,8.0,12.0,1.2,0.6,1.0,20.0,19.0,31.0,0.0
2020-04-29,24.0,12.0,12.0,1.6,0.0,0.5,22.0,5.0,2.0,0.0
2020-04-28,15.0,0.0,15.0,2.6,0.0,0.8,18.0,24.0,13.0,0.0
2020-04-27,29.0,0.0,29.0,2.0,0.0,1.1,20.0,35.0,2.0,0.0
2020-04-26,14.0,0.0,14.0,1.0,0.0,0.0,23.0,33.0,3.0,0.0
2020-04-25,6.0,0.0,6.0,0.4,0.0,0.5,22.0,32.0,19.0,0.0
2020-04-24,0.0,0.0,0.0,0.0,0.0,0.0,42.0,33.0,33.0,0.0
2020-04-23,0.0,0.0,0.0,0.0,0.0,0.0,43.0,35.0,35.0,0.0
2020-04-22,0.0,0.0,0.0,0.0,0.0,0.0,43.0,34.0,34.0,0.0
2020-04-21,0.0,0.0,0.0,0.0,0.0,0.0,37.0,29.0,29.0,0.0
2020-04-20,0.0,0.0,0.0,0.0,0.0,0.0,38.0,28.0,28.0,0.0
2020-04-19,0.0,0.0,0.0,0.0,0.0,0.0,37.0,28.0,28.0,0.0
2020-04-18,0.0,0.0,0.0,0.0,0.0,0.0,37.0,28.0,28.0,0.0
2020-04-17,0.0,0.0,0.0,0.0,0.0,0.0,38.0,29.0,29.0,0.0
2020-04-16,0.0,0.0,0.0,0.0,0.0,0.0,42.0,33.0,33.0,0.0
2020-04-15,0.0,0.0,0.0,0.0,0.0,0.0,44.0,35.0,35.0,0.0
2020-04-14,0.0,0.0,0.0,0.0,0.0,0.0,41.0,35.0,35.0,0.0
2020-04-13,0.0,0.0,0.0,0.0,0.0,0.0,38.0,30.0,30.0,0.0
2020-04-12,0.0,0.0,0.0,0.0,0.0,0.0,38.0,29.0,29.0,0.0
2020-04-11,0.0,0.0,0.0,0.0,0.0,0.0,46.0,36.0,36.0,0.0
2020-04-10,0.0,0.0,0.0,0.0,0.0,0.0,45.0,35.0,35.0,0.0
2020-04-09,0.0,0.0,0.0,0.0,0.0,0.0,47.0,36.0,36.0,0.0
2020-04-08,0.0,0.0,0.0,0.0,0.0,0.0,46.0,35.0,36.0,0.0
2020-04-07,0.0,0.0,0.0,0.0,0.0,0.0,43.0,34.0,34.0,0.0
    
```

Εικόνα 33. Υπόδειγμα δεδομένων Sunspot Number



Εικόνα 34. Βασιλικό Αστεροσκοπείο Βελγίου (Πηγή: www.bis.sidc.be)

6.2.2.6 Energetic Particle Flux

Τα δεδομένα που αφορούσαν το Energetic Particle Flux (Ροή ενεργών σωματιδίων), ελήφθησαν από το SWPC-NOAA. Το αρχείο είναι σε μορφή txt και περιλαμβάνει δεδομένα Πρωτονίων, ηλεκτρονίων και νετρονίων σε διάφορες τιμές ενέργειες όπως παρατηρούνται από τον κύριο δορυφόρο GOES.

GOES-15 Proton FluEncE			GOES-15 ElElectron FluEncE		NEutron
Protons/cm2-day-sr			ElElectrons/cm2-day-sr		Monitor
>1 MEV	>10 MEV	>100 MEV	>0.8 MEV	>2 MEV	% of bkgd
560000	16000	3400	500000000	1600000	-999.99
560000	16000	3400	500000000	1600000	-999.99
560000	16000	3400	500000000	1600000	-999.99
560000	16000	3400	500000000	1600000	-999.99
560000	16000	3400	500000000	1600000	-999.99
560000	16000	3400	500000000	1600000	-999.99
560000	16000	3400	500000000	1600000	-999.99
560000	16000	3400	500000000	1600000	-999.99
470000	15000	3600	1100000000	2300000	-999.99
470000	15000	3600	1100000000	2300000	-999.99
470000	15000	3600	1100000000	2300000	-999.99
470000	15000	3600	1100000000	2300000	-999.99
470000	15000	3600	1100000000	2300000	-999.99
470000	15000	3600	1100000000	2300000	-999.99
470000	15000	3600	1100000000	2300000	-999.99
470000	15000	3600	1100000000	2300000	-999.99
470000	15000	3600	1100000000	2300000	-999.99
470000	15000	3600	1100000000	2300000	-999.99
400000	16000	3500	970000000	2000000	-999.99
400000	16000	3500	970000000	2000000	-999.99
400000	16000	3500	970000000	2000000	-999.99
400000	16000	3500	970000000	2000000	-999.99
400000	16000	3500	970000000	2000000	-999.99
400000	16000	3500	970000000	2000000	-999.99
400000	16000	3500	970000000	2000000	-999.99
400000	16000	3500	970000000	2000000	-999.99

Εικόνα 35. Υπόδειγμα δεδομένων Energetic Particle Flux.

Η National Oceanic and Atmospheric Administration είναι μια αμερικανική επιστημονική και ρυθμιστική υπηρεσία στο Υπουργείο Εμπορίου των Ηνωμένων Πολιτειών που προβλέπει καιρικές συνθήκες, παρακολουθεί τις ωκεάνιες και ατμοσφαιρικές συνθήκες, χαρτογραφεί τις θάλασσες, διεξάγει εξερεύνηση βαθέων υδάτων και διαχειρίζεται την αλιεία και την προστασία θαλάσσιων θηλαστικών και απειλούμενων ειδών στην αποκλειστική οικονομική ζώνη των ΗΠΑ.

Το Space Weather Prediction Center (SWPC) είναι ένα εργαστήριο και κέντρο υπηρεσιών της Εθνικής Μετεωρολογικής Υπηρεσίας των ΗΠΑ (NWS), μέρος της Εθνικής Υπηρεσίας Ωκεανών και Ατμόσφαιρας (NOAA), που βρίσκεται στο Boulder του Κολοράντο. Το SWPC παρακολουθεί και προβλέπει συνεχώς το διαστημικό περιβάλλον της Γης, παρέχοντας ηλιακές-γήινες πληροφορίες. Το SWPC είναι η επίσημη πηγή ειδοποιήσεων και προειδοποιήσεων διαστημικού καιρού για τις Ηνωμένες Πολιτείες.

6.2.2.7 Solar Flares

Τα δεδομένα που αφορούσαν τα Solar Flares (Ηλιακές εκλάμψεις), ελήφθησαν από τη NASA μέσω του προγράμματος RHESSI. Το αρχείο είναι σε μορφή txt και περιλαμβάνει τις καταγραφές των εκλάμψεων για την περίοδο μελέτης όπως φαίνεται στην εικόνα.

HESSI Flare List (generated 7-Oct-2020 13:36)

Total # flares: 121206 Time range: 12-Feb-2002 21:29:56.000 - 3-Mar-2018 04:12:20.000

Flare	Start time	Peak	End	Dur s	Peak c/s	Total Counts	Energy keV	X Pos asec	Y Pos asec	Radial asec	AR
18010601	6-Jan-2018 16:31:44	16:32:26	16:32:56	72	128	4152	3-6	0	0	0	A0 D
18011801	18-Jan-2018 07:29:24	07:34:58	07:42:56	812	256	86808	25-50	88	-121	150	2696 A0 P
18011802	18-Jan-2018 08:11:08	08:12:54	08:16:16	308	40	13446	6-12	110	-129	169	2696 A0 D
18012001	20-Jan-2018 04:50:48	04:51:58	04:53:28	160	20	4200	6-12	501	-130	517	2696 A0 P
18012002	20-Jan-2018 04:53:28	04:54:30	04:57:28	240	16	5608	6-12	499	-115	512	2696 A0 P
18012202	22-Jan-2018 02:43:28	02:53:22	03:15:04	1896	40	82840	6-12	817	-157	832	2696 A0 D
18020401	4-Feb-2018 21:14:28	21:15:06	21:19:12	284	22	4696	6-12	-960	-115	966	2699 A0 D
18020402	4-Feb-2018 21:19:12	21:22:18	21:28:12	540	14	6264	6-12	-960	-115	966	2699 A0 D
18020601	6-Feb-2018 18:40:04	18:55:38	19:04:20	976	36	39272	6-12	-821	113	828	2699 A0 D
18020602	6-Feb-2018 19:04:20	19:05:30	19:09:08	388	13	5544	6-12	-845	-35	845	2699 A0 D
18020603	6-Feb-2018 19:09:08	19:12:30	19:17:24	496	13	9024	6-12	-829	-58	831	2699 A0 D
18020701	7-Feb-2018 13:34:44	13:44:46	13:45:00	616	288	87832	25-50	-689	-45	690	2699 A0 D
18020702	7-Feb-2018 14:16:52	14:17:02	14:19:04	132	6	1160	6-12	-729	-38	730	2699 A0 D
18020703	7-Feb-2018 14:19:04	14:20:22	14:24:40	336	6	2328	6-12	-729	-38	730	2699 A0 D
18020801	8-Feb-2018 17:00:04	17:00:14	17:11:24	680	15	9808	6-12	-508	-49	510	2699 A0 D
18020802	8-Feb-2018 18:42:44	18:44:38	18:46:12	208	24	4648	6-12	-499	-38	500	2699 A0 D
18020803	8-Feb-2018 19:52:56	19:53:54	19:56:56	240	25	7646	6-12	-515	-16	515	2699 A0 D
18020901	9-Feb-2018 14:53:32	14:55:22	14:58:32	300	13	3008	6-12	-345	-38	347	2699 A0 D
18020902	9-Feb-2018 15:45:28	15:46:54	15:52:36	428	28	9088	6-12	0	0	0	2699 A0 D
18020903	9-Feb-2018 16:41:28	16:42:54	16:43:32	124	18	2888	6-12	-345	-38	347	2699 A0 D
18020904	9-Feb-2018 18:15:56	18:17:26	18:17:40	104	16	1656	6-12	-268	-38	271	2699 A0 D
18021001	10-Feb-2018 13:04:36	13:06:46	13:07:04	148	15	2224	6-12	-115	-38	121	2699 A0 D
18022601	26-Feb-2018 15:49:56	15:51:18	15:53:52	236	16	3312	6-12	115	192	223	2700 A0 D
18030301	3-Mar-2018 04:04:08	04:06:22	04:12:20	492	42	15816	6-12	926	128	935	2700 A0 P

Εικόνα 36. Υπόδειγμα δεδομένων Solar Flares.

6.2.2.8 Coronal Mass Ejections

Οι Coronal Mass Ejections (CMEs) είναι τεράστιες εκρήξεις πλάσματος από τον ήλιο. Τα δεδομένα που αφορούσαν τα CMEs, ελήφθησαν από τη NASA μέσω του προγράμματος SOHO-LASCO. Το αρχείο είναι σε μορφή txt και περιλαμβάνει τις καταγραφές των εκλάμψεων για την περίοδο μελέτης όπως φαίνεται στην εικόνα.

Ένας από τους επιστημονικούς στόχους του SOHO-LASCO (Large Angle and Spectrometric Coronagraph) είναι να κατανοήσει γιατί συμβαίνουν αυτά τα συμβάντα. Πιστεύεται ότι προκαλούνται από αστάθειες στο ηλιακό μαγνητικό πεδίο, το οποίο εξελίσσεται συνεχώς. Ένας άλλος επιστημονικός στόχος είναι να κατανοηθούν οι επιδράσεις των CME στον διαπλανητικό χώρο και πολύ σημαντικό τι επιπτώσεις έχουν οι CME όταν συναντούν το περιβάλλον της γης.

Ο διαθέσιμος κατάλογος CME δημιουργείται και διατηρείται στο CDAW Data Center από τη NASA και το Καθολικό Πανεπιστήμιο της Αμερικής σε συνεργασία με το Ναυτικό Ερευνητικό Εργαστήριο. Το SOHO (NASA Solar and Heliospheric Observatory) είναι ένα έργο διεθνούς συνεργασίας μεταξύ της ESA και της NASA.

First C2 Appearance Date Time [UT]	Central PA [deg]	Angular Width [deg]	Linear Speed [km/s]	2nd- order Speed at final height [km/	2nd- order Speed at 20 Rs [m/s ²]	Accel [m/s ²]	Mass [gram]	Kinetic Energy [erg]	MPA [deg]	s, plots, & links	Remarks
2018/01/01 05:05	315	28	100	182	369	5.8*1	2.4e+15	1.2e+29	301	C2 C3 PHTX DST Java	Very Poor Event
2018/01/02 12:05	48	12	377	307	0	-67.5*1	----	----	51	C2 C3 PHTX DST Java	Very Poor Event; Only C2
2018/01/03 12:05	104	9	244	301	355	4.0*1	----	----	111	C2 C3 PHTX DST Java	Poor Event
2018/01/04 08:05	278	26	128	175	402	6.4*1	4.6e+13	3.7e+27	276	C2 C3 PHTX DST Java	Very Poor Event; Only C2
2018/01/04 24:05	191	39	241	394	782	25.0*1	5.8e+13	1.7e+28	192	C2 C3 PHTX DST Java	Poor Event

Εικόνα 37. Υπόδειγμα δεδομένων Coronal Mass Ejections.

6.3 Επεξεργασία των δεδομένων

Τα δεδομένα όπως περιεγράφηκαν παραπάνω βρισκόντουσαν σε διάφορες μορφές αρχείων και ήταν καταγεγραμμένα σε διαφορετικά χρονικά διαστήματα όπως φαίνεται και στον πίνακα. Αφού επεξεργάστηκαν όλα τα δεδομένα και ήρθαν σε ίδια μορφή, αποφασίστηκε να ταξινομηθούν σε διαστήματα 3 ωρών (00.00-03.00-06.00-09.00-12.00-15.00-18.00-21.00) όπως φαίνεται στο Παράρτημα Α και να εισαχθούν σε ένα αρχείο xlsx ώστε να είναι πιο διαχειρίσιμα και εύληπτα για οποιονδήποτε χρήστη. Για την ταξινόμησή τους σε διαστήματα 3 ωρών έπρεπε να γίνουν κάποιες διαδικασίες. Αρχικά, όσα δεδομένα ήταν σε διαστήματα μικρότερα των 3 ωρών (πχ τα δεδομένα TEC) λαμβάνοντας τους μέσους όρους για τα διαστήματα των 3 ωρών, προέκυψε η τελική τους τιμή. Για δεδομένα με διαστήματα μεγαλύτερα των 3 ωρών όπως τα Sunspot Number (Ημερήσια), τοποθετήθηκε η καταγεγραμμένη τιμή σε όλα τα τρίωρα διαστήματα της εκάστοτε μέρας. Για τα δεδομένα που είχα καταγραφές συγκεκριμένων ωρών όπως το Solar Radio Flux, συμπληρώθηκε ο πίνακας κάθε μέρας με χρήση γραμμικής παρεμβολής. Τέλος, για τα δεδομένα τυχαίας εμφάνισης όπως τα CMEs, τοποθετήθηκαν στην αντίστοιχη μέρα και ώρα εμφάνισής τους και όλες οι υπόλοιπες ώρες συμπληρώθηκαν με 0. Ολοκληρώνοντας, αφού αντικαταστάθηκαν όσα κελιά που δεν είχαν δεδομένα λόγω κάποιου προβλήματος στο δέκτη με 0, συμπληρώθηκε ο πίνακας για κάθε μήνα σε ξεχωριστές καρτέλες (Παράρτημα Α). Τέλος, παρήχθησαν αρχεία xlsx για κάθε μήνα ώστε να μπορεί να χρησιμοποιηθεί στην εκπαίδευση των μοντέλων.

Μελέτη σεναρίων επίδρασης υπερ-παραμέτρων

7. Εισαγωγικά

7.1 Βέλτιστο σενάριο παραμέτρων

Προτού αναλύσουμε και αξιολογήσουμε τα αποτελέσματα σεναρίων με διαφοροποίηση υπερπαραμέτρων για κάθε νευρωνικό δίκτυο, θα αναφερθούμε σε μια αντίστοιχη με την παρούσα μελέτη, με σκοπό την ανάδειξη βέλτιστου συνδυασμού παραμέτρων. Στο τρίτο κεφάλαιο της παρούσας αναφερθήκαμε στις παραμέτρους που επηρεάζουν την ιονόσφαιρα ενώ κάναμε και μια σύντομη αναφορά και για το πως. Στην πρόβλεψη όμως των ποσοτήτων TEC με χρήση νευρωνικών δικτύων, μπορούν να καταρτιστούν διάφορα σενάρια συνδυασμού των παραμέτρων. Πιο συγκεκριμένα στη διπλωματική εργασία με τίτλο «Μελέτη της επίδρασης διαφόρων παραμέτρων για την πρόβλεψη της ιονοσφαιρικής δραστηριότητας κάνοντας χρήση μοντέλων μηχανικής μάθησης και μετρήσεις GNSS» του Δ. Σακελλαρίου, εκπαιδεύτηκαν δύο είδη νευρωνικών δικτύων, το Recurrent neural network (RNN) και οι νευρώνες μακράς-βραχείας διάρκειας μνήμης (Long Short-Term Memory - LSTM), σε επτά σενάρια συνδυασμού παραμέτρων.

Πίνακας 3. Σενάρια για επιλογή καταλληλότερων παραμέτρων

ΣΕΝΑΡΙΟ	ΠΑΡΑΜΕΤΡΟΙ	ΠΡΟΣ ΕΚΠΑΙΔΕΥΣΗ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ
1	ΟΛΕΣ	RNN, LSTM
2	Daily geomagnetic activity average (K)	RNN,LSTM
	Solar Radio Flux	
3	Daily geomagnetic activity average (K)	RNN, LSTM
	Solar Radio Flux	
	Sunspot Number	
4	Daily geomagnetic activity average (K)	RNN, LSTM
	Coronal Mass Ejections	
5	Daily geomagnetic activity average (K)	RNN, LSTM
	Solar Radio Flux	
	Solar Flares	

	Coronal Mass Ejections	
6	Daily geomagnetic activity average (K)	RNN, LSTM
	Solar Radio Flux	
	Coronal Mass Ejections	
7	Daily geomagnetic activity average (K)	RNN, LSTM
	Solar Radio Flux	
	Sunspot Number	
	Energetic Particle Flux	

Έπειτα από αξιολόγηση των αποτελεσμάτων συγκρίνοντας τους μετρητικούς δείκτες Mean Square error (MSE) και Mean Absolute error (MAE), εξήχθη το συμπέρασμα πως βέλτιστο σενάριο αποτελεί το δεύτερο εκ των επτά, στο οποίο συνδυάζονται Γεωμαγνητικές και τις Solar Radio Flux παράμετροι επιρροής των τιμών TEC.

7.2 Σενάρια μελέτης υπερπαραμέτρων

Κατόπιν επιλογής του δεύτερου σεναρίου συνδυασμού παραμέτρων ως βέλτιστο, πραγματοποιήθηκε εκπαίδευση τριών ειδών νευρωνικών δικτύων [Recurrent neural network (RNN), (Long Short-Term Memory - LSTM) και Gated recurrent units (GRUs)], κατά την εκπαίδευση των οποίων εισήχθησαν ως δεδομένα οι Γεωμαγνητικές και οι Solar Radio Flux παράμετροι επιρροής των τιμών TEC. Εν προκείμενο διαφοροποιήθηκαν τέσσερα σενάρια πλήθους φίλτρων (υπερπαραμέτροι). Πιο συγκεκριμένα η εκπαίδευση και των τριών νευρωνικών δικτύων πραγματοποιήθηκε αρχικά με 64 φίλτρα για τα δεδομένα εισόδου και στη συνέχεια αυξήσαμε την ποσότητα των φίλτρων και εκπαιδεύσαμε τα δίκτυα με πλήθος 128, 256 και 512 φίλτρων. Στη συνέχεια του κεφαλαίου παρουσιάζονται και αξιολογούνται τα αποτελέσματα με σκοπό την ανάδειξη τελικού βέλτιστου μοντέλου πρόβλεψης ιονοσφαιρικής δραστηριότητας. Σε αυτό το σημείο να αφαιρούμε επίσης πως πραγματοποιήθηκε δοκιμή πλήθος εποχών και επιλέχθηκε ως βέλτιστος αριθμός οι εκατό (100 εποχές).

Πίνακας 4. Διαχωρισμός σεναρίων μελέτης υπερπαραμέτρων επιρροής πρόβλεψης των τιμών TEC.

ΣΕΝΑΡΙΟ	ΠΑΡΑΜΕΤΡΟΙ	ΠΛΗΘΟΣ ΕΠΟΧΩΝ	ΠΛΗΘΟΣ ΦΙΛΤΡΩΝ	ΠΡΟΣ ΕΚΠΑΙΔΕΥΣΗ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ
1	geomagnetic activity & Solar Radio Flux	100	64	RNN, LSTM & GRU
2			128	
3			256	
4			512	

7.3 Δείκτες αξιολόγησης αποτελεσμάτων

Το βασικό βήμα σε οποιοδήποτε μοντέλο μηχανικής μάθησης είναι η αξιολόγηση της ακρίβειας του μοντέλου. Για την αξιολόγηση και τελικώς την ανάδειξη βέλτιστου μοντέλου πρόβλεψης ιονοσφαιρικής δραστηριότητας, χρησιμοποιήθηκαν οι μετρητικοί δείκτες Mean Square error (MSE) και Mean Absolute error (MAE).

Mean Square error (MSE)

Το μέσο απόλυτο σφάλμα (mae) αντιπροσωπεύει τον μέσο όρο της απόλυτης διαφοράς μεταξύ των πραγματικών και των προβλεπόμενων τιμών στο σύνολο δεδομένων. Μετρά τον μέσο όρο των υπολειμμάτων στο σύνολο δεδομένων.

Mean Absolute error (MAE)

Το μέσο τετραγωνικό σφάλμα (mse) αντιπροσωπεύει τον μέσο όρο της διαφοράς στο τετράγωνο μεταξύ των αρχικών και των προβλεπόμενων τιμών στο σύνολο δεδομένων. Μετρά τη διακύμανση των υπολειμμάτων.

Όσο οι αριθμοί MAE και MSE είναι μικροί και σχεδόν ίσοι, τόσο καλύτερα προσδιορίζεται το μοντέλο και αποφεύγονται τα χωρικά ακρότατα.

Training & Validation MAE - Loss

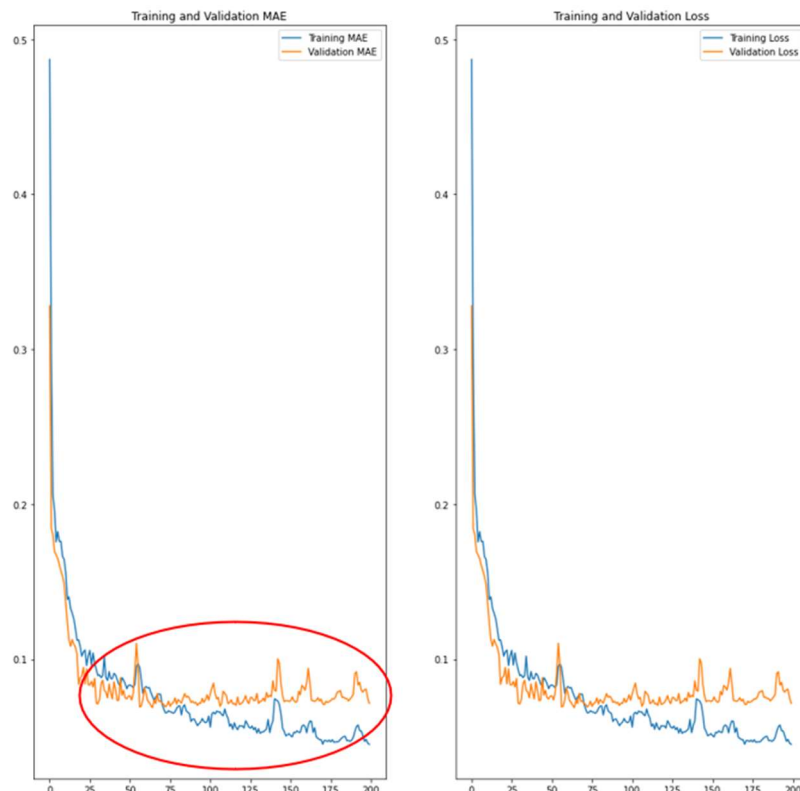
Συνδυαστικά με τους μετρητικούς δείκτες MAE και MSE, χρησιμοποιήθηκαν οι δείκτες accuracy και Loss οι οποίοι ορίζονται ως

$$\text{Accuracy} = \frac{TM}{VM} \quad \text{Loss} = \frac{TL}{VL}$$

με τις τιμές TM, VM, TL και VL να αντιστοιχούν στις έννοιες Training MAE, Validation MAE, Training Loss και Validation Loss αντίστοιχα.

Ένα σετ δεδομένων προσδιορίζεται από τις τιμές εκπαίδευσης (training) και τις τιμές αξιολόγησης (validation). Για να είναι ακριβές το μοντέλο θα πρέπει αυτά τα δύο να συνάδουν.

Πιο συγκεκριμένα η μπλε γραμμή αποτυπώνει τα δεδομένα εκπαίδευσης και η πορτοκαλί τα δεδομένα αξιολόγησης. Όταν η πορτοκαλί γραμμή ταυτίζεται με την μπλε γραμμή τότε το σφάλμα ή η ακρίβεια στο σετ δεδομένων αξιολόγησης είναι πολύ μικρή. Αντίθετα αν η πορτοκαλί γραμμή απέχει από την μπλε τότε τα αποτελέσματα της πρόβλεψης δεν είναι ικανοποιητικά αξιόπιστα. Επίσης όταν η πορτοκαλί γραμμή σταματάει να έχει καθοδική πορεία και έχει γενική τάση παράλληλη με τον οριζόντιο άξονα, όπως σημειώνεται στο ανωτέρω γράφημα, αυτό ερμηνεύεται ως υπερπροσαρμογή του νευρωνικού δικτύου στα δεδομένα.



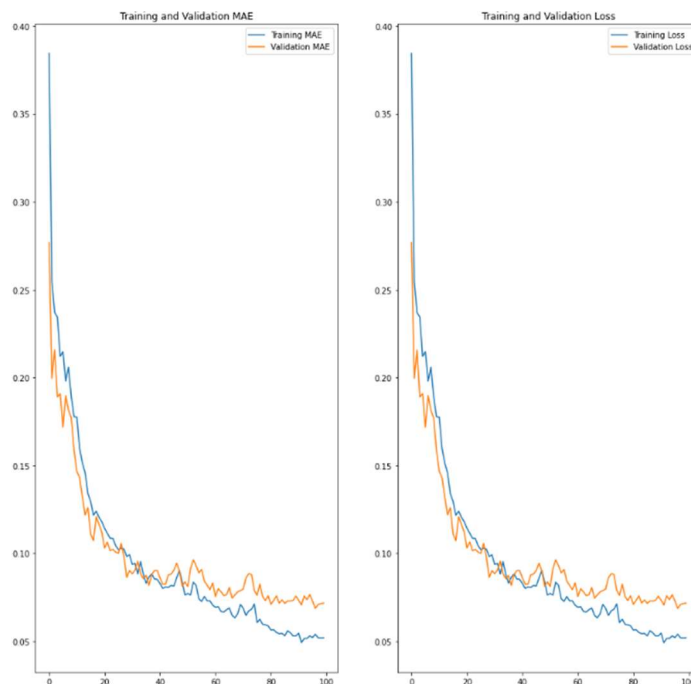
Εικόνα 38. Αποτέλεσμα εκπαίδευσης δικτύου RNN με 64 φίλτρα σε 200 εποχές.

Υπερπροσαρμογή

Η υπερπροσαρμογή είναι ένα θεμελιώδες ζήτημα στην επιβλεπόμενη μηχανική μάθηση, το οποίο μας εμποδίζει από το να γενικεύσουμε τέλεια τα μοντέλα ώστε να ταιριάζουν καλά με τα παρατηρούμενα δεδομένα στα δεδομένα εκπαίδευσης, καθώς και με τα αθέατα δεδομένα στο σύνολο δοκιμών. Λόγω της παρουσίας θορύβου, του περιορισμένου μεγέθους του συνόλου εκπαίδευσης και της πολυπλοκότητας των ταξινομητών, συμβαίνει υπερπροσαρμογή.

Με άλλα λόγια όταν το μοντέλο που έχουμε εκπαιδεύσει μπορεί και προβλέπει σε πολύ ικανοποιητικό βαθμό τα δεδομένα εκπαίδευσης, αλλά δεν είναι σε θέση να ταξινομήσει ικανοποιητικά δεδομένα τα οποία δεν περιλαμβάνονται στο σετ εκπαίδευσης τότε λέμε ότι το μοντέλο έχει υπερπροσαρμοστεί. Για να θεωρήσουμε ότι το μοντέλο μας έχει εκπαιδευτεί ικανοποιητικά, σίγουρα θέλουμε να αποφύγουμε την περίπτωση της υπερπροσαρμογής. Αυτό επιτυγχάνεται είτε με προσθήκη δεδομένων στο σετ των δεδομένων εκπαίδευσης, αύξηση των δεδομένων με τροποποίηση των ήδη διαθέσιμων ώστε το σετ δεδομένων μας να μεγαλώσει και τη μείωση της πολυπλοκότητας του μοντέλου.

Στη δική μας περίπτωση επιλέξαμε να μειώσουμε το πλήθος των εποχών. Όπως αναφέραμε παραπάνω πραγματοποιήθηκε δοκιμή πλήθους εποχών και καταλήξαμε στις εκατό εποχές, για αποφυγή υπερπροσαρμογής του μοντέλου στα δεδομένα εκπαίδευσης.



Εικόνα 39. Αποτέλεσμα εκπαίδευσης δικτύου RNN με 64 φίλτρα σε 100 εποχές.

Συγκρίνοντας το γράφημα εκπαίδευσης δικτύου RNN με 64 φίλτρα σε 200 εποχές, με το γράφημα από αντίστοιχο δίκτυο αλλά σε 100 εποχές, παρατηρούμε ότι πετύχαμε την αποφυγή της υπερπροσαρμογής.

7.4 Παράθεση και αξιολόγηση σεναρίων

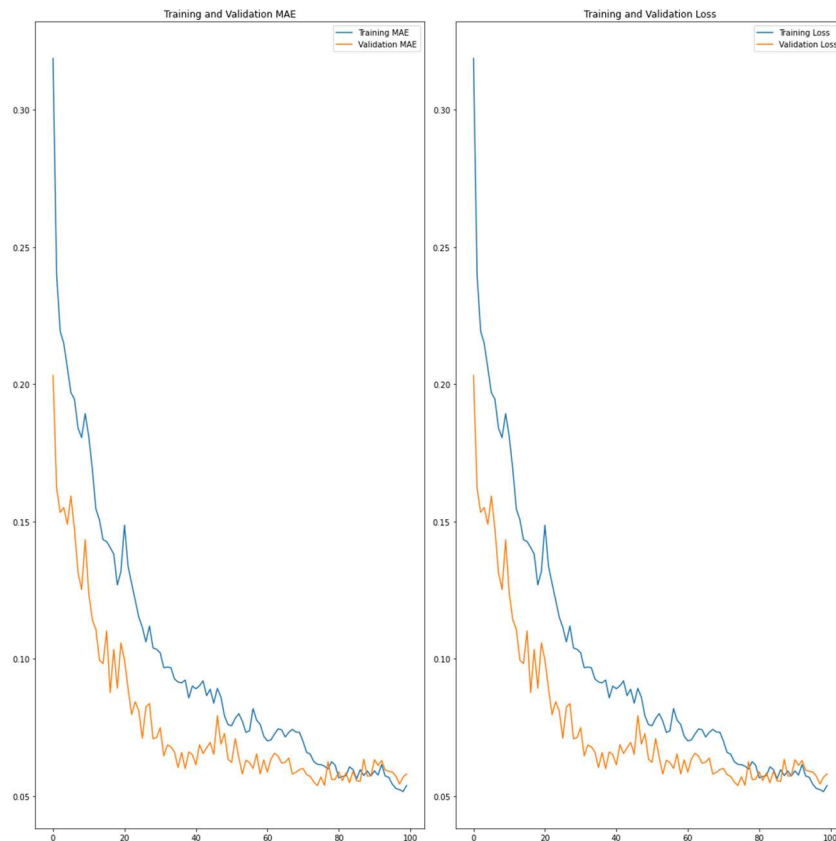
Ακολουθεί παρουσίαση και αξιολόγηση των αποτελεσμάτων εκπαίδευσης των νευρικών δικτύων [Recurrent neural network (RNN), Long Short-Term Memory (LSTM) και Gated recurrent units (GRUs)], σε εκατό εποχές. Θα προηγηθούν τα μοντέλα πρόβλεψης με δεδομένα εξόδου VTEC και ακολούθως με δεδομένα εξόδου STEC.

7.4.1 Αποτελέσματα μοντέλων πρόβλεψης με δεδομένα εξόδου VTEC

1^ο ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 64.


Recurrent neural network (RNN)

Τα αποτελέσματα από την εκπαίδευση του νευρωνικού δικτύου RNN για το πρώτο σενάριο φαίνονται στα ακόλουθα γραφήματα.



Εικόνα 40. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.

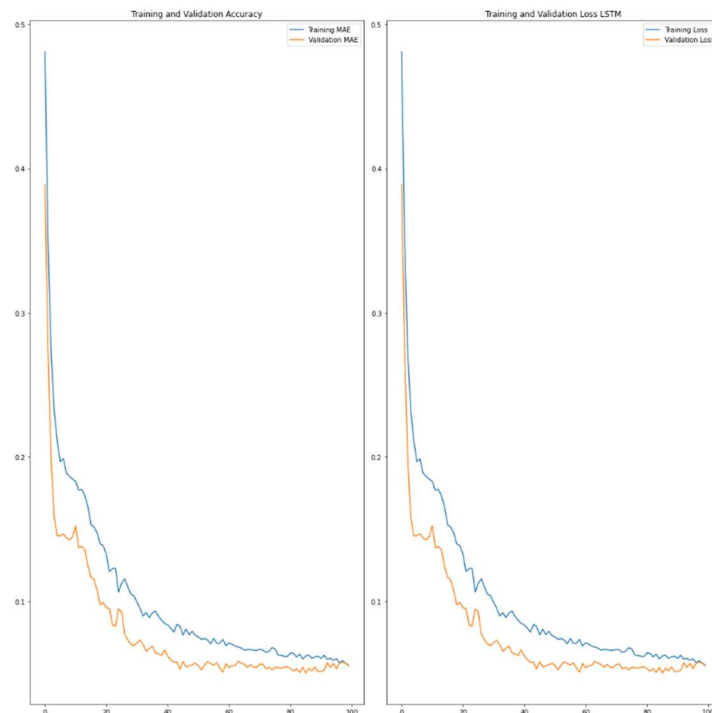
Όπως αναφέραμε και παραπάνω με την μπλε γραμμή αποτυπώνονται τα δεδομένα εκπαίδευσης ενώ με την πορτοκαλί τα δεδομένα ελέγχου. Επιθυμητό είναι οι δύο γραμμές να παρουσιάζουν όμοια πορεία με βέλτιστο το να ταυτίζονται, τότε το δίκτυο έχει εκπαιδευτεί ικανοποιητικά. Στην προκειμένη περίπτωση και το MAE και το Loss των δεδομένων εκπαίδευσης απέχουν από εκείνα των δεδομένων ελέγχου, που σημαίνει ότι η εκπαίδευση του δικτύου δεν είναι ικανοποιητική.



Εικόνα 41. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.


Το συμπέρασμα μας επιβεβαιώνεται με το γράφημα σφάλματος πρόβλεψης των δεδομένων, στο οποίο παρουσιάζεται μεγάλη διασπορά.

Long Short Term Memory (LSTM)



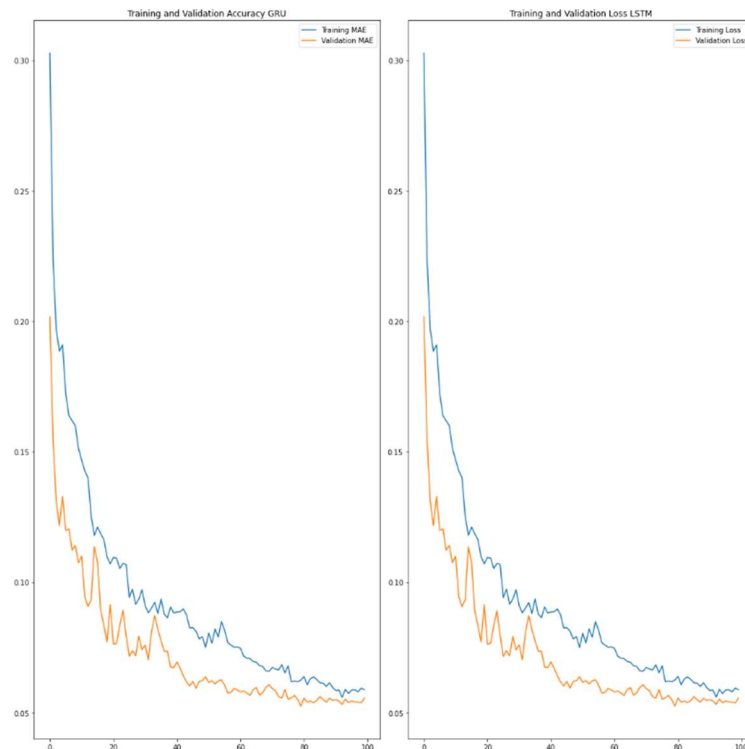
Εικόνα 42. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM

Με ίδιο πλήθος υπερπαραμέτρων το νευρωνικό δίκτυο LSTM δείχνει να προσαρμόζεται καλύτερα από ότι το RNN, καθώς η πορεία των γραφημάτων απεικόνισης, για MAE και το Loss, των δεδομένων εκπαίδευσης και ελέγχου συνάδουν. Βέβαια τιμές σφαλμάτων αρκετά κοντά στη μονάδα δεν αποτελούν ικανοποιητικά αποτελέσματα για την εκπαίδευση του μοντέλου πρόβλεψης. Χωρικά ακρότατα παρουσιάζονται και σε αυτή την περίπτωση.




Εικόνα 43. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.

Gated recurrent units (GRUs)



Εικόνα 44. Γράφηματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.

Το νευρωνικό δίκτυο GRU δείχνει να έχει καλύτερη προσαρμογή από τα δύο προηγούμενα δίκτυα για πλήθος υπερπαραμέτρων 64, παρ' όλα αυτά παρουσιάζονται και στην προκειμένη περίπτωση ακρότατα που μας οδηγούν να επιθυμούμε να συνεχίσουμε την αναζήτηση βέλτιστου μοντέλου.

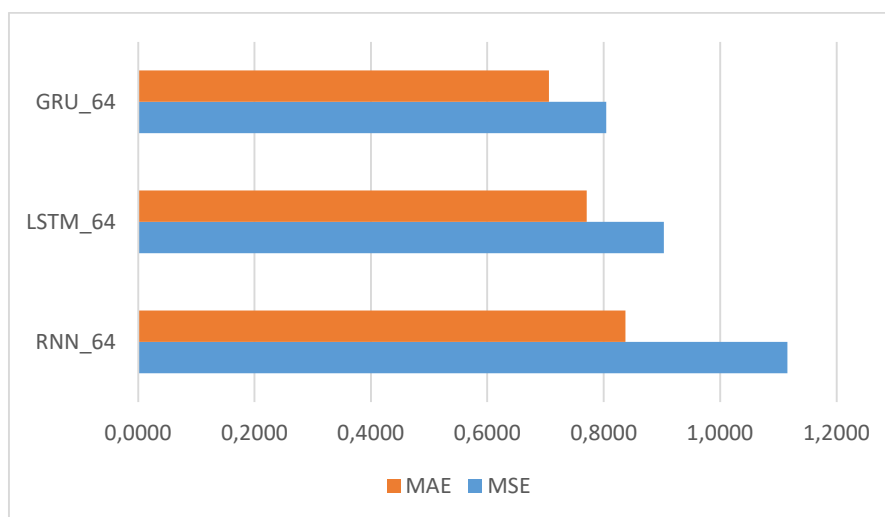


Εικόνα 45. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.

Σύγκριση αποτελεσμάτων εκπαίδευσης δικτύων 1^{ου} σεναρίου

Με το πέρας του πρώτου σεναρίου έπειτα από την αξιολόγηση των γραφημάτων σφαλμάτων διαπιστώθηκαν τα παρακάτω:

- Το πλήθος των υπερπαραμέτρων **δεν** είναι ικανοποιητικό ώστε να σταματήσουμε την αναζήτηση βέλτιστου μοντέλου πρόβλεψης της ιονοσφαιρικής δραστηριότητας.
- Όπως φαίνεται και στο ακόλουθο ραβδόγραμμα καλύτερη προσαρμογή από τα τρία δίκτυα είχε το Gated recurrent units (GRU), με μικρές διαφορές από το Long Short Term Memory (LSTM).

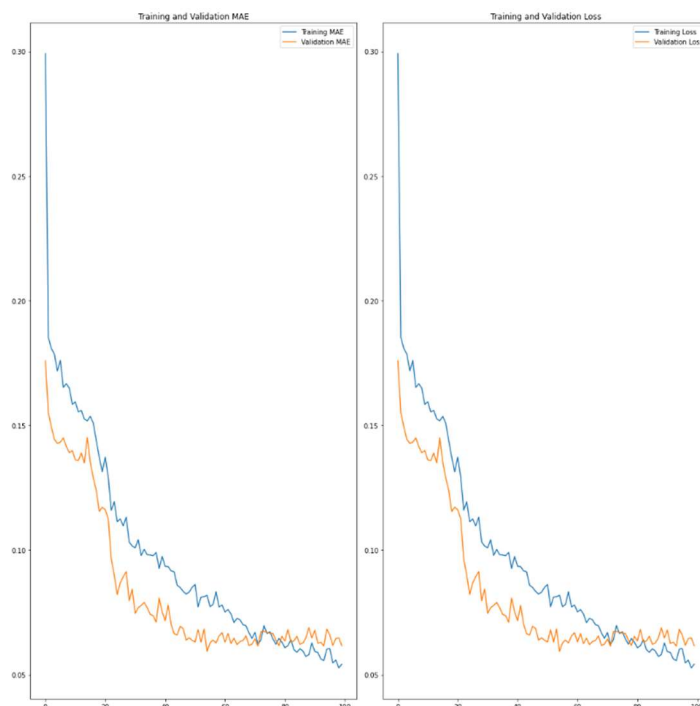


Όσο πιο μικρός είναι ο αριθμός αυτών των δεικτών και όσο περισσότερο ταυτίζονται, τόσο καλύτερα προσδιορίζεται το μοντέλο.

2^ο ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 128.


Recurrent neural network (RNN)

Για πλήθος υπερπαραμέτρων 128 το νευρωνικό δίκτυο RNN εκπαιδεύτηκε και έδωσε τα ακόλουθα γραφήματα σφαλμάτων:



Εικόνα 46. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.

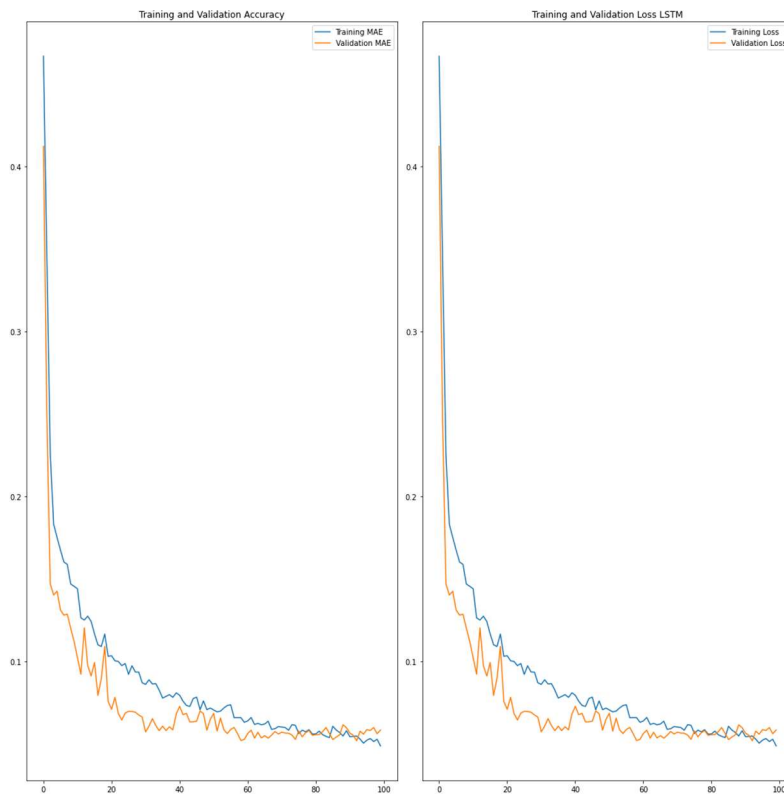
Τα αποτελέσματα είναι ελαφρώς ικανοποιητικότερα σε σύγκριση με το αντίστοιχο δίκτυο με 64 φίλτρα. Η διασπορά παραμένει αρκετά μεγάλη συνεπώς δεν μπορούμε να αποδεχτούμε την εκπαίδευση του μοντέλου ικανοποιητική.




Εικόνα 47. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.

Long Short Term Memory (LSTM)

Τα γραφήματα που ακολουθούν υποδεικνύουν ικανοποιητικότερα αποτελέσματα, για την εκπαίδευση του μοντέλου, καθώς τα σφάλματα μειώθηκαν ικανοποιητικά. Συγκρινόμενα με τα λοιπά δίκτυα στο παρόν σενάριο το LSTM αποτελεί βέλτιστη επιλογή για την επιλογή μοντέλου πρόβλεψης. Παρ' όλα αυτά συνεχίζουν να παρουσιάζονται ακρότατα στο γράφημα σφαλμάτων.

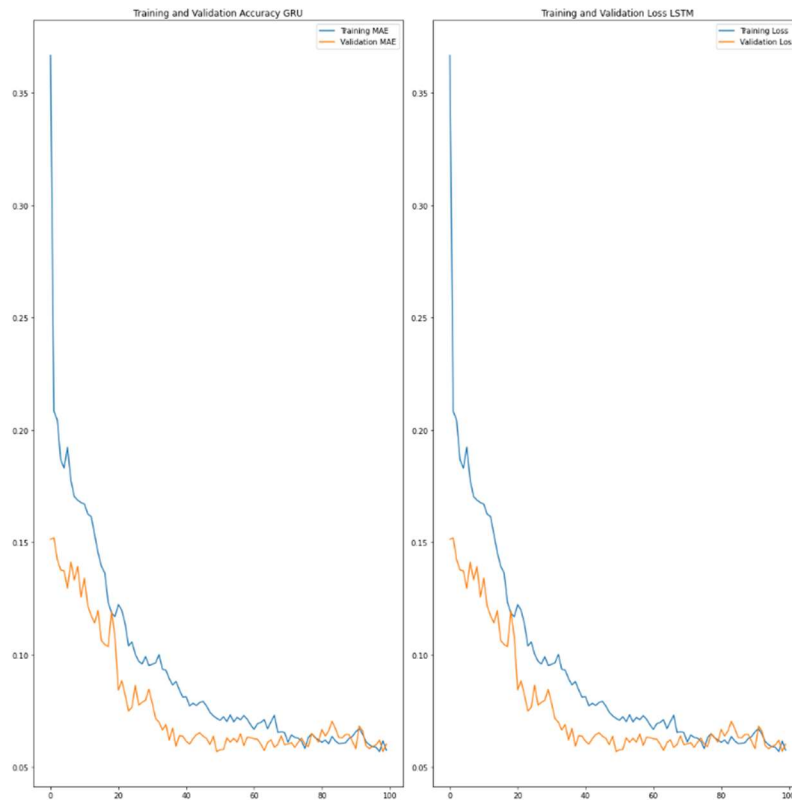


Εικόνα 48. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.




Εικόνα 49. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.

Gated recurrent units (GRUs)



Εικόνα 50. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.

Με την αύξηση του πλήθους των φίλτρων παρατηρούμε την βελτίωση εκπαίδευσης του μοντέλου και στην περίπτωση του GRU δικτύου, με συνέχιση παρουσίας χωρικών ακροτάτων παρόλη τη μείωση του σφάλματος πρόβλεψης.




Εικόνα 51. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.

Σύγκριση αποτελεσμάτων εκπαίδευσης δικτύων 2^{ου} σεναρίου

Με το πέρας αξιολόγησης αποτελεσμάτων 2^{ου} σεναρίου όσον αφορά το επίπεδο εκπαίδευσης των μοντέλων διαπιστώνουμε τα ακόλουθα:


- Αν και με την αύξηση του πλήθους των υπερπαραμέτρων τα σφάλματα μειώθηκαν, παρόλα αυτά κανένα από τα μοντέλα δεν μπορεί να χαρακτηριστεί ως βέλτιστο για την παρούσα μελέτη.
- Το δίκτυο με την καλύτερη προσαρμογή σε αυτό το σενάριο ήταν το LSTM και όχι το GRU όπως στο προηγούμενο.
- Το ραβδόγραμμα σύγκρισης των μοντέλων επιβεβαιώνει τις αξιολογήσεις μας καθώς όλες οι τιμές σφαλμάτων είναι κάτω από τη μονάδα.




3^ο ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 256.

Recurrent neural network (RNN)

Με την αύξηση του πλήθους των υπερπαραμέτρων σε 256 το αποτέλεσμα προσαρμογής του δικτύου RNN δείχνει χειρότερο από τις προηγούμενες περιπτώσεις παρόλο που οι τιμές των μετρητικών δεικτών έχουν μειωθεί.



Εικόνα 52. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.

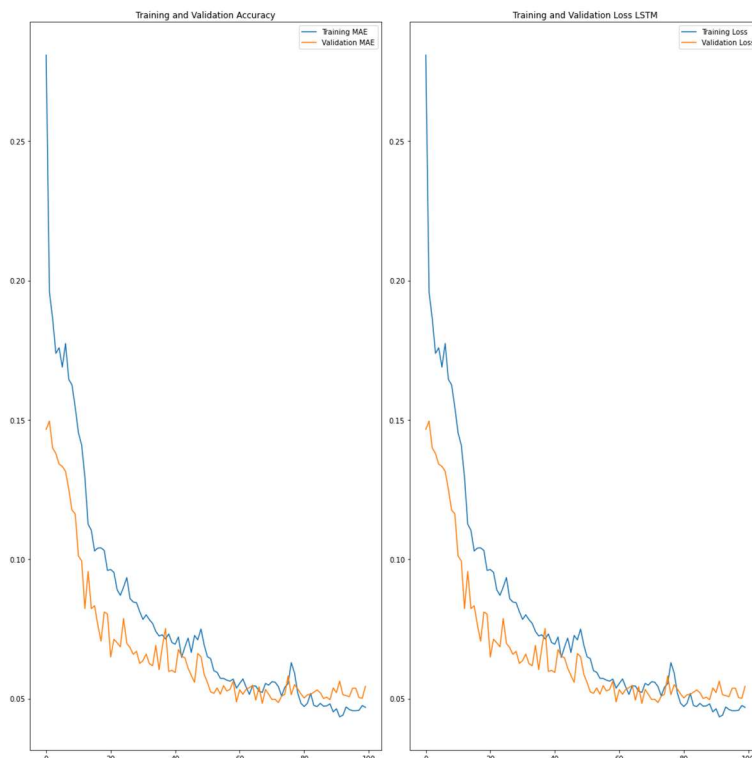


Εικόνα 53. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.


Τα χωρικά ακρότατα σε γράφημα δείχνουν έχουν ίδια εικόνα με ελάχιστη βελτίωση.

Long Short Term Memory (LSTM)

Το δίκτυο LSTM αν και τα δεδομένα στο γράφημα δείχνουν να μην προσαρμόζονται βέλτιστα παρόλα αυτά οι δείκτες σφάλματος MAE και MSE έχουν τι μικρότερες τιμές από κάθε άλλο δίκτυο και αντίστοιχη περίπτωση διαφοροποίησης υπερπαραμέτρων για αυτόν τον τύπο δικτύου



Εικόνα 54. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.



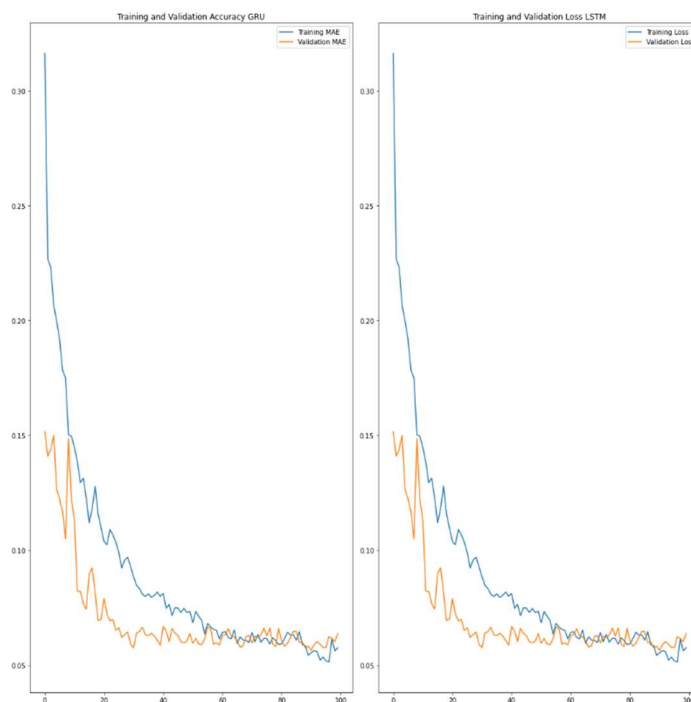
Εικόνα 55. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.

Επίσης τα σφάλματα πρόβλεψης οπτικοποιούνται αρκετά ικανοποιητικά, με κάποια χωρικά ακρότατα, βέλτιστα έως τώρα όμως.


Gated recurrent units (GRUs)

Το παρόν μοντέλο παρουσιάζει ικανοποιητικές τιμές σφαλμάτων, θα μπορούσαμε να πούμε συγκριτικά καλύτερες από τις προηγούμενες περιπτώσεις. Παρατηρούμε όμως ότι το μοντέλο με την παρέλευση 30 εποχών υπερπροσαρμόζεται, γεγονός που

μας οδηγεί να μην το επιλέξουμε ως βέλτιστο μοντέλο και απλά μας προκαλεί το ενδιαφέρον να μελετήσουμε την συμπεριφορά του σε αύξηση των υπερπαραμέτρων στο επόμενο σενάριο.



Εικόνα 56. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.




Εικόνα 57. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.

Τα χωρικά ακρότατα δείχνουν να έχουν μειωθεί, παρόλα αυτά η υπερπροσαρμογή του μοντέλου μας οδηγεί να το απορρίψουμε.

Σύγκριση αποτελεσμάτων εκπαίδευσης δικτύων 3^{ου} σεναρίου

Ολοκληρώνοντας και το 3^ο σενάριο με πλήθος υπερπαραμέτρων 256, οδηγούμαστε στα ακόλουθα συμπεράσματα έπειτα από αξιολόγηση των αποτελεσμάτων εκπαίδευσης των δικτύων.


- Αρχικά τα δίκτυα RNN και GRU έχουν ως αποτέλεσμα τη μείωση των δεικτών σφάλματος στην αύξηση των υπερπαραμέτρων, ωστόσο το με πρώτο τα δεδομένα εκπαίδευσης δεν προσαρμόζονται ικανοποιητικά με τα ελέγχου και το δεύτερο παρουσιάζει υπερπροσαρμογή στο σετ δεδομένων εκπαίδευσης.
- Το δίκτυο LSTM από το παρόν σενάριο αναδεικνύεται ως βέλτιστο καθόσον τα χωρικά του ακρότατα είναι λιγότερα, οι τιμές MAE και MSE είναι οι μικρότερες από κάθε άλλη περίπτωση μοντέλου και τα δεδομένα εκπαίδευσης προσαρμόζονται ικανοποιητικά με τα δεδομένα ελέγχου χωρίς να παρουσιάζεται υπερπροσαρμογή.
- Από το ραβδόγραμμα που ακολουθεί επιβεβαιώνονται τα ανωτέρω συμπεράσματα, καθώς οι τιμές MAE και MSE για το δίκτυο LSTM είναι οι μικρότερες από κάθε άλλη περίπτωση που έχουμε εξετάσει.




4^ο ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 512.

Recurrent neural network (RNN)

Από τα γραφήματα που παρατίθενται για μοντέλο εκπαίδευσης RNN στο παρόν σενάριο, ευκολά οδηγούμαστε στο συμπέρασμα ότι η αύξηση των υπερπαραμέτρων δεν έχει τα επιθυμητά για την μελέτη αποτελέσματα. Τα δεδομένα εκπαίδευσης δεν προσαρμόζονται με τα δεδομένα ελέγχου, ενώ ταυτόχρονα οι δείκτες σφαλμάτων αυξάνουν εν αντίθεση με τα με τα προηγούμενα σενάρια. Επιπρόσθετα τα χωρικά ακρότατα δείχνουν να αυξάνουν, γεγονός που οδηγεί αβίαστα, σε συνδυασμό με τα προηγούμενα, στο να απορρίψουμε το εν λόγω μοντέλο, αφού παρουσιάζει την χειρότερη έως τώρα εικόνα συγκρινόμενο με τα λοιπά μοντέλα.



Εικόνα 58. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.

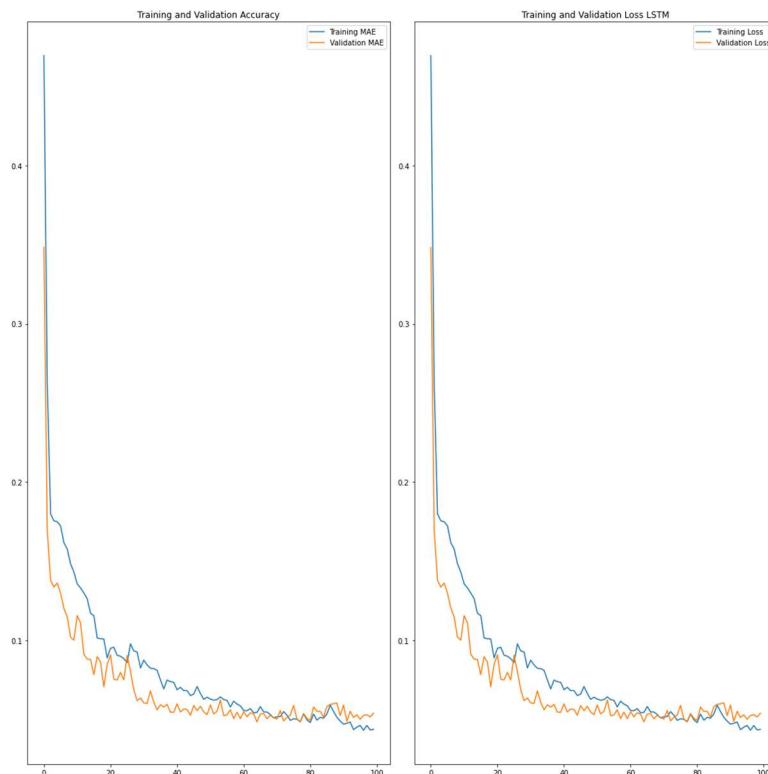


Εικόνα 59. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.


Long Short Term Memory (LSTM)

Το παρόν μοντέλο στο σενάριο των 512 φίλτρων παρουσιάζει καλή προσαρμογή των δεδομένων εκπαίδευσης με τα δεδομένα ελέγχου, όμως παρατηρείται υπερπροσαρμογή με την παρέλευση της 40 εποχής. Επίσης ενώ οι μετρητικοί δείκτες με την αύξηση των υπερπαραμέτρων έως και το τρίτο σενάριο είχαν καθοδική πορεία, στο παρόν σενάριο οι δείκτες MAE και MSE αυξάνουν, γεγονός που μας

οδηγεί στο συμπέρασμα ότι το μοντέλο με πλήθος LSTM με πλήθος υπερπαραμέτρων 256 είναι ίσως το βέλτιστο για την πρόβλεψη των τιμών VTEC.



Εικόνα 60. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.




Εικόνα 61. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.


Η οπτικοποίηση των σφαλμάτων πρόβλεψης παραμένει σχεδόν αμετάβλητη, με την παρουσίαση κάποιων χωρικών ακροτάτων.

Gated recurrent units (GRUs)

Η υπερπροσαρμογή του εν λόγω δικτύου και σε αυτό το σενάριο είναι μεγάλη. Παρατηρούμε επίσης ότι τα δεδομένα εκπαίδευσης προσαρμόζονται αρκετά με τα δεδομένα ελέγχου, ενώ οι τιμές των δεικτών σφαλμάτων παρουσιάζουν μικρή αύξηση και το χωρικά ακρότατα μειώθηκαν ελαφρώς.



Εικόνα 62. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.




Εικόνα 63. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.

Η υπερπροσαρμογή του δικτύου από την 20 εποχή μας απαγορεύει να υιοθετήσουμε το εν λόγω δίκτυο με τις επιλεγμένες παραμέτρους και υπερπαραμέτρους.

Σύγκριση αποτελεσμάτων εκπαίδευσης δικτύων 4^{ου} σεναρίου

Με το πέρας αξιολόγησης του 4^{ου} σεναρίου, που ήταν και το τελευταίο για τα μοντέλα πρόβλεψης με δεδομένα εξόδου VTEC, καταλήγουμε στα εξής:

- Με την αύξησης φίλτρων δεδομένων εισόδου τα μοντέλα δείχνουν να βελτιώνονται, αλλά μέχρι ένα σημείο και μετά υπερπροσαρμόζονται. Ταυτόχρονα οι δείκτες σφαλμάτων ενώ είχαν καθοδική πορεία τείνουν να αυξάνουν.
- Στο παρόν σενάριο καλύτερο μοντέλο αναδείχθηκε το LSTM, όμως δεν είναι και το καλύτερο συγκρινόμενο με τα μοντέλα των λοιπών σεναρίων.
- Στο ραβδόγραμμα που ακολουθεί οπτικοποιούνται οι διαφοροποιήσεις των δεικτών MAE και MSE για τα αποτελέσματα του 4^{ου} σεναρίου.

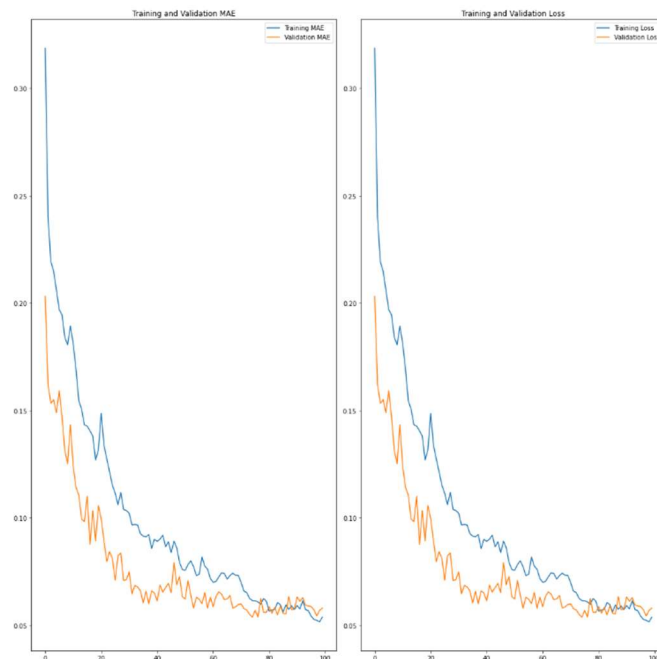


7.4.2 Αποτελέσματα μοντέλων πρόβλεψης με δεδομένα εξόδου STEC

Όπως και στην προηγούμενη υποενότητα, αλλά εν προκειμένω μοντέλα πρόβλεψης με δεδομένα εξόδου STEC, εκπαιδεύτηκαν τρία είδη δικτύων σε 100 εποχές με πρώτο σενάριο 64 φίλτρα δεδομένων εισόδου.


1^ο ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 64.

Recurrent neural network (RNN)



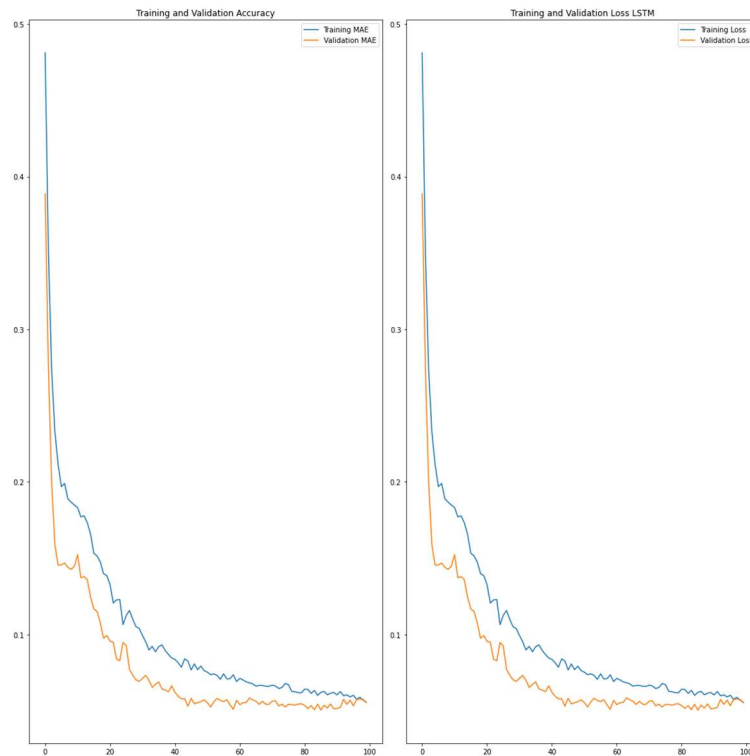
Εικόνα 64. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.

Τα αποτελέσματα του πρώτου σεναρίου κατά την εκπαίδευση του νευρωνικού δικτύου RNN δεν δείχνουν αρκετά ικανοποιητικά καθώς, δεν παρατηρείται καλή προσαρμογή ανάμεσα στα δεδομένα εκπαίδευσης και στα δεδομένα ελέγχου, ενώ ταυτόχρονα παρατηρείται μεγάλη διασπορά στα σφάλματα πρόβλεψης, καθώς οι τιμές MAE και MSE είναι αρκετά μεγάλες.




Εικόνα 65. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.

Long Short Term Memory (LSTM)



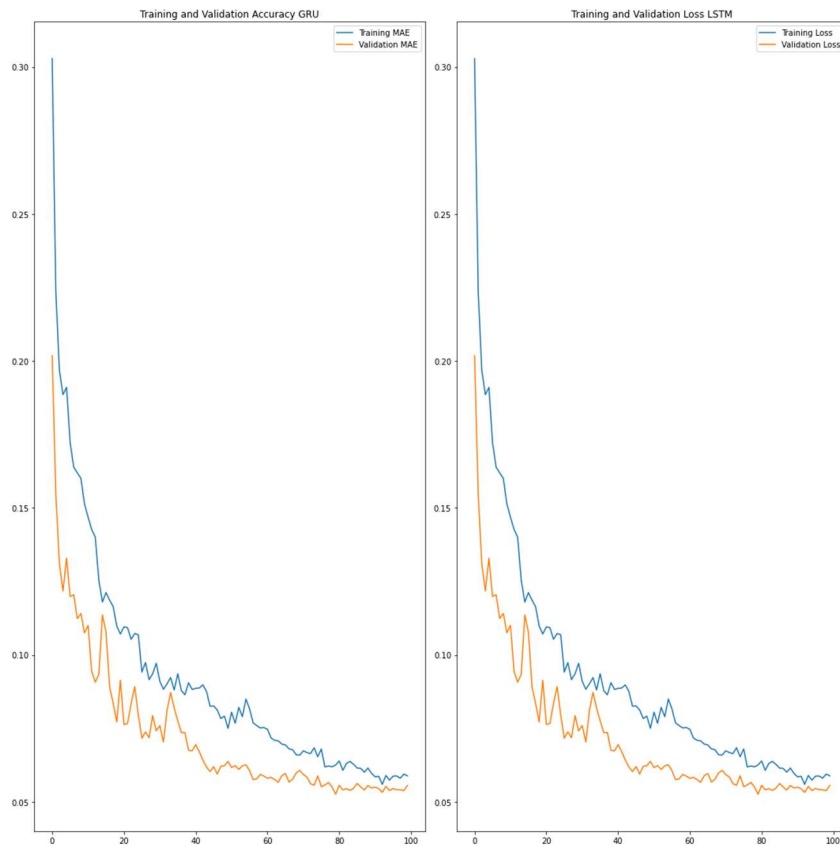
Εικόνα 66. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.

Η εικόνα των γραφημάτων σφάλματος για την εκπαίδευση του νευρικού δικτύου LSTM δείχνει συγκριτικά καλύτερη από εκείνη του RNN το παρόντος σεναρίου. Τα δεδομένα εκπαίδευσης προσαρμόζονται με τα δεδομένα ελέγχου, βέβαια με μια τάση υπερπροσαρμογής. Επίσης παρατηρούνται χωρικά ακρότατα, ενώ οι δείκτες MAE και MSE και σε αυτό το μοντέλο παρουσιάζουν υψηλές τιμές.




Εικόνα 67. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.

Gated recurrent units (GRUs)



Εικόνα 68. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.

Η προσαρμογή των δεδομένων εκπαίδευσης στα δεδομένα ελέγχου είναι χειρότερη από εκείνη του LSTM μοντέλου για το τρέχον σενάριο. Η διασπορά είναι σχετικά έντονη, καθώς οι δείκτες MAE και MSE είναι αρκετά μεγάλοι αλλά συγκριτικά καλύτεροι από εκείνους του μοντέλου RNN το παρόντος σεναρίου.




Εικόνα 69. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.

Σύγκριση αποτελεσμάτων εκπαίδευσης δικτύων 1^{ου} σεναρίου

Με το πέρας αξιολόγησης του πρώτου σεναρίου για την εκπαίδευση μοντέλων πρόβλεψης με δεδομένα εξόδου τις τιμές STEC, διαπιστώθηκαν τα ακόλουθα:


- Η εκπαίδευση του νευρωνικού δικτύου LSTM έδωσε τα καλύτερα στατιστικά αποτελέσματα, με ικανοποιητική προσαρμογή των δεδομένων εκπαίδευσης και τον δεδομένων ελέγχου. Παρατηρήθηκε βέβαια μια τάση υπερπροσαρμογής άλλα όχι έντονη.
- Οι δείκτες MAE και MSE ήταν αρκετά αυξημένοι σε όλα τα μοντέλα, συγκριτικά με το αντίστοιχο σενάριο για δεδομένα εξόδου VTEC που είδαμε στην προηγούμενη υποενότητα.
- Στο ραβδόγραμμα που ακολουθεί επιβεβαιώνονται τα όσα συμπεράναμε.



2^ο ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 128.


Recurrent neural network (RNN)

Με την αύξηση των υπερπαραμέτρων από 64 σε 128, τα αποτελέσματα από την εκπαίδευση του νευρωνικού δικτύου RNN, δείχνουν χειρότερα. Μέχρι την εποχή 60 δείχνουν τα δεδομένα εκπαίδευσης να έχουν καλή προσαρμογή με τα δεδομένα ελέγχου, όμως στη συνέχεια παρατηρείται μια τάση υπερπροσαρμογής.



Εικόνα 70. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.

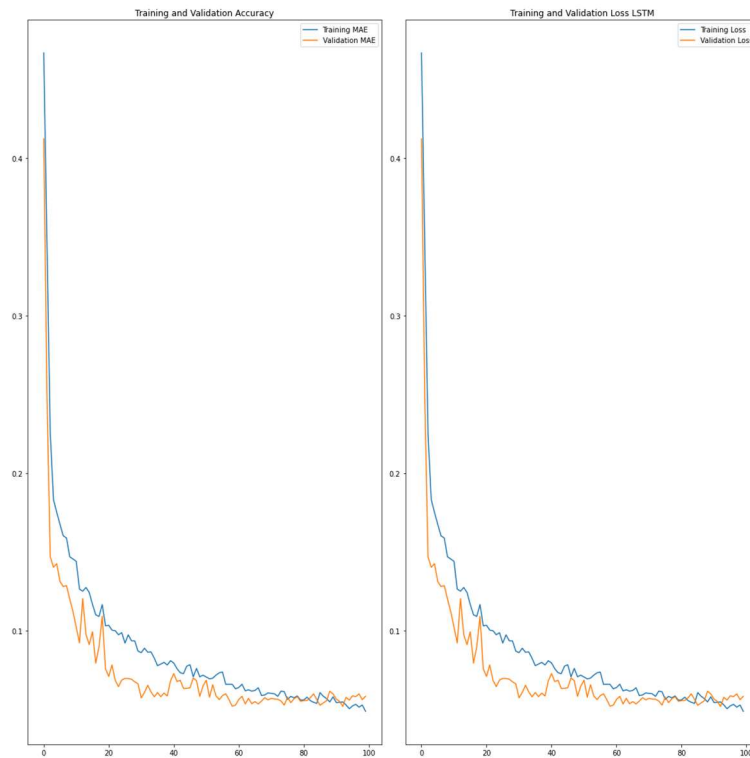
Επίσης εντοπίζονται αρκετά χωρικά ακρότατα, ίσως και περισσότερα από το αντίστοιχο μοντέλο του προηγούμενου σεναρίου, αν και οι μετρητικοί δείκτες παρουσιάζουν μείωση.



Εικόνα 71. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.


Long Short Term Memory (LSTM)

Στα ακόλουθα γραφήματα παρατηρούμε ότι, και για το εν λόγω μοντέλο, με την αύξηση των υπερπαραμέτρων η προσαρμογή των δεδομένων δεν βελτιώνεται, ενώ η τάση υπερπροσαρμογής αυξάνει, βέβαια τα αποτελέσματα είναι σχετικά ικανοποιητικά.



Εικόνα 72. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.

Επίσης παρατηρούμε ότι η διασπορά χωρικών ακροτάτων μειώθηκε, σε σύγκριση με το πρώτο σενάριο, καθώς και οι μετρητικοί δείκτες MAE και MSE μειώθηκαν.

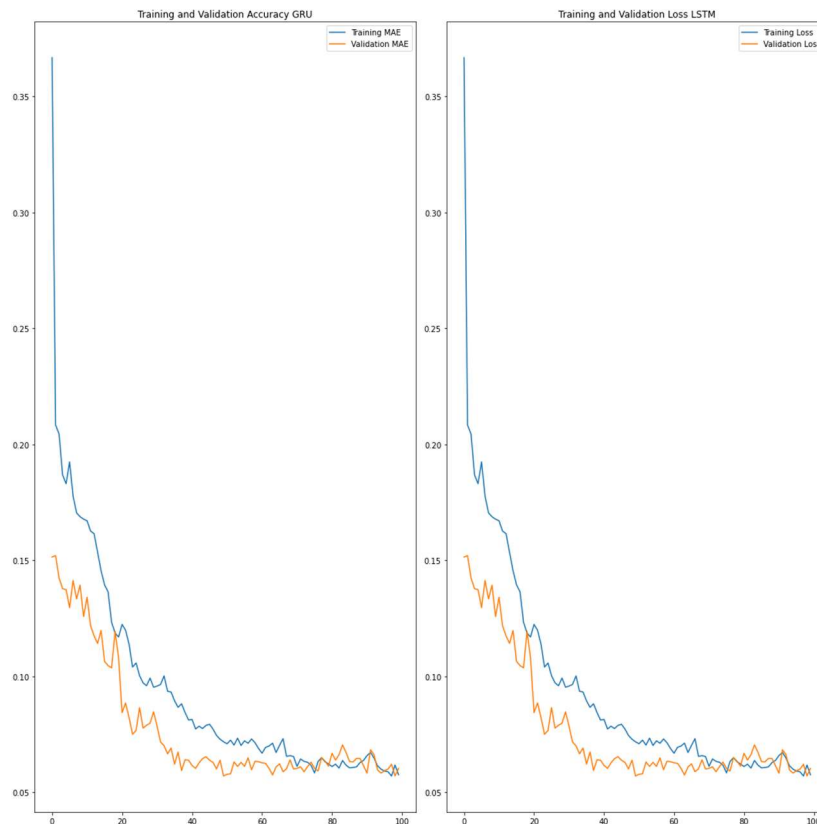


Εικόνα 73. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.


Gated recurrent units (GRUs)

Στα ακόλουθα αποτελέσματα εκπαίδευσης του μοντέλου GRU παρατηρούμε τάση υπερπροσαρμογής του μοντέλου. Να σημειωθεί όμως ότι τα χωρικά ακρότατα

μειώνονται και σε αυτό το μοντέλο για το τρέχον σενάριο, χωρίς όμως το παρόν μοντέλο να αποτελεί την βέλτιστη επιθυμητή επιλογή.



Εικόνα 74. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.




Εικόνα 75. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.

Σύγκριση αποτελεσμάτων εκπαίδευσης δικτύων 2^{ου} σεναρίου

Έπειτα από αξιολόγηση των αποτελεσμάτων του δευτέρου σεναρίου καταλήγουμε στα εξής συμπεράσματα:


- Οι μετρητικοί δείκτες δείχνουν να μειώνονται και τα χωρικά ακρότατα να μειώνονται. Βέβαια παρατηρείται μια έντονη μεταξύ των τιμών MAE και MSE το οποίο υποδηλώνει μη καλός προσδιορισμός του μοντέλου.
- Από τα τρία νευρωνικά δίκτυα καλύτερη προσαρμογή δείχνει να έχει η εκπαίδευση του μοντέλου LSTM, γεγονός που επιβεβαιώνεται και από το ακόλουθο γράφημα.



3^ο ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 256.


Recurrent neural network (RNN)

Τα αποτελέσματα για την εκπαίδευση του δικτύου RNN στο τρέχον σενάριο γίνονται ακόμη χειρότερα σε σύγκριση με τα δύο προγενέστερα. Τα δεδομένα εκπαίδευσης δεν προσαρμόζονται με δεδομένα ελέγχου, ενώ εμφανίζεται και μια τάση υπερπροσαρμογής μετά την 80^η εποχή.



Εικόνα 76. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.

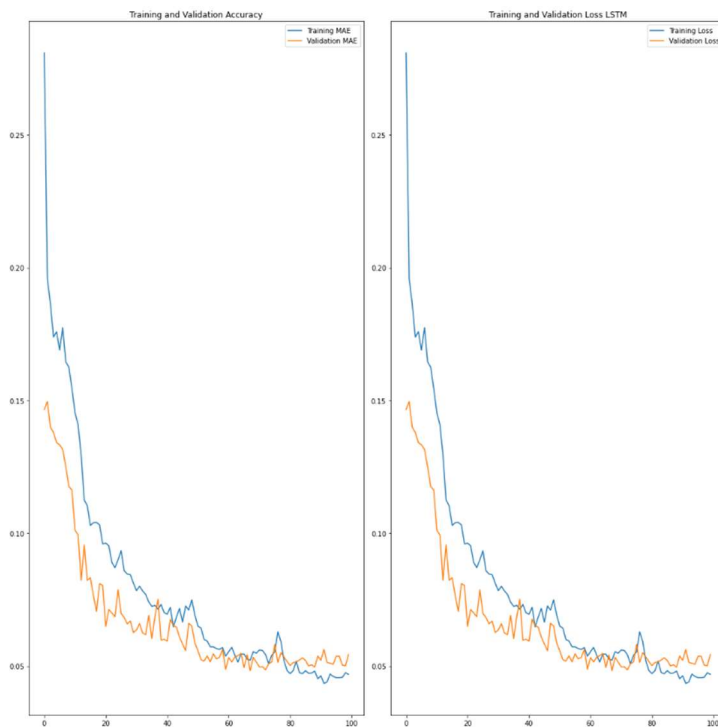
Τα χωρικά ακρότατα από την άλλη δείχνουν να μειώνονται με ταυτόχρονη μείωση των τιμών MAE και MSE.



Εικόνα 77. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.


Long Short Term Memory (LSTM)

Στο παρόν σενάριο το νευρωνικό δίκτυο LSTM παρουσιάζει την καλύτερη εικόνα σε σύγκριση με τα προγενέστερα σενάρια. Τα δεδομένα εκπαίδευσης προσαρμόζονται ικανοποιητικά με τα δεδομένα ελέγχου, ενώ η τάση υπερπροσαρμογής δείχνει να ελατώθηκε.



Εικόνα 78. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.

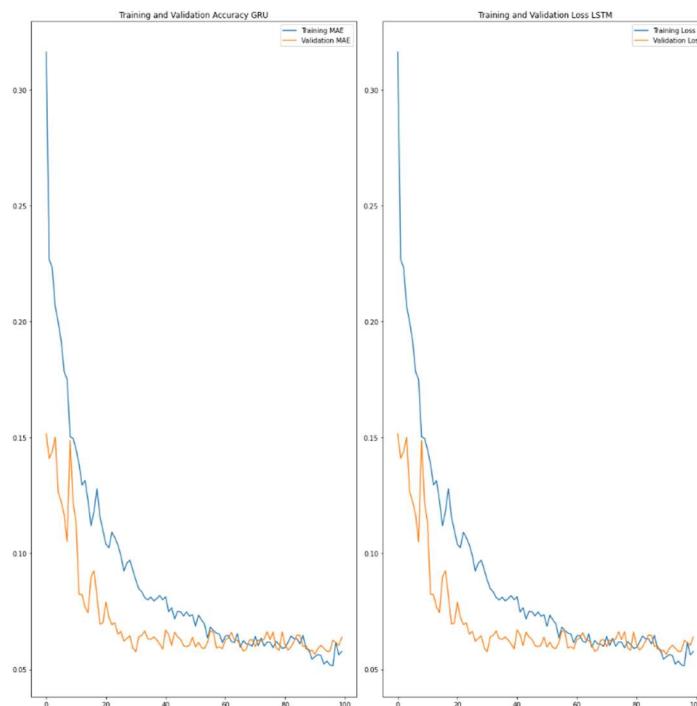
Οι τιμές των MAE και MSE είναι οι μικρότερες σε σύγκριση με τα προηγούμενα σενάρια και τα χωρικά ακρότατα δείχνουν να έχουν μειωθεί αρκετά, ως εκ τούτου το παρόν μοντέλο αποτελεί βέλτιστη έως τώρα επιλογή.




Εικόνα 79. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.

Gated recurrent units (GRUs)

Το γράφημα που εξήχθη από την εκπαίδευση του νευρωνικού δικτύου GRU στο παρόν σενάριο εμφανίζει υπερπροσαρμογή και συνεπώς από τις χειρότερες έως τώρα επιλογές.



Εικόνα 80. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.




Εικόνα 81. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.

Σύγκριση αποτελεσμάτων εκπαίδευσης δικτύων 3^{ου} σεναρίου


Αφού αξιολογήθηκαν τα γραφήματα σε συνδυασμό με τις τιμές σφαλμάτων εκπαίδευσης των δικτύων για το τρίτο σενάριο καταλήξαμε στα ακόλουθα:

- Το νευρωνικό δίκτυο LSTM παρουσιάζει βέλτιστη προσαρμογή συγκρινόμενα με κάθε άλλο προγενέστερο σενάριο της παρούσας υποενοότητας.
- Τα μοντέλα RNN και GRU με την αύξηση των φίλτρων δεδομένων εισόδου στο πλήθος 256 δεν εκπαιδεύτηκαν με αναμενόμενα στατικά πρόβλεψης, αντίθετα απορρίφθηκαν λόγω κακής προσαρμογής δεδομένων εκπαίδευσης και ελέγχου.
- Οι τιμές των μετρητικών δεικτών αν και διατηρούνται μεγάλες, όπως βλέπουμε και στο ραβδόγραμμα που ακολουθεί θεωρούνται ικανοποιητικές, κυρίως για το νευρωνικό δίκτυο LSTM καθώς είναι οι μικρότερες έως την ολοκλήρωση το τρέχοντος σεναρίου.




4^ο ΣΕΝΑΡΙΟ: Πλήθος φίλτρων 512.

Recurrent neural network (RNN)



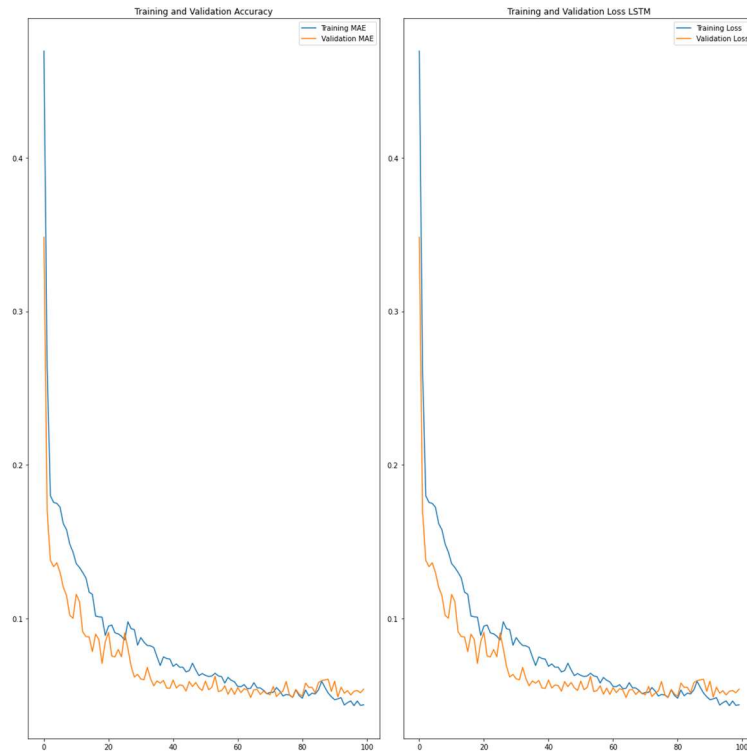
Εικόνα 82. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου RNN.

Τα ανωτέρω γραφήματα αποτελούν τη χειρότερη έως τώρα προσαρμογή, καθώς οι γραμμές Training MAE και Validation MAE όπως και οι Training Loss και Validation Loss απέχουν περισσότερο από κάθε άλλη φορά. Σύμφωνα με τα όσα παρατηρούμε το συγκεκριμένο μοντέλο δεν αποτελεί επιλογή μοντέλου πρόβλεψης ιονοσφαιρικής δραστηριότητας. Απόφαση που επιβεβαιώνεται και από τη έντονη εμφάνιση χωρικών ακροτάτων.




Εικόνα 83. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο RNN.

Long Short Term Memory (LSTM)




Εικόνα 84. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου LSTM.

Αντίθετα το νευρωνικό δίκτυο LSTM παρουσιάζει καλή προσαρμογή μεταξύ δεδομένων εκπαίδευσης και ελέγχου, όμως παρατηρούμε και το φαινόμενο υπερπροσαρμογής από την 30^η κιόλας εποχή. Επίσης τα χωρικά ακρότατα στο παρόν σενάριο παρουσιάζουν καλύτερη εικόνα σε σχέση με το μοντέλο RNN. Παρόλα αυτά εύκολα συμπεραίνουμε ότι στο προηγούμενο σενάριο η εκπαίδευση του δικτύου ήταν καλύτερη.




Εικόνα 85. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο LSTM.

Gated recurrent units (GRUs)



Εικόνα 86. Γραφήματα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης δικτύου GRU.

Η υπερπροσαρμογή του δικτύου συνεχίζει να υφίσταται παρόλο που αυξήσαμε τα φίλτρα δεδομένων εισόδου. Επίσης οι τιμές των MAE και MSE μειώθηκαν συγκριτικά με το προηγούμενο σενάριο.




Εικόνα 87. Σφάλμα πρόβλεψης των δεδομένων σε δίκτυο GRU.

Σύγκριση αποτελεσμάτων εκπαίδευσης δικτύων 4^{ου} σεναρίου

Με την ολοκλήρωση του παρόντος σεναρίου ολοκληρώθηκαν τα σενάρια για την μελέτη εκπαίδευσης νευρωνικών δικτύων πρόβλεψης ιονοσφαιρικής

δραστηριότητας. Αφού αξιολογήσαμε τα αποτελέσματα οδηγηθήκαμε στα παρακάτω συμπεράσματα:

- Η αύξηση των υπερπαραμέτρων στην τιμή 512 δεν βελτίωσε την εκπαίδευση των νευρωνικών δικτύων, αλλά είχε τα αντίθετα αποτελέσματα.
- Στο παρόν σενάριο βέλτιστο μοντέλο αναδείχτηκε το LSTM, βέβαια με εικόνα φαινομένου υπερπροσαρμογής.
- Οι μετρητικοί δείκτες με την αύξηση των υπερπαραμέτρων αυξήθηκαν αντί να μειωθούν, όπως συνέβαινε στην ακολουθία των τριών πρώτων σεναρίων, γεγονός που μας οδηγεί να σταματήσουμε την μελέτη περαιτέρω σεναρίων.




7.5 Βέλτιστο μοντέλο πρόβλεψης ιονοσφαιρικής δραστηριότητας


Με το πέρας της παρούσας μελέτης, καταλήξαμε στην ανάδειξη ως βέλτιστου μοντέλου πρόβλεψης ιονοσφαιρικής δραστηριότητας, το μοντέλο LSTM με συνδυασμό παραμέτρων τις Γεωμαγνητικές και τις Solar Radio Flux και με πλήθος υπερπαραμέτρων 256. Το συγκεκριμένο μοντέλο παρουσίασε την καλύτερη προσαρμογή δεδομένων εκπαίδευσης και ελέγχου σε σύγκριση με τα αποτελέσματα που έδωσαν όλα τα υπόλοιπα που υλοποιήθηκαν.

Το συμπέρασμά μας θεωρούμε ότι είναι ασφαλές, καθώς το μοντέλο LSTM παρουσίασε την καλύτερη προσαρμογή σε σύγκριση με τα RNN και GRU στα διάφορα σενάρια. Εκτός αυτού το πλήθος 256 το θεωρούμε βέλτιστο, αφού με την αύξηση του πλήθους των φίλτρων μέχρι την τιμή 256 το μοντέλο παρουσίαζε βελτίωση και στο σενάριο του πλήθους 512 φίλτρων το μοντέλο υπερπροσαρμόστηκε.

Πίνακας 5. Συγκεντρωτικό γράφημα μετρητικών δεικτών MAE και MSE όλων των σεναρίων μοντέλων πρόβλεψης VTEC.



Πίνακας 6. Συγκεντρωτικό γράφημα μετρητικών δεικτών MAE και MSE όλων των σεναρίων μοντέλων πρόβλεψης STEC.



Συμπεράσματα

Ο στόχος της παρούσας διπλωματικής εργασίας επετεύχθη, καθώς μέσω αξιολόγησης αποτελεσμάτων εκπαίδευσης νευρικών δικτύων, χρησιμοποιώντας δεδομένα μετρήσεων GNSS, αναδείχθηκε βέλτιστο μοντέλο πρόβλεψης ιονοσφαιρικής δραστηριότητας.

Με την εκπόνηση της παρούσας πέραν του βέλτιστου μοντέλου αναδείχτηκε επίσης, η δυνατότητα επίλυσης δύσκολων και ουσιαστικών υπολογιστικών προβλημάτων με αλγόριθμους βαθιάς μάθησης, όπως τα νευρωνικά δίκτυα RNN, LSTM και GRU που χρησιμοποιήθηκαν.

Ακόμη αναδείχθηκε το σχεδόν μηδενικό κόστος της μελέτης, αφού τα δεδομένα αντλήθηκαν από το διαδίκτυο και η επεξεργασία και εξαγωγή αποτελεσμάτων και συμπερασμάτων πραγματοποιήθηκε σε χαμηλού κόστους υπολογιστική μονάδα, σε υψηλού επιπέδου (κοντά στο χρήστη) γλώσσα προγραμματισμού.

Ως γλώσσα προγραμματισμού επιλέχθηκε η Python καθώς προσφέρει δύο μεγάλα πλεονέκτημα στην αντιμετώπιση του παραπάνω προβλήματος. Είναι μια ανοιχτού κώδικα γλώσσα με τρομερές δυνατότητες που διαθέτει χωρίς κόστος άπειρα εργαλεία και βιβλιοθήκες. Το δεύτερο πλεονέκτημα αφορά στα αναφερόμενα εργαλεία και οι βιβλιοθήκες pandas, shap και sklearn, προσφέρουν συναρτήσεις που κάνουν ειδικά τον προγραμματισμό δικτύων μηχανικής μάθησης εφικτό σε επαγγελματίες χρήστες και μη.

Τέλος κρίνεται σκόπιμη η περαιτέρω μελέτη μεγαλύτερων χρονοσειρών και εκμετάλλευση μεγαλύτερου όγκου δεδομένων, για την εξαγωγή ακόμη πιο αξιόπιστων συμπερασμάτων, με τελικό στόχο τη βελτιστοποίηση μοντέλων πρόβλεψης ιονοσφαιρικής δραστηριότητας.

Αναφορές

- [1] R. Orús, M. Hernández-Pajares, J. M. Juan, J. Sanz, και M. García-Fernández, 'Performance of different TEC models to provide GPS ionospheric corrections', *J. Atmospheric Sol.-Terr. Phys.*, τ. 64, τχ. 18, σσ. 2055–2062, Δεκεμβρίου 2002, doi: 10.1016/S1364-6826(02)00224-9.
- [2] Κ. Μανδαλίδης, 'Εφαρμογή του μετασχηματισμού Hilbert-Huang στη μελέτη μεταβολών της ιονόσφαιρας', Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης, 2018. Ημερομηνία πρόσβασης: 15 Οκτώβριος 2022. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://ikee.lib.auth.gr/record/300785>
- [3] Jingbin L. I. U., Zemin W., Hongping Z., και Wenyao Z. H. U., 'Comparison and Consistency Research of Regional Ionospheric TEC Models Based on GPS Measurements', *武汉大学学报 • 信息科学版*, τ. 33, τχ. 5, σσ. 479–483, Μαΐου 2008.
- [4] Ι. Κ. Φαρμακίδου και Ι. Κ. Farmakidis, 'Μελέτη της ιονόσφαιρας στην Ελλάδα μέσω της επεξεργασίας παρατηρήσεων GPS', bachelorThesis, 2013. Ημερομηνία πρόσβασης: 15 Οκτώβριος 2022. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://dspace.lib.ntua.gr/xmlui/handle/123456789/38351>
- [5] I. L. Mallika, D. V. Ratnam, Y. Ostuka, G. Sivavaraprasad, και S. Raman, 'Implementation of Hybrid Ionospheric TEC Forecasting Algorithm Using PCA-NN Method', *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, τ. 12, τχ. 1, σσ. 371–381, Ιανουαρίου 2019, doi: 10.1109/JSTARS.2018.2877445.
- [6] B. Hofmann-Wellenhof, H. Lichtenegger, και E. Wasle, *GNSS – Global Navigation Satellite Systems: GPS, GLONASS, Galileo, and more*. Springer Science & Business Media, 2007.
- [7] G. Böhme, 'atmosphere', *Online Encycl. Philos. Nat.*, τχ. 1, Art. τχ. 1, Ιουνίου 2021, doi: 10.11588/oeprn.2021.1.80607.
- [8] M. C. Kelley, *The Earth's Ionosphere: Plasma Physics and Electrodynamics*. Academic Press, 2009.
- [9] M. Kaselimi, N. Doulamis, A. Doulamis, A. Voulodimos, και E. Protopapadakis, 'Bayesian-optimized Bidirectional LSTM Regression Model for Non-intrusive Load Monitoring', στο *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Φεβρουαρίου 2019, σσ. 2747–2751. doi: 10.1109/ICASSP.2019.8683110.
- [10] A. J. Florczyk κ.ά., 'A New European Settlement Map From Optical Remotely Sensed Data', *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, τ. 9, τχ. 5, σσ. 1978–1992, Μαΐου 2016, doi: 10.1109/JSTARS.2015.2485662.
- [11] J. T. Gosling, E. Hildner, R. M. MacQueen, R. H. Munro, A. I. Poland, και C. L. Ross, 'The speeds of coronal mass ejection events', *Sol. Phys.*, τ. 48, τχ. 2, σσ. 389–397, Ιουνίου 1976, doi: 10.1007/BF00152004.
- [12] E. Stevenson, V. Rodriguez-Fernandez, E. Minisci, και D. Camacho, 'A deep learning approach to solar radio flux forecasting', *Acta Astronaut.*, τ. 193, σσ. 595–606, Απριλίου 2022, doi: 10.1016/j.actaastro.2021.08.004.
- [13] M. A. Balikhin, R. J. Boynton, S. N. Walker, J. E. Borovsky, S. A. Billings, και H. L. Wei, 'Using the NARMAX approach to model the evolution of energetic electrons

- fluxes at geostationary orbit', *Geophys. Res. Lett.*, τ. 38, τχ. 18, 2011, doi: 10.1029/2011GL048980.
- [14] T. N. Davis και M. Sugiura, 'Auroral electrojet activity index AE and its universal time variations', *J. Geophys. Res. 1896-1977*, τ. 71, τχ. 3, σσ. 785–801, 1966, doi: 10.1029/JZ071i003p00785.
- [15] 'On the existence of a long range correlation in the Geomagnetic Disturbance storm time (Dst) index | SpringerLink'. <https://link.springer.com/article/10.1007/s10509-011-0836-1> (ημερομηνία πρόσβασης 18 Οκτώβριος 2022).
- [16] T. Mitchell, B. Buchanan, G. DeJong, T. Dietterich, P. Rosenbloom, και A. Waibel, 'Machine Learning', *Annu. Rev. Comput. Sci.*, τ. 4, τχ. 1, σσ. 417–433, 1990, doi: 10.1146/annurev.cs.04.060190.002221.
- [17] Y. LeCun, Y. Bengio, και G. Hinton, 'Deep learning', *Nature*, τ. 521, τχ. 7553, Art. τχ. 7553, Μαΐου 2015, doi: 10.1038/nature14539.
- [18] C. M. Bishop, 'Neural networks and their applications', *Rev. Sci. Instrum.*, τ. 65, τχ. 6, σσ. 1803–1832, Ιουνίου 1994, doi: 10.1063/1.1144830.
- [19] S. Grossberg, 'Recurrent Neural Networks', *Scholarpedia*, τ. 8, τχ. 2, σ. 1888, Φεβρουαρίου 2013, doi: 10.4249/scholarpedia.1888.
- [20] A. Sherstinsky, 'Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network', *Phys. Nonlinear Phenom.*, τ. 404, σ. 132306, Μαρτίου 2020, doi: 10.1016/j.physd.2019.132306.
- [21] R. Dey και F. M. Salem, 'Gate-variants of Gated Recurrent Unit (GRU) neural networks', στο *2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS)*, Δεκεμβρίου 2017, σσ. 1597–1600. doi: 10.1109/MWSCAS.2017.8053243.
- [22] G. van Rossum (Guido), 'Python reference manual', *Department of Computer Science [CS]*, τχ. R 9525. CWI, 1 Ιανουάριος 1995. Ημερομηνία πρόσβασης: 18 Οκτώβριος 2022. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://ir.cwi.nl/pub/5008>
- [23] M. Canesche, L. Bragança, O. P. V. Neto, J. A. Nacif, και R. Ferreira, 'Google Colab CAD4U: Hands-On Cloud Laboratories for Digital Design', στο *2021 IEEE International Symposium on Circuits and Systems (ISCAS)*, Φεβρουαρίου 2021, σσ. 1–5. doi: 10.1109/ISCAS51556.2021.9401151.
- [24] P. Goldsborough, 'A Tour of TensorFlow'. arXiv, 1 Οκτώβριος 2016. doi: 10.48550/arXiv.1610.01178.
- [25] A. Gulli και S. Pal, *Deep Learning with Keras*. Packt Publishing Ltd, 2017.
- [26] W. McKinney, *Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython*. O'Reilly Media, Inc., 2012.
- [27] S. van der Walt, S. C. Colbert, και G. Varoquaux, 'The NumPy Array: A Structure for Efficient Numerical Computation', *Comput. Sci. Eng.*, τ. 13, τχ. 2, σσ. 22–30, Μαρτίου 2011, doi: 10.1109/MCSE.2011.37.
- [28] T. E. Oliphant, *A guide to NumPy*, τ. 1. Trelgol Publishing USA, 2006.
- [29] C. E. Noll, 'The crustal dynamics data information system: A resource to support scientific analysis using space geodesy', *Adv. Space Res.*, τ. 45, τχ. 12, σσ. 1421–1440, Ιουνίου 2010, doi: 10.1016/j.asr.2010.01.018.
- [30] J. Kouba και B. Street, 'A GUIDE TO USING INTERNATIONAL GNSS SERVICE (IGS) PRODUCTS', σ. 34.

- [31] W. Gurtner και L. Estey, 'RINEX The Receiver Independent Exchange Format', σ. 40.
- [32] 'A study of vTEC above Nepal exploring different calibration techniques, including a comparison with the NeQuick-2 model | SpringerLink'. <https://link.springer.com/article/10.1007/s10509-022-04041-w> (ημερομηνία πρόσβασης 18 Οκτώβριος 2022).

Παραρτήματα

A. Πίνακας δεδομένων ανά μήνα

<https://www.dropbox.com/s/xxio754m78y9fzz/Indices.txt?dl=0>

B. Κώδικας σε γλώσσα προγραμματισμού Python

```
from google.colab import drive
drive.mount('/content/drive')
```

Importing libraries

```
import pandas as pd
import numpy as np
# from __future__ import print_function
import tensorflow
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Flatten, InputLayer, Reshape
from tensorflow.keras.layers import LSTM, TimeDistributed, Bidirectional, Conv1D, SimpleRNN, GRU, Conv2D
import os
```

Load data in a dataframe format

```
# Load data in a dataframe format
#path = "/content/drive/MyDrive/data/months/jan.xlsx - January.csv"

#Data = pd.read_csv(path, sep=",")

path_for_excel = "/content/drive/MyDrive/data/months/jan.xlsx"
Data = pd.read_excel(path_for_excel)

print(Data.head(10))
print(Data.keys())
# Column names of the data
# ['STEC', 'VTEC', 'A_(Daily)', 'Kp', 'ap', 'D', 'SML', 'SMU', 'fluxtime', 'fluxjulian', 'fluxcarrington', 'fluxobsflux', 'fluxadjflux', 'fluxursi', 'Daily_Total_Sunspot_Number', 'Daily_North_Sunspot_Number', 'Daily_South_Sunspot_Number', 'Standard_Deviation_of_Raw_Daily_Total_Sunspot_Data', 'Standard_Deviation_of_Raw_Daily_North_Sunspot_Data', 'Standard_Deviation_of_Raw_Daily_South_Sunspot_Data', 'Number_of_Observations_for_Daily_Total_Sunspot_Number', 'Number_of_Observations_for_Daily_North_Sunspot_Number']
```

```
pot_Number', 'Number_of_Observations_for_Daily_South_Sunspot_Number', 'Definitive/Provisional_Indicator', 'GOES-15_Proton_FluEncE', 'GOES-15_ElElectron_FluEncE', 'NEutron', 'Solar_Flares', 'Central_PA', 'Angular', 'Linear', '2nd-order_Speed_at_final_height', '2nd-order_Speed_at_20_Rs', 'Accel_*', 'Mass_*', 'Kinetic_Energy_*', 'MPA']  
Variables = Data.columns
```

```
InputDataFrame = Data[['kp', 'ap', 'D', 'SML', 'SMU', 'fluxtime', 'fluxjulian', 'fluxcarrington',  
    'fluxobsflux', 'fluxadjflux', 'fluxursi', 'dts']]
```

```
InputVariables = InputDataFrame.columns  
print(InputDataFrame.head(10))
```

```
OutputDataFrame = Data[['stec']]  
OutputVariables = OutputDataFrame.columns
```

DATA NORMALIZATION

FIRST STEP: FIND THE MAXIMUM VALUES PER VARIABLE

```
max_values = dict.fromkeys(InputVariables)  
for i in InputVariables:
```

```
    InputDataColumn = InputDataFrame[i]  
    max_values[i] = InputDataColumn.max()
```

SECOND STEP: CONVERT DATAFRAME TO NUMPY ARRAY

```
InputArray = InputDataFrame.to_numpy()  
OutputArray = OutputDataFrame.to_numpy()
```

THIRD STEP: CREATE THE NORMALIZED VERSION OF THE NUMPY ARRAY

```
InputArrayNormalized = np.empty([InputArray.shape[0], InputArray.shape[1]])  
OutputArrayNormalized = np.empty([OutputArray.shape[0], OutputArray.shape[1]])  
for i in range(0,12):  
    invar = InputVariables[i]  
    InputArrayNormalized[:,i] = InputArray[:,i]/max_values[invar]
```

```
OutputArrayNormalized[:] = OutputArray[:]/np.amax(OutputArray)
```

FOURTH STEP: CREATE THE 3D NUMPY ARRAY

```
IntermediateArrayNormalized = np.empty([(InputArray.shape[0]-7), 7])
Input3DArrayNormalized = np.empty([(InputArray.shape[0]-7), 7])
for i in range(0,12):
    invar = InputVariables[i]
    for j in range(0,(InputArray.shape[0]-7)):
        IntermediateArrayNormalized[j,:] = InputArrayNormalized[j:j+7,i]

    Input3DArrayNormalized =np.dstack((Input3DArrayNormalized, IntermediateArray
Normalized))

X = np.delete(Input3DArrayNormalized, 0, 2) # (411, 7, 14)

Output3DArrayNormalized = np.empty([(OutputArray.shape[0]-7), 7])
for j in range(0, (OutputArray.shape[0] - 7)):
    Output3DArrayNormalized[j, :] = np.transpose(OutputArrayNormalized[j:j + 7])
Y = Output3DArrayNormalized.reshape(Output3DArrayNormalized.shape[0], Output
3DArrayNormalized.shape[1], 1) # (411, 7, 1)
```

FIFTH STEP: RANDOMIZE-BLEND THE VALUES

```
randomize_idx = np.asarray(range(0,(len(X)-1)))
np.random.shuffle(randomize_idx)
train_index = randomize_idx[0:round(0.85*len(randomize_idx))]
test_index = randomize_idx[len(train_index):len(randomize_idx)]
print("TRAIN:", train_index, "TEST:", test_index)
X_train = X[train_index]
y_train = Y[train_index]
X_test = X[test_index]
y_test = Y[test_index]
```

SIXTH STEP: MODEL ARCHITECTURE

```
from datetime import date
import datetime
import matplotlib.pyplot as plt
from keras.utils.vis_utils import plot_model
```

Hyper - Parameters

```
hidden_units= 512 #64 128 256 512
conv_filters = 512 #64 128 256 512
epochs = 100
```


Simple RNN

```
in_sh=hidden_units
model_simpleRNN = Sequential()
model_simpleRNN.add(InputLayer(input_shape=(X.shape[1],X.shape[2])))
model_simpleRNN.add(Conv1D(conv_filters, 3, activation='relu')) # convolutional layer
#model_simpleRNN.add(Conv1D(conv_filters, 3, activation='relu')) # convolutional layer
model_simpleRNN.add((SimpleRNN(hidden_units, return_sequences=True)))
model_simpleRNN.add((SimpleRNN(X.shape[1], return_sequences=True)))
model_simpleRNN.add(Dropout(0.1))
model_simpleRNN.add(Reshape((X.shape[1], -1)))
model_simpleRNN.add(Dense(1, activation='tanh'))
model_simpleRNN.compile(loss='mean_absolute_error', optimizer='adam', metrics=['mean_absolute_error'])
print(model_simpleRNN.summary())

plot_model(model_simpleRNN, to_file='/content/drive/MyDrive/data/model_plot_RNN.png', show_shapes=True, show_layer_names=True)

#start1 = datetime.now()

# TRAIN THE MODEL
history = model_simpleRNN.fit(X_train, y_train, validation_split=0.1, epochs=epochs,
    shuffle=False, batch_size=12, verbose=1)
#histnew = pd.DataFrame(history.history)
#histnew['epoch'] = history.epoch
#histnew.tail()

#stop1 = datetime.now()
#Execution time of the model
#execution_time_RNN = stop1-start1
#print("RNN execution time is: ", execution_time_RNN)

mean_absolute_error = history.history['mean_absolute_error']
val_mean_absolute_error = history.history['val_mean_absolute_error']

loss = history.history['loss']
val_loss = history.history['val_loss']

number_of_epochs_it_ran = len(history.history['loss'])
epochs_range = range(number_of_epochs_it_ran)
```

```
plt.figure(figsize=(15, 15))
plt.subplot(1, 2, 1)
plt.plot(epochs_range, mean_absolute_error, label='Training MAE')
plt.plot(epochs_range, val_mean_absolute_error, label='Validation MAE')
plt.legend(loc='upper right')
plt.title('Training and Validation MAE')

plt.subplot(1, 2, 2)
plt.plot(epochs_range, loss, label='Training Loss')
plt.plot(epochs_range, val_loss, label='Validation Loss')
plt.legend(loc='upper right')
plt.title('Training and Validation Loss')
plt.show()

# PREDICT THE OUTPUT VALUES
yhat = model_simpleRNN.predict(X_test, verbose=0)
yhat = np.squeeze(yhat, axis=2)
yground = np.squeeze(y_test, axis=2)

yh = yhat[:,0]*np.amax(OutputArray)
yg = yground[:,0]*np.amax(OutputArray)

diff = np.absolute(yg - yh)
MAE_RNN = sum(abs(yh - yg)) / len(yg)
MIN = np.amin(diff)
MAX = np.amax(diff)
MSE_RNN = sum((yh - yg) ** 2)/(len(yg))
print("MSE on test set: {:.4f}".format(MSE_RNN))
print("MAE on test set: {:.4f}".format(MAE_RNN))

plt.xlabel('Ground Truth')
plt.ylabel('Predicted Labels')
plt.title('RNN')
plt.scatter(yg, yh)
plt.show()
```

LSTM

```
in_sh=hidden_units
model_LSTM = Sequential()
model_LSTM.add(InputLayer(input_shape=(X.shape[1],X.shape[2])))
model_LSTM.add(Conv1D(conv_filters, 3, activation='relu')) # convolutional layer
model_LSTM.add((LSTM(hidden_units, return_sequences=True)))
model_LSTM.add((LSTM(X.shape[1], return_sequences=True)))
```

```
model_LSTM.add(Dropout(0.1))
model_LSTM.add(Reshape((X.shape[1], -1)))
model_LSTM.add(Dense(1, activation='tanh'))
model_LSTM.compile(loss='mean_absolute_error', optimizer='adam', metrics=['mean_absolute_error'])
print(model_LSTM.summary())

plot_model(model_LSTM, to_file='/content/drive/MyDrive/data/model_plot_LSTM.png', show_shapes=True, show_layer_names=True)

#start1 = datetime.now()

# TRAIN THE MODEL
history = model_LSTM.fit(X_train, y_train, validation_split=0.1, epochs=epochs, shuffle=False, batch_size=12, verbose=1)
#histnew = pd.DataFrame(history.history)
#histnew['epoch'] = history.epoch
#histnew.tail()

#stop1 = datetime.now()
#Execution time of the model
#execution_time_RNN = stop1-start1
#print("RNN execution time is: ", execution_time_RNN)

mean_absolute_error = history.history['mean_absolute_error']
val_mean_absolute_error = history.history['val_mean_absolute_error']

loss = history.history['loss']
val_loss = history.history['val_loss']

number_of_epochs_it_ran = len(history.history['loss'])
epochs_range = range(number_of_epochs_it_ran)

plt.figure(figsize=(15, 15))
plt.subplot(1, 2, 1)
plt.plot(epochs_range, mean_absolute_error, label='Training MAE')
plt.plot(epochs_range, val_mean_absolute_error, label='Validation MAE')
plt.legend(loc='upper right')
plt.title('Training and Validation Accuracy')

plt.subplot(1, 2, 2)
plt.plot(epochs_range, loss, label='Training Loss')
plt.plot(epochs_range, val_loss, label='Validation Loss')
plt.legend(loc='upper right')
```

```
plt.title('Training and Validation Loss LSTM')
plt.show()

# PREDICT THE OUTPUT VALUES
yhat = model_LSTM.predict(X_test, verbose=0)
yhat = np.squeeze(yhat, axis=2)
yground = np.squeeze(y_test, axis=2)

yh = yhat[:,0]*np.amax(OutputArray)
yg = yground[:,0]*np.amax(OutputArray)

diff = np.absolute(yg - yh)
MAE_LSTM = sum(abs(yh - yg)) / len(yg)
MIN = np.amin(diff)
MAX = np.amax(diff)
MSE_LSTM = sum((yh - yg) ** 2)/(len(yg))
print("MSE on test set: {:.4f}".format(MSE_LSTM))
print("MAE on test set: {:.4f}".format(MAE_LSTM))

plt.xlabel('Ground Truth')
plt.ylabel('Predicted Labels')
plt.title('LSTM')
plt.scatter(yg, yh)
plt.show()
```

GRU

```
in_sh=hidden_units
model_GRU = Sequential()
model_GRU.add(InputLayer(input_shape=(X.shape[1],X.shape[2])))
model_GRU.add(Conv1D(conv_filters, 3, activation='relu')) # convolutional layer
model_GRU.add((GRU(hidden_units, return_sequences=True)))
model_GRU.add((GRU(X.shape[1], return_sequences=True)))
model_GRU.add(Dropout(0.1))
model_GRU.add(Reshape((X.shape[1], -1)))
model_GRU.add(Dense(1, activation='tanh'))
model_GRU.compile(loss='mean_absolute_error', optimizer='adam', metrics=['mean
_absolute_error'])
print(model_GRU.summary())

plot_model(model_GRU, to_file='/content/drive/MyDrive/data/model_plot_GRU.png', show_shapes=True, show_layer_names=True)

#start1 = datetime.now()
```

```
# TRAIN THE MODEL
history = model_GRU.fit(X_train, y_train, validation_split=0.1, epochs=epochs, shuffle=False, batch_size=12, verbose=1)
#histnew = pd.DataFrame(history.history)
#histnew['epoch'] = history.epoch
#histnew.tail()

#stop1 = datetime.now()
#Execution time of the model
#execution_time_RNN = stop1-start1
#print("RNN execution time is: ", execution_time_RNN)

mean_absolute_error = history.history['mean_absolute_error']
val_mean_absolute_error = history.history['val_mean_absolute_error']

loss = history.history['loss']
val_loss = history.history['val_loss']

number_of_epochs_it_ran = len(history.history['loss'])
epochs_range = range(number_of_epochs_it_ran)

plt.figure(figsize=(15, 15))
plt.subplot(1, 2, 1)
plt.plot(epochs_range, mean_absolute_error, label='Training MAE')
plt.plot(epochs_range, val_mean_absolute_error, label='Validation MAE')
plt.legend(loc='upper right')
plt.title('Training and Validation Accuracy GRU')

plt.subplot(1, 2, 2)
plt.plot(epochs_range, loss, label='Training Loss')
plt.plot(epochs_range, val_loss, label='Validation Loss')
plt.legend(loc='upper right')
plt.title('Training and Validation Loss LSTM')
plt.show()

# PREDICT THE OUTPUT VALUES
yhat = model_GRU.predict(X_test, verbose=0)
yhat = np.squeeze(yhat, axis=2)
yground = np.squeeze(y_test, axis=2)

yh = yhat[:,0]*np.amax(OutputArray)
yg = yground[:,0]*np.amax(OutputArray)
```

```
diff = np.absolute(yg - yh)
MAE_GRU = sum(abs(yh - yg)) / len(yg)
MIN = np.amin(diff)
MAX = np.amax(diff)
MSE_GRU = sum((yh - yg) ** 2)/(len(yg))
print("MSE on test set: {:.4f}".format(MSE_GRU))
print("MAE on test set: {:.4f}".format(MAE_GRU))
```

```
plt.xlabel('Ground Truth')
plt.ylabel('Predicted Labels')
plt.title('GRU')
plt.scatter(yg, yh)
plt.show()
```

TABLE OF COMPARISONS

```
plt.rcParams["figure.figsize"] = [5.00, 5.50]
plt.rcParams["figure.autolayout"] = True
fig, ax = plt.subplots(1,1)
data=[[MSE_RNN,MAE_RNN],
      [MSE_LSTM,MAE_LSTM],
      [MSE_GRU,MAE_GRU]]
column_labels=["MSE", "MAE"]
row=["RNN ", "LSTM", "GRU"]
df=pd.DataFrame(data,columns=column_labels)
df.update(df.applymap('{:,.4f}'.format))
ax.axis('tight')
ax.axis('off')
the_table = ax.table(cellText=df.values,colLabels=df.columns,rowLabels=row,fontsize
=15,loc="center",cellLoc='center')
the_table.auto_set_font_size(False)
the_table.set_fontsize(14)
plt.show()
```