

Μελέτη της επίδρασης διαφόρων παραμέτρων για την πρόβλεψη της ιονοσφαιρικής δραστηριότητας κάνοντας χρήση μοντέλων μηχανικής μάθησης και μετρήσεις GNSS

Σακελλαρίου Δημήτριος

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, 09 Μαρτίου 2022-

Τριμελής επιτροπή

Δουλάμης Νικόλαος
Αναπληρωτής Καθηγητής

Τσακίρη Μαρία
Καθηγήτρια

Δουλάμης Αναστάσιος
Αναπληρωτής Καθηγητής

Ευχαριστίες

Με την συγγραφή της παρούσας διπλωματικής εργασίας, ολοκληρώνεται ένας πενταετής κύκλος προπτυχιακών σπουδών στην Σχολή Αγρονόμων και Τοπογράφων Μηχανικών - Μηχανικών Γεωπληροφορικής του Εθνικού Μετσόβιου Πολυτεχνείου. Ο κύκλος αυτός, ήταν καθοριστικός για εμένα, γνώρισα και συνεργάστηκα με εξαιρετικούς καθηγητές και συμφοιτητές, ενώ δέχθηκα την στήριξη πολλών ατόμων τα οποία οφείλω να ευχαριστήσω.

Πρωτίστως, ένα μεγάλο ευχαριστώ αξίζει στον Αναπληρωτή Καθηγητή Δουλάμη Νικόλαο, για την εμπιστοσύνη του από την πρώτη στιγμή που ανέλαβα την παρούσα διπλωματική εργασία, την καθοδήγησή του και τις συμβουλές του για την συγγραφή της. Ένα μεγάλο ευχαριστώ θα πάει επίσης και στους συναδέλφους και συμφοιτητές Τσουμενή Εμμανουήλ και Σπανάκη Μάριο γιατί ήμασταν πάντα ο ένας για τον άλλο από την πρώτη ημέρα που παρουσιάστηκαμε στη ΓΥΣ μέχρι και την παρουσίαση των διπλωματικών μας εργασιών.

Ένα μεγάλο ευχαριστώ αφιερώνεται στην οικογένειά μου, σε φίλους και συγγενείς. Στη σύζυγο μου, Χρυσάνθη, και στα δύο μου παιδιά Αθανασία και Μιχαήλ, για την αδιάκοπη στήριξή τους, χάρη στους οποίους κατάφερα να ολοκληρώσω έναν πολυετή κύκλο σπουδών, αρχομένης από την επιτυχή φοίτηση στη Στρατιωτική Σχολή Ευελπίδων, τη Σχολή Πεζικού και τη Σχολή Τοπογραφίας της Γεωγραφικής Υπηρεσίας Στρατού και την αποφοίτησή μου από τη Σχολή Αγρονόμων και Τοπογράφων Μηχανικών – Μηχανικών Γεωπληροφορικής του Εθνικού Μετσόβιου Πολυτεχνείου.

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

Περίληψη

Η αναγκαιότητα πρόβλεψης της ιονοσφαιρικής δραστηριότητας αποτελεί μείζον θέμα για τις μετρήσεις προσδιορισμού θέσης. Η καθυστέρηση της ιονόσφαιρας είναι ανάλογη με το συνολικό αριθμό ηλεκτρονίων της ιονόσφαιρας (**TEC**) κατά μήκος της διαδρομής διάδοσης, και αντιστρόφως ανάλογη του τετραγώνου της συχνότητας f του φορέα (L1 ή L2). Οι τιμές TEC (Total Electron Content) είναι απαραίτητες για τη διόρθωση της διάθλασης της ιονόσφαιρας και είναι ζωτικής σημασίας για τα συστήματα δορυφορικής πλοήγησης, προκειμένου να διασφαλιστεί η υψηλή απόδοση των δορυφορικών συστημάτων στον εντοπισμό θέσης.

Με το παρόν, προτείνουμε μια προσέγγιση βασισμένη στη βαθιά μάθηση για μοντελοποίηση ιονόσφαιρας. Αυτή η μέθοδος εκμεταλλεύεται τα πλεονεκτήματα των επαναλαμβανόμενων νευρωνικών δικτύων μακροπρόθεσμης βραχυπρόθεσμης μνήμης (RNN-LSTM) για την πρόβλεψη των τιμών κατακόρυφης συνολικής περιεκτικότητας ηλεκτρονίων (VTEC) και λοξής (πλάγιας) συνολικής περιεκτικότητας ηλεκτρονίων (STEC), με δεδομένα εισόδου συνδυασμό γεωμαγνητικών και ηλιακών παραμέτρων επιρροής της ιονόσφαιρας. Ο σκοπός της προτεινόμενης μεθόδου είναι να συγκρίνει και να αξιολογήσει την εκτίμηση ιονοσφαιρικής καθυστέρησης με διαφορετικό κάθε φορά συνδυασμό δεδομένων εισόδου (παραμέτρους). Αυτό θα οδηγήσει στην κατανόηση και στην διαλογή των σημαντικότερων παραμέτρων (με το μεγαλύτερο βάρος) με σκοπό τον προσδιορισμό της ιονόσφαιρας.

Για τον προσδιορισμό της καλύτερης μεθοδολογίας χρησιμοποιήθηκαν οι συναρτήσεις απώλειας Μέσου Τετράγωνικού Σφάλματος (MSE) και Μέσου Απόλυτου Σφάλματος (MAE).

Λέξεις κλειδιά

Παγκόσμιο Δορυφορικό Σύστημα Πλοήγησης, ιονοσφαιρική καθυστέρηση, Επαναλαμβανόμενο Νευρωνικό Δίκτυο, Νευρώνες μακράς-βραχείας διάρκειας μνήμης, Συνολικός αριθμός ηλεκτρονίων ιονόσφαιρας.

Abstract

The need to predict ionospheric activity is a major issue for positioning measurements. The ionosphere delay is proportional to the number of ionosphere electrons (TEC) along the propagation path, and inversely proportional to the square of the carrier frequency f (L1 or L2). TEC values are necessary for the correction of ionosphere refraction and are vital for satellite navigation systems in order to ensure the high performance of satellite systems at the location.

We now propose an in-depth learning-based approach to ionosphere modeling. This method takes advantage of repetitive long-term short-term memory (RNN-LSTM) neural networks for predicting vertical total electron content (VTEC) and STEC values, with a combination of geomagnetic and solar erythrocytes. The purpose of the proposed method is to compare and evaluate the ionospheric delay estimation with a different combination of input data (parameters). This will lead to the understanding and sorting of the most important parameters (with the greatest weight) in order to determine the ionosphere.

The Squared Mean Error (MSE) and Absolute Mean (MAE) loss functions were used to determine the best methodology.

Keywords

GNSS, IONOSPHERIC DELAY, RNN, LSTM, TEC

Περιεχόμενα

Ευχαριστίες.....	1
Περίληψη.....	2
Λέξεις κλειδιά	2
Abstract	3
Keywords.....	3
Κατάλογος συντομογραφιών	8
Κατάλογος σχημάτων	9
Κατάλογος πινάκων	12
Κεφάλαιο 1 ^ο Εισαγωγή.....	13
1.1 Η σημασία της πρόβλεψης της ιονοσφαιρικής δραστηριότητας	13
1.2 Κύριες προκλήσεις.....	14
1.2.1 Η πρόκληση της μοντελοποίησης TEC με χρήση δεδομένων GNSS.....	15
1.3 Συνεισφορά	16
1.4 Δομή εργασίας.....	17
Κεφάλαιο 2 ^ο Βιβλιογραφική ανασκόπηση	18
2.1 Διαστημικά Καιρικά Φαινόμενα.....	18
2.2 Νευρώνες μακράς-βραχείας διάρκειας μνήμης (Long Short-Term Memory - LSTM)	19
2.3 Principal component analysis (PCA).....	19
2.4 OKSM.....	21
2.5 Τεχνικές Μοντελοποίησης DIAS	22
2.6 Τεχνική Support Vector Machine (SVM).....	23
Κεφάλαιο 3 ^ο Σύστημα GNSS και Ατμόσφαιρα.....	24
3.1 Βασικές αρχές συστήματος GNSS	24
3.2 Η ατμόσφαιρα της Γης.....	25
3.2.1 Εισαγωγικές Έννοιες	25
3.2.2 Τα στρώματα της ατμόσφαιρας	25
3.3 Η Ιονόσφαιρα και τα στρώματά της	28
3.3.1 Εισαγωγικές Έννοιες	28
3.3.2 Τα στρώματα της ιονόσφαιρας και τα χαρακτηριστικά τους	28
3.4 Οι τιμές TEC (Total Electron Content).....	31
3.4.1 Εισαγωγικές έννοιες	31
3.4.2 Βασικές αρχές.....	32
3.5 Παράμετροι επιρροής τιμών Tec.....	34

3.5.1 Εισαγωγικές έννοιες	34
3.5.2 Μαγνητική κ Ιονοσφαιρική Καταιγίδα	36
3.5.3 Ηλιακές Εκλάμψεις (Solar Flares).....	37
3.5.4 Coronal mass ejection.....	38
3.5.5 Solar Radio Flux	39
3.5.6 Sunspot Number	40
3.5.7 Ενεργητικές ροές ηλεκτρονίων (Energetic electrons fluxes)	41
3.5.8 Γεωμαγνητικοί δείκτες K	42
3.5.9 Disturbance storm time (Dst)	42
3.5.10 Disturbance storm time (Dst)	43
Κεφάλαιο 4ο Βασικές έννοιες Τεχνητής Νοημοσύνης	44
4.1 Μηχανική μάθηση (Machine Learning)	44
4.2 Πρόβλεψη και Νευρωνικά δίκτυα (Neural Networks).....	46
4.2.1 Συνάρτηση Απώλειας (Loss Function).....	47
4.2.2 Συναρτήσεις Ενεργοποίησης	49
4.3 Βαθιά μάθηση (Deep Learning).....	49
4.4 Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural networks).....	50
4.5 Νευρώνες μακράς-βραχείας διάρκειας μνήμης (Long Short-Term Memory - LSTM) 51	
Κεφάλαιο 5ο Η γλώσσα προγραμματισμού Python.....	53
5.1 Γενικά για την γλώσσα προγραμματισμού Python.....	53
5.2 Η συμβολή της γλώσσας Python στην ανάπτυξη του δικτύου: Google Colaboratory	54
5.3 Σημαντικές βιβλιοθήκες Python που χρησιμοποιήθηκαν	54
5.4 Υλοποίηση σε Python	56
5.4.1 Εκπαίδευση δικτύου	56
5.4.2 Έλεγχος δικτύου	63
5.4.3 Οπτικοποίηση αποτελεσμάτων.....	63
Κεφάλαιο 6ο Πειραματική διαχείριση – Περιγραφή και επεξεργασία αρχικών δεδομένων	65
6.1 Εισαγωγικές έννοιες	65
6.2 Περιγραφή των δεδομένων.....	65
6.2.1 Observation Files του σταθμού COTE00ATA.....	65
6.2.2 Παράμετροι επιρροής τιμών Tec	71
6.3 Επεξεργασία των δεδομένων	78
Κεφάλαιο 7ο Χρήση παραμέτρων δεδομένων TEC – Σενάρια και αξιολόγηση αυτών.....	80
7.1 Μετρητικοί δείκτες αξιολόγησης αποτελεσμάτων.....	81

7.1.1 Mean Square error (MSE) - Mean Absolute error (MAE).....	81
7.1.2 Ακρίβεια (Accuracy) – Σφάλμα (loss) στο σετ δεδομένων.....	83
7.2 Σενάριο 1 ^ο (για τον μήνα Ιανουάριου 2018).....	85
7.2.1 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου STEC.....	85
7.2.2 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου VTEC.....	93
7.3 Σενάριο 2 ^ο (για τον μήνα Ιανουάριου 2018).....	100
7.3.1 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου STEC.....	100
7.3.2 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου VTEC.....	107
7.4 Σενάριο 3 ^ο (για τον μήνα Ιανουάριου 2018).....	115
7.4.1 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου STEC.....	115
7.4.2 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου VTEC.....	122
7.5 Σενάριο 4 ^ο (για τον μήνα Ιανουάριου 2018).....	130
7.5.1 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου STEC.....	130
7.5.2 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου VTEC.....	137
7.6 Σενάριο 5 ^ο (για τον μήνα Ιανουάριου 2018).....	144
7.7 Σενάριο 6 ^ο (για τον μήνα Ιανουάριου 2018).....	145
7.8 Σενάριο 7 ^ο (για τον μήνα Ιανουάριου 2018).....	146
7.9 Συγκρίσεις πειραματικών δεδομένων – Σεναρίων.....	146
Κεφάλαιο 8 ^ο Συμπεράσματα.....	148
Αναφορές.....	149
Παράρτημα Α.....	154
Πίνακας δεδομένων ανά μήνα.....	154
Παράρτημα Β.....	155
Αποτελέσματα Σεναρίου Νο 1,2,3,4 για τους μήνες Φεβρουάριο και Μάρτιο 2018.....	155
STEC ΦΕΒΡΟΥΑΡΙΟΥ.....	155
VTEC ΦΕΒΡΟΥΑΡΙΟΥ.....	161
STEC ΜΑΡΤΙΟΥ.....	167
VTEC ΜΑΡΤΙΟΥ.....	173
Αποτελέσματα Σεναρίου Νο 5 για τους μήνες Ιανουάριο, Φεβρουάριο και Μάρτιο 2018.....	177

STEC ΙΑΝΟΥΑΡΙΟΥ.....	177
VTEC ΙΑΝΟΥΑΡΙΟΥ.....	183
STEC ΦΕΒΡΟΥΑΡΙΟΥ.....	188
VTEC ΦΕΒΡΟΥΑΡΙΟΥ.....	194
STEC ΜΑΡΤΙΟΥ.....	200
VTEC ΜΑΡΤΙΟΥ.....	206
Αποτελέσματα Σεναρίου Νο 6 για τους μήνες Ιανουάριο, Φεβρουάριο και Μάρτιο 2018	212
STEC ΙΑΝΟΥΑΡΙΟΥ.....	212
VTEC ΙΑΝΟΥΑΡΙΟΥ.....	218
STEC ΦΕΒΡΟΥΑΡΙΟΥ.....	224
VTEC ΦΕΒΡΟΥΑΡΙΟΥ.....	230
STEC ΜΑΡΤΙΟΥ.....	236
VTEC ΜΑΡΤΙΟΥ.....	242
Αποτελέσματα Σεναρίου Νο 7 για τους μήνες Φεβρουάριο και Μάρτιο 2018.....	248
STEC ΙΑΝΟΥΑΡΙΟΥ.....	248
VTEC ΙΑΝΟΥΑΡΙΟΥ.....	254
STEC ΦΕΒΡΟΥΑΡΙΟΥ.....	260
VTEC ΦΕΒΡΟΥΑΡΙΟΥ.....	266
STEC ΜΑΡΤΙΟΥ.....	272
VTEC ΜΑΡΤΙΟΥ.....	279
Παράρτημα Γ.....	289
ΚΩΔΙΚΑΣ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ RNN & LSTM.....	289
STEC.....	289
VTEC.....	296

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

Κατάλογος εικόνων

Εικόνα 1. Μοντέλο PCA	20
Εικόνα 2. Μοντέλο OKSM.....	22
Εικόνα 3. Τεχνική SVM.....	23
Εικόνα 4. Τα στρώματα της ατμόσφαιρας	26
Εικόνα 5. Τα στρώματα της ιονόσφαιρας.....	31
Εικόνα 6. Έκρηξη CME στις 31 Αυγούστου 2012 (Πηγή: NASA Goddard Space Flight Center)	39
Εικόνα 7. 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)	41
Εικόνα 8. Τεχνητή νοημοσύνη και τα υποσύνολά της.	44
Εικόνα 9. Συνάρτηση απώλειας Mean Absolute Error (MAE)	47
Εικόνα 10. Συνάρτηση απώλειας Mean Square Error (MSE).....	48
Εικόνα 11. Αναπαράσταση δικτύων αναδρομικών νευρωνικών δικτύων	50
Εικόνα 12. Μνήμη κελιού ενός LSTM δικτύου.....	52
Εικόνα 13. Σταθμός COTE00ATA (Πηγή: IGS)	65
Εικόνα 14. Όλοι οι διαθέσιμοι σταθμοί του συστήματος GNSS (Πηγή: IGS)	66
Εικόνα 15. Τυπική μορφή αρχείου RINEX.	66
Εικόνα 16. Συμπεριφορά των τιμών TEC ανά ώρα με βάση το γεωγραφικό πλάτος	69
Εικόνα 17. Τιμές TEC ανά Δορυφόρο.....	70
Εικόνα 18. Η διακύμανση της τιμής TEC την 01 Ιανουαρίου 2018, ανά Δ/Φ (PRN 01, 02 κλπ) σε κάποιο εύρος υψομέτρων.	70
Εικόνα 19. Υπόδειγμα δεδομένων γεωμαγνητικής δραστηριότητας (K).....	72
Εικόνα 20. 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)	72
Εικόνα 21. Υπόδειγμα δεδομένων SME	73
Εικόνα 22. Υπόδειγμα δεδομένων Dst.....	74
Εικόνα 23. Υπόδειγμα δεδομένων Solar Radio Flux	75
Εικόνα 24. Υπόδειγμα δεδομένων Sunspot Number	76
Εικόνα 25. Βασιλικό Αστεροσκοπείο Βελγίου (Πηγή: www.bis.sidc.be).....	76
Εικόνα 26. Υπόδειγμα δεδομένων Energetic Particle Flux.	77
Εικόνα 27. Υπόδειγμα δεδομένων Solar Flares.	77
Εικόνα 28. Υπόδειγμα δεδομένων Coronal Mass Ejections.....	78
Εικόνα 29. Ικανοποιητικός προσδιορισμός μοντέλου, μέσω των μετρητικών σχέσεων MSE-MAE	82
Εικόνα 30. Γραμμική παλινδρόμηση	82
Εικόνα 31. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης	83
Εικόνα 32. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης	86
Εικόνα 33. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)	86
Εικόνα 34. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης	87
Εικόνα 35. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)	88
Εικόνα 36. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης	88
Εικόνα 37. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)	89

Εικόνα 132. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)	142
Εικόνα 133. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης	143
Εικόνα 134. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)	143
Εικόνα 135. Προσδιορισμός μοντέλου, μέσω των μετρητικών σχέσεων MSE-MAE	144

Κατάλογος πινάκων

Πίνακας 1. Παράμετροι επιρροής της ιονόσφαιρας.....	34
Πίνακας 2. Excel με τα δεδομένα των παραμέτρων που χρησιμοποιήθηκαν	71
Πίνακας 3. Σενάρια για επιλογή καταλληλότερων παραμέτρων	80
Πίνακας 4. Πρώτο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας	85
Πίνακας 5. Δεύτερο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας	100
Πίνακας 6. Τρίτο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας.....	115
Πίνακας 7. Τέταρτο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας	130
Πίνακας 8. Πέμπτο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας	145
Πίνακας 9. Έκτο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας	145
Πίνακας 10. Έβδομο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας	146

Κεφάλαιο 1^ο Εισαγωγή

1.1 Η σημασία της πρόβλεψης της ιονοσφαιρικής δραστηριότητας

Η μελέτη της επίδρασης διαφόρων παραμέτρων για την πρόβλεψη της ιονοσφαιρικής δραστηριότητας, αποτελεί μια διαδικασία συλλογής δεδομένων, που είναι απαραίτητη για πληθώρα εργασιών και μελετών. Το δορυφορικό σήμα GPS, καθώς διαδίδεται στην ατμόσφαιρα μέχρι τη γήινη επιφάνεια συνεχώς διαθλάται λόγω της μεταβολής του δείκτη διάθλασης της ατμόσφαιρας. Ειδικότερα το σήμα GPS, που είναι διαμορφωμένο κύμα και μεταφέρει πληροφορία, κατά τη διάδοσή του στην ιονόσφαιρα (τμήμα της ατμόσφαιρας από περίπου 50 έως 1000χλμ. ύψος από τη γήινη επιφάνεια με έντονη παρουσία ελεύθερων ηλεκτρονίων και ιόντων) εξαρτάται σημαντικά και από τις συχνότητες των συνιστωσών κυμάτων που το απαρτίζουν.

Τα σφάλματα που σχετίζονται με τη διάδοση του σήματος, όπως είναι τα ατμοσφαιρικά σφάλματα (στα οποία συμπεριλαμβάνεται και το ιονοσφαιρικό σφάλμα), αποτελούν τυχαία σφάλματα (random errors) που προφανώς είναι αναπόφευκτα κατά την εκτέλεση των μετρήσεων, και ονομάζονται και ως θόρυβος (noise, white noise). Η καθυστέρηση της ιονόσφαιρας είναι ανάλογη με το συνολικό αριθμό ηλεκτρονίων της ιονόσφαιρας (**TEC**) κατά μήκος της διαδρομής διάδοσης, και αντιστρόφως ανάλογη του τετραγώνου της συχνότητας f του φορέα (L1 ή L2) . Οι τιμές TEC είναι απαραίτητες για τη διόρθωση της διάθλασης της ιονόσφαιρας και είναι ζωτικής σημασίας για τη δορυφορική πλοήγηση συστημάτων, προκειμένου να διασφαλιστεί η υψηλή απόδοση των δορυφορικών συστημάτων στον εντοπισμό θέσης [1]

Η ιονόσφαιρα είναι το τμήμα της ατμόσφαιρας που επεκτείνεται από περίπου 50 έως 1000 χλμ. πάνω από τη γήινη επιφάνεια και χαρακτηρίζεται από την ύπαρξη ιονιζόντων αερίων (O_2 , H_2 , He , N_2) κυρίως ελεύθερων ηλεκτρονίων και θετικών ιόντων. Η ιονόσφαιρα αποτελεί μέσο διασποράς για το σήμα GPS, δλδ. ο δείκτης διάθλασης εξαρτάται από τη συχνότητα του σήματος και το γεγονός αυτό είναι πολύ βολικό για παρατηρήσεις GPS και στις δύο συχνότητες πχ. L1 και L2, L1 και L5. Αυτός είναι και ο βασικός σκοπός δύο τουλάχιστον συχνοτήτων L στο σήμα GPS. Με δέκτες διπλής συχνότητας το ιονοσφαιρικό σφάλμα μπορεί ουσιαστικά να απαλείφει αν χρησιμοποιήσουμε έναν κατάλληλο γραμμικό συνδυασμό πρωτογενών παρατηρήσεων των δύο φορέων, είτε ψευδοαποστάσεων από κώδικες είτε φάσεων. [2]

Περιβαλλοντικές, τοπογραφικές και γεωαδαιτικές μελέτες [3], [4], [5], [6] όλες καλούνται να απαντήσουν στην εξής απορία: Ποιος είναι ο βέλτιστος συνδυασμών παραμέτρων επιρροής της ιονοσφαιρικής δραστηριότητας, που θα οδηγήσει στην ελαχιστοποίηση του ιονοσφαιρικού σφάλματος;

Οι παραπάνω μελέτες όσο αφορά την συλλογή δεδομένων έχουν μια ειδοποιό διαφορά, τον τρόπο εύρεσης του συνδυασμού των παραμέτρων που αποσκοπεί στην ελαχιστοποίηση του ιονοσφαιρικού σφάλματος. Γενικότερα, , για τη διόρθωση της ιονόσφαιρικής καθυστέρησης χρησιμοποιούνται μοντέλα καθυστέρησης εκπομπής ιονόσφαιρας που βασίζονται σε απλά εμπειρικά μοντέλα TEC όπως τα μοντέλα Klobuchar (1987) και NeQuick (Hochebger et al. 2000, Radicella and Leitinger 2001). Καθώς όμως, ο χρόνος ανταπόκρισης και διάσωσης είναι πολύ σημαντικός, είναι αναγκαίο να υπάρξει και άλλη προσέγγιση, κατά την οποία κάνοντας χρήση μοντέλων μηχανικής μάθησης και μετρήσεων GNSS να γίνεται αυτόματα η εύρεση του βέλτιστου συνδυασμού παραμέτρων για την ελαχιστοποίηση του ιονοσφαιρικού σφάλματος.

1.2 Κύριες προκλήσεις

Τα νευρωνικά δίκτυα βαθιάς μάθησης (Deep Learning Neural Networks) μαθαίνουν πολύπλοκες αντιστοιχίσεις μεταξύ δεδομένων εισόδου και εξόδου και υποστηρίζουν πολλαπλές εισόδους και εξόδους. Έχουν αποδειχθεί αποτελεσματική λύση δεδομένης της ικανότητάς τους να αυτοματοποιούνται [7] Ωστόσο, επιλέγοντας το πιο βολικό τύπο νευρωνικού δικτύου βαθιάς μάθησης και η παραμετροποίηση του, είναι ένα σύνθετο έργο που απαιτεί σημαντικό εξειδίκευση.

Ως εκ τούτου, υπάρχει ανάγκη για βαθύτερες μελέτες σχετικά με την καταλληλότητα όλων των υφιστάμενων αρχιτεκτονικών για διαφορετικές εργασίες για την εκπαίδευση ενός νευρωνικού δικτύου. Πρακτικές πτυχές όπως ο καθορισμός των αξιών για υπερπαραμέτρους και την επιλογή των καταλληλότερων πλαισίων, για την επιτυχή εφαρμογή παρέχονται. Δεδομένης της πολυπλοκότητάς της, η εκπαίδευση ενός νευρωνικού δικτύου είναι ένας τομέας υψίστης σημασίας σε διάφορες ερευνητικά πεδία. Τα νευρωνικά δίκτυα πρέπει να λαμβάνουν υπόψη πολλά ζητήματα, όπως τάσεις και εποχιακές διακυμάνσεις της σειράς, η συσχέτιση μεταξύ των παρατηρούμενων τιμών που είναι κοντά στο χρόνο ως καθώς και η εξάρτησή τους από διάφορες εξωτερικές παραμέτρους. Στην παρούσα διπλωματική εργασία προτείνονται μέθοδοι για την αντιμετώπιση των προαναφερθέντων πτυχών συζητούνται.

Στην παρούσα διπλωματική εργασία παρέχεται μια συγκριτική ανάλυση που αξιολογεί την απόδοση αρκετών αρχιτεκτονικές βαθιάς μάθησης [8] σε μεγάλο αριθμό συνόλων δεδομένων.

Το κύριο ερευνητικό πεδίο που συζητάται εδώ είναι 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.

1.2.1 Η πρόκληση της μοντελοποίησης TEC με χρήση δεδομένων GNSS

Η μεταβλητότητα των ιονοσφαιρικών παραμέτρων περιορίζει την αποτελεσματικότητα των επικοινωνιών, των ραντάρ και συστήματα πλοήγησης. Ο όρος TEC, που ορίζεται ως το ολοκλήρωμα της πυκνότητας ηλεκτρονίων σε μια διαδρομή σήματος, χρησιμοποιείται συχνά για να περιγράψει τη μεταβλητότητα της ιονόσφαιρας [9], [10]. Οι τιμές TEC είναι απαραίτητες για τη διόρθωση της διάθλασης της ιονόσφαιρας [11] και είναι ζωτικής σημασίας για τα συστήματα δορυφορικής πλοήγησης, προκειμένου να διασφαλιστεί η υψηλή απόδοση των δορυφορικών συστημάτων στον εντοπισμό θέσης.

Τα μεταδιδόμενα σήματα από τα Global Navigation Satellite Systems (GNSS) επηρεάζονται άμεσα από τις ιονοσφαιρικές διακυμάνσεις, προκαλώντας καθυστερήσεις [12]. Αυτές οι καθυστερήσεις εξαρτώνται από τη συχνότητα του σήματος και την πυκνότητα ηλεκτρονίων κατά μήκος της διαδρομής μετάδοσης. Ως εκ τούτου, εισάγεται η ιονοσφαιρική μεταβλητότητα, μια πρόσθετη πηγή σφάλματος στην τοποθέτηση GNSS [13]. Η χρήση πολλαπλών σημάτων πλοήγησης της διακριτής κεντρικής συχνότητας που μεταδίδεται από τον ίδιο δορυφόρο GNSS, επιτρέπει την άμεση εκτίμηση αυτών των ιονοσφαιρικών καθυστερήσεων. Αξιοποιώντας το γεγονός ότι διαφορετικές συχνότητες σήματος επηρεάζονται διαφορετικά από την ιονόσφαιρα, μια κατάλληλη στρατηγική επεξεργασίας σημάτων GNSS πολλαπλών συχνοτήτων, εξαλείφει το ιονοσφαιρικό σφάλμα [13].

Σε αντίθεση με τους δέκτες GNSS πολλαπλών συχνοτήτων, σε πραγματικό χρόνο (RT) μονής συχνότητας, ο εντοπισμός με χαμηλού-κόστους δέκτη, μονής συχνότητας (SF), έχει λάβει αυξανόμενη προσοχή τα τελευταία χρόνια λόγω του μεγάλο αριθμού πιθανών εφαρμογών του. Ωστόσο, σε αυτή την περίπτωση, μια σημαντική πρόκληση είναι ο αποτελεσματικός μετριασμός αυτών των ιονοσφαιρικών καθυστερήσεων [14]. Οι τεχνικές RT-SF-SPP (Standard Point Positioning)/PPP (Precise Point Positioning) χρησιμοποιούν προϊόντα ιονόσφαιρας STEC και VTEC που απελευθερώνονται από την υπηρεσία διεθνούς υπηρεσίας GNSS (IGS) σε πραγματικό χρόνο [15], για την εξάλειψη του ιονοσφαιρικού σφάλματος και την εφαρμογή διορθώσεων στο μοντέλο ως εξωτερικές παραμέτρους.

Το Κέντρο Προσδιορισμού Τροχιών στην Ευρώπη (CODE) παρέχει Παγκόσμιους Ιονοσφαιρικούς Χάρτες (GIM) σε ένα κάρναβο (2,5°×5,0°), σε χρονική διάρκεια 2 ωρών ανάλυση, οδηγώντας σε ένα χωροχρονικό αραιό μοντέλο. Αυτό σημαίνει ότι οι διορθώσεις που εφαρμόστηκαν, βελτίωσαν την ακρίβεια της παρεχόμενης λύσης για την τοποθέτηση. Ωστόσο, οι τιμές STEC και VTEC αποτυγχάνουν να αφαιρέσουν τη συνολική ποσότητα θορύβου που προκαλείται από την ιονόσφαιρα, λόγω της συνολικής τους κάλυψης και την αδυναμίας τους να προσαρμοστούν με ακρίβεια σε περιφερειακό (και περισσότερο σε τοπικό) επίπεδο.

Ο στόχος αυτής της διπλωματικής εργασίας είναι να προσδιορίσει όσο το δυνατόν καλύτερα το ιονοσφαιρικό μοντέλο, μέσω της εύρεσης του κατάλληλου συνδυασμού των παραμέτρων επιρροής των τιμών TEC.

Ειδικότερα, οι κύριες προκλήσεις που πηγάζουν από το στόχο της παρούσας διπλωματικής εργασίας είναι :

- Η βελτίωση της ακρίβειας των υφιστάμενων περιφερειακών μοντέλων TEC και η διερεύνηση της απόκρισης του μοντέλου σε περιπτώσεις υψηλής δραστηριότητας ιονόσφαιρας και σε ακανόνιστες συνθήκες.
- Η διερεύνηση της σημασίας των διαφόρων εξωτερικών παραμέτρων (π.χ. ηλιακή και γεωμαγνητική δραστηριότητα) και η εύρεση του βέλτιστου συνδυασμού αυτών, για τη βελτίωση της ακρίβειας στη μοντελοποίηση TEC.
- Η εισαγωγή αξιόπιστων δεδομένων περιφερειακής παρατήρησης για τον χαρακτηρισμό περιφερειακών ανωμαλιών που επηρεάζουν την ιονόσφαιρα σε τοπικό επίπεδο (χωρική), και επιπλέον για την εκτίμηση των αλλαγών TEC, που στοχεύουν σε χωροχρονικά μοντέλα πρόβλεψης STEC και VTEC

1.3 Συνεισφορά

Η συνολική συμβολή της παρούσας διπλωματικής εργασίας έγκειται στους ακόλουθους στόχους που καθορίστηκαν:

- να προτείνει ένα μοντέλο βασισμένο σε LSTM, για ακριβείς εκτιμήσεις TEC από δεδομένα GNSS, και για την υπέρβαση προβλημάτων που σχετίζονται με την ακανόνιστη συμπεριφορά της ιονόσφαιρας σε περιφερειακό επίπεδο
- να προτείνει ισχυρά μοντέλα βαθιάς μάθησης που εκμεταλλεύονται διάφορες εξωτερικές παραμέτρους (π.χ. σχετικές ηλιακή και γεωμαγνητική δραστηριότητα) για τη βελτίωση της πρόβλεψης και της ακρίβειας στη μοντελοποίηση TEC
- να προτείνει χρονικά μοντέλα RNN, που θα εφαρμοστούν για ανάλυση TEC δεδομένων και σύγκριση της απόδοσής τους
- να παρουσιάσει μια ολοκληρωμένη ανάλυση για διάφορους μήνες, υπό διαφορετική ηλιακή και γεωμαγνητική δραστηριότητα. Τα μοντέλα ελέγχονται για διαφορετικές ημέρες για να ελεγχθεί η ανταπόκριση του μοντέλου σε περιπτώσεις υψηλής δραστηριότητας ιονόσφαιρας

1.4 Δομή εργασίας

Στα πλαίσια της παρούσας διπλωματικής εργασίας θα μελετήσουμε την επίδραση διαφόρων παραμέτρων, ώστε να προβλεφθεί η ιονοσφαιρική δραστηριότητα, κάνοντας χρήση μοντέλων μηχανικής μάθησης και μετρήσεων GNSS.. Στην ουσία μέσω της εκπαίδευσης ενός νευρωνικού δικτύου, θα μπορεί να προβλεφθεί το ιονοσφαιρικό σφάλμα, και αυτό θα έχει ως αποτέλεσμα την χρήση δέκτη μίας μόνο συχνότητας στις παρατηρήσεις GPS. Η μηχανική τους περιγραφή (μοντελοποίηση), αν και ικανοποιητική στις περισσότερες περιπτώσεις, έχει ως αποτέλεσμα την αύξηση των αγνώστων παραμέτρων στα μοντέλα συνόρθωσης και τη μείωση της ισχύος της λύσης.

Στο επόμενο κεφάλαιο θα γίνει μια βιβλιογραφική ανασκόπηση σε έρευνες που έχουν αντιμετωπίσει το πρόβλημα της πρόβλεψης του ιονοσφαιρικού σφάλματος και των τεχνικών που χρησιμοποιήσαν για να επιτευχθεί αυτό.

Στο τρίτο κεφάλαιο αναφέρονται κάποια γενικά στοιχεία για τα συστήματα GNSS, την ατμόσφαιρα της Γης και γίνεται ειδική αναφορά στις παραμέτρους που επηρεάζουν την ιονόσφαιρα.

Στο τέταρτο κεφάλαιο, γίνεται αναφορά σε βασικές έννοιες για την κατανόηση των όρων της τεχνητής νοημοσύνης, για την καλύτερη παρακολούθηση της ροής εργασίας.

Στο πέμπτο κεφάλαιο, παρουσιάζεται η γλώσσα προγραμματισμού Python στην οποία έγιναν όλα τα πειράματα, ενώ παράλληλα γίνεται αναφορά στις βιβλιοθήκες που χρησιμοποιήθηκαν και στην υλοποίηση του αλγορίθμου.

Στο έκτο κεφάλαιο περιγράφεται η πειραματική διαχείριση και αφορά την περιγραφή των δεδομένων GNSS που συλλέχθηκαν, ο τρόπος διαχείρισης τους και γίνεται αναφορά στα σενάρια συνδυασμού των παραμέτρων που χρησιμοποιήθηκαν ως δεδομένα εισόδου στο νευρωνικό δίκτυο.

Στο έβδομο κεφάλαιο γίνεται αναλυτική αναφορά στα σενάρια που εκτελέστηκαν και στην επιλογή του βέλτιστου σεναρίου καθώς και της πιο σημαντικής παραμέτρου επιρροής τιμών TEC.

Τέλος, στο όγδοο κεφάλαιο παρατίθενται τα συμπεράσματα που προκύπτουν από όλη την προηγούμενη ανάλυση και επεξεργασία, ενώ αναγράφονται και κάποιες μελλοντικές κατευθύνσεις όσον αφορά τον συνδυασμό της μηχανικής μάθησης και της παρακολούθησης των τυχαίων σφαλμάτων που επηρεάζουν τον προσδιορισμό της θέσης (και του χρόνου κατά περίπτωση) με παρατηρήσεις GPS.

Κεφάλαιο 2^ο Βιβλιογραφική ανασκόπηση

Στο συγκεκριμένο κεφάλαιο, γίνεται βιβλιογραφική ανασκόπηση σε εργασίες που έχουν αντιμετωπίσει με διάφορους τρόπους το πρόβλημα της πρόβλεψης τη ιονοσφαιρικής δραστηριότητας. Έχοντας ως βάση τις δυσκολίες σύμφωνα με τους τύπους δεδομένων για την υλοποίηση μιας τέτοιας διαδικασίας από το προηγούμενο κεφάλαιο, αλλά και τη σημασία αυτής της, αξίζει να μελετηθεί η μεθοδολογία αντιμετώπισής του και από άλλους ερευνητές. Οι εργασίες ταξινομούνται σύμφωνα με τον τύπο δεδομένων που χρησιμοποιήθηκαν με σκοπό την προσέγγιση στη λύση του προβλήματος.

2.1 Διαστημικά Καιρικά Φαινόμενα

Σύμφωνα με το [16], επισημαίνεται ότι τα διαστημικά καιρικά φαινόμενα μπορούν να προκαλέσουν σοβαρές διαταραχές της ιονοσφαιρικής συμπεριφοράς.

Εξετάζεται λοιπόν η τρέχουσα κατάσταση της ανίχνευσης, παρακολούθησης και πρόβλεψης ιονοσφαιρικών διαταραχών στην Ευρώπη με βάση το GNSS σε σχέση με τη δράση COST ES0803 «Ανάπτυξη προϊόντων και υπηρεσιών διαστημικού καιρού στην Ευρώπη».

Η έρευνα του διαστημικού καιρού και οι σχετικές μελέτες ιονόσφαιρας απαιτούν ευρεία διεθνή συνεργασία για την κοινή χρήση βάσεων δεδομένων, την ανάπτυξη λογισμικού και μοντέλων ανάλυσης και την παροχή υπηρεσιών. Γι αυτό το λόγο, αναθεωρήθηκε η ευρωπαϊκή βάση δεδομένων GNSS, συμπεριλαμβανομένων των υπηρεσιών ιονόσφαιρας που παρέχουν παράγωγα προϊόντα δεδομένων, όπως το συνολικό περιεχόμενο ηλεκτρονίων (TEC) και οι δείκτες ραδιοσπινθηρισμού. Τα θεμελιώδη φαινόμενα ιονοσφαιρικής διαταραχής που καλύπτουν αρκετά διαφορετικές κλίμακες σε χρόνο και χώρο, εξετάστηκαν υπό το πρίσμα των πρόσφατων επιτευγμάτων στην ιονοσφαιρική παρακολούθηση που βασίζεται στο GNSS. Έτσι, λαμβάνονται υπόψη διεργασίες διαταραχής μεγάλης κλίμακας που χαρακτηρίζονται από κινούμενα μέτωπα ιονισμού, ιοντίζουσες ιονόσφαιρες που μοιάζουν με κύμα και τέλος μικρής κλίμακας ανωμαλίες που προκαλούν ραδιοσπινθηρισμούς.

Ενώ οι επίγειες και διαστημικές τεχνικές παρακολούθησης GNSS είναι καλά ανεπτυγμένες, η πρόβλεψη ιονόσφαιρων διαταραχών χρειάζεται πολύ περισσότερη δουλειά για να γίνει ελκυστική για χρήστες που μπορεί να ενδιαφέρονται για συμπυκνωμένες πληροφορίες σχετικά με το βαθμό διαταραχής της ιονόσφαιρας από ισχυρούς δείκτες.

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

Σε αυτή τη μελέτη [17], όπως και η συγκεκριμένη διπλωματική εργασία, το νευρωνικό δίκτυο μακράς βραχυπρόθεσμης μνήμης (LSTM) (NN) εφαρμόζεται για την πρόβλεψη των 256 σφαιρικών αρμονικών (SH) συντελεστών που χρησιμοποιούνται παραδοσιακά για την κατασκευή παγκόσμιων ιονοσφαιρικών χαρτών (GIM). Πολλαπλά δεδομένα εισόδου, συμπεριλαμβανομένων των ιστορικών χρονοσειρών των συντελεστών SH, της ηλιακής ακραίας υπεριώδους ροής (EUV), του δείκτη χρόνου καταιγίδας διαταραχής (Dst) και της ώρας της ημέρας, χρησιμοποιούνται στο αναπτυγμένο μοντέλο LSTM NN. Διαφορετικοί συνδυασμοί των παραπάνω παραμέτρων έχουν χρησιμοποιηθεί για την κατασκευή του μοντέλου LSTM NN και βρέθηκε ότι το μοντέλο που χρησιμοποιεί και τις τέσσερις παραμέτρους έχει την καλύτερη απόδοση.

Στη συνέχεια, το μοντέλο LSTM με την καλύτερη απόδοση χρησιμοποιείται για την πρόβλεψη των συντελεστών SH και οι παγκόσμιοι ωριαίοι χάρτες TEC αναπαράγονται χρησιμοποιώντας τους 256 προβλεπόμενους συντελεστές SH. Πραγματοποιείται συνολική αξιολόγηση σε σχέση με το CODE GIM TEC.

Τα αποτελέσματα δείχνουν ότι το μέσο τετραγωνικό σφάλμα ρίζας TEC πρώτης/δεύτερης ώρας (RMSE) είναι 1,27/2,20 TECU κατά τη διάρκεια της καταιγίδας και 0,86/1,51 TECU κατά τη διάρκεια της ώρας ησυχίας, επομένως το αναπτυγμένο μοντέλο έχει καλή απόδοση τόσο σε περιόδους ησυχίας όσο και σε περιόδους καταιγίδας. Επιπλέον, τυπικές ιονοσφαιρικές δομές, όπως η ανωμαλία ιοντισμού του ισημερινού (EIA) και η πυκνότητα ενισχυμένη από καταιγίδες (SED), αναπαράγονται καλά στους προβλεπόμενους χάρτες TEC κατά τη διάρκεια της καταιγίδας. Το μοντέλο που αναπτύχθηκε δείχνει επίσης ανταγωνιστική απόδοση στην πρόβλεψη του παγκόσμιου TEC σε σύγκριση με το μοντέλο επιμονής και δύο εμπειρικά μοντέλα (IRI-2016 και NeQuick-2).


2.3 Principal component analysis (PCA)

Αυτή η εργασία [18], εισάγει έναν νέο αλγόριθμο πρόβλεψης ιονόσφαιρας που βασίζεται στη σύντηξη μεθόδων ανάλυσης κύριων συστατικών και τεχνητών νευρωνικών δικτύων (PCA-NN) για την πρόβλεψη των τιμών TEC της ιονόσφαιρας. Για την εφαρμογή μεθοδολογιών τεχνητής νοημοσύνης χρησιμοποιήθηκαν ηλιακός δείκτης (F10.7), γεωμαγνητικός δείκτης (δείκτης Ap) και δεδομένα TEC 20 ετών (1997-2016) σε σημείο πλέγματος της Ιαπωνίας (34,95 °N και 134,05 °E). Τα πειραματικά αποτελέσματα υπογραμμίζουν την αξιοπιστία του προτεινόμενου αλγορίθμου στην πρόβλεψη των επιπτώσεων χρονοκαθυστέρησης της ιονόσφαιρας.

Η ανάλυση κύριου συστατικού (PCA) είναι η διαδικασία υπολογισμού των κύριων στοιχείων και χρήσης τους για την πραγματοποίηση αλλαγής βάσης στα δεδομένα, μερικές φορές χρησιμοποιώντας μόνο τα πρώτα κύρια στοιχεία και αγνοώντας τα υπόλοιπα.

Το PCA χρησιμοποιείται στην διερευνητική ανάλυση δεδομένων και στη δημιουργία προγνωστικών μοντέλων. Χρησιμοποιείται συνήθως για τη μείωση των διαστάσεων προβάλλοντας κάθε σημείο δεδομένων μόνο στα πρώτα βασικά στοιχεία για να ληφθούν δεδομένα χαμηλότερης διάστασης, διατηρώντας παράλληλα όσο το δυνατόν μεγαλύτερη παραλλαγή των δεδομένων. Η πρώτη κύρια συνιστώσα μπορεί ισοδύναμα να οριστεί ως μια κατεύθυνση που μεγιστοποιεί τη διακύμανση των προβαλλόμενων δεδομένων.

Από κάθε στόχο, μπορεί να φανεί ότι τα κύρια συστατικά είναι ιδιοδιανύσματα του πίνακα συνδιακύμανσης των δεδομένων. Έτσι, τα κύρια συστατικά υπολογίζονται συχνά με ιδιοαποσύνθεση του πίνακα συνδιακύμανσης δεδομένων ή με αποσύνθεση μοναδικής τιμής του πίνακα δεδομένων. Το PCA είναι η απλούστερη από τις πραγματικές πολυμεταβλητές αναλύσεις που βασίζονται σε ιδιοδιάνυσμα και σχετίζεται στενά με την ανάλυση παραγόντων. Η παραγοντική ανάλυση συνήθως ενσωματώνει περισσότερες ειδικές υποθέσεις για την υποκείμενη δομή και επιλύει ιδιοδιανύσματα ενός ελαφρώς διαφορετικού πίνακα. Η PCA σχετίζεται επίσης με την κανονική ανάλυση συσχέτισης (CCA). Το CCA ορίζει συστήματα συντεταγμένων που περιγράφουν βέλτιστα τη διασταυρούμενη συνδιακύμανση μεταξύ δύο συνόλων δεδομένων ενώ το PCA ορίζει ένα νέο ορθογώνιο σύστημα συντεταγμένων που περιγράφει βέλτιστα τη διακύμανση σε ένα μεμονωμένο σύνολο δεδομένων.



Εικόνα 1. Μοντέλο PCA

2.4 OKSM

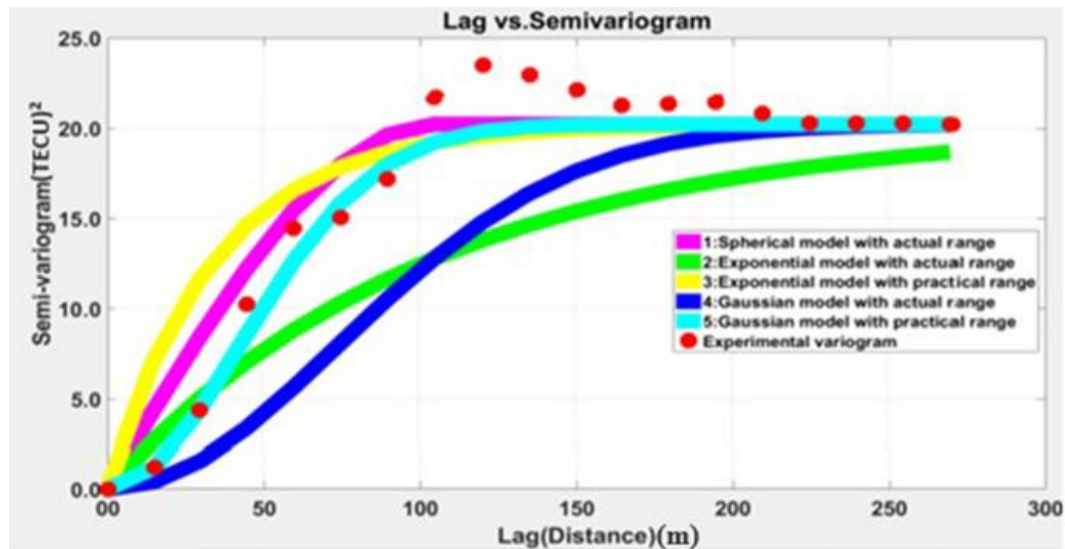
Αυτό το έγγραφο [19], περιγράφει τη μεθοδολογία πρόβλεψης TEC χρησιμοποιώντας το συνηθισμένο μοντέλο υποκατάστασης με βάση το Kriging (OKSM). Το OKSM αξιολογείται χρησιμοποιώντας τα δεδομένα που λαμβάνονται και συλλέγονται από τον σταθμό δέκτη IRNSS που είναι εγκατεστημένος στο ACS College of Engineering (ACSCE), στο Bengaluru (12,8913 °N, 77,4658 °E), στην Ινδία και σε άλλους σταθμούς δικτύου Διεθνούς Υψηλής GNSS (IGS). Τα δεδομένα IRNSS TEC (Ιανουάριος 2018) υπολογίζονται χρησιμοποιώντας τη μέθοδο ψευδοεμβέλειας διπλής συχνότητας (L5 & S) και το TEC εξομαλύνεται με τη μέθοδο κανονικής κυβικής εξομάλυνσης spline. Το IRNSS Vertical TEC (VTEC) προβλέπεται από τις 16 Ιανουαρίου 2018 έως τις 26 Ιανουαρίου 2018 χρησιμοποιώντας προηγούμενες έξι ημέρες εκτιμώμενων τιμών VTEC. Ομοίως, το GPS VTEC για το σταθμό IGS στο IISC, Bengaluru προβλέπεται επίσης για την ίδια διάρκεια για την επικύρωση του ανεπτυγμένου OKSM.

Προκειμένου να αξιολογηθεί η απόδοση του αναπτυγμένου μοντέλου πρόβλεψης για διαφορετικές γεωγραφικές τοποθεσίες, συνθήκες ηλιακής δραστηριότητας και εποχές, το VTEC προβλέπεται και αναλύεται για διαφορετικές περιοχές γεωγραφικού πλάτους, όπως σταθμός PHON χαμηλού γεωγραφικού πλάτους (6,9599 °N, 158,2101 °E), μεσαία - Γεωγραφικό πλάτος σταθμός ALGO (45,9588 °N, -78,0714 °E) και σταθμός NRIL μεγάλου πλάτους (69,3618 °N, 88,3597 °E) κατά τη διάρκεια διαφορετικών συνθηκών ηλιακής δραστηριότητας (Χαμηλή-2008, Μέση-2011 και Υψηλή ηλιακή δραστηριότητα 2013) και κατά τη διάρκεια διαφορετικών εποχών (άνοιξη, καλοκαίρι, βροχερός και χειμώνας) το έτος 2017.

Από την ανάλυση των αποτελεσμάτων πρόβλεψης OKSM, παρατηρείται ότι, το RMSE της προβλεπόμενης TEC ποικίλλει από 0,79 έως 3,6 TECU, το MAE είναι 0,4 έως 3 TECU και το MAPE είναι εντός 40% για ιονόσφαιρες ήρεμες μέρες. Το VTEC προβλέπεται επίσης κατά τη διάρκεια των ημερών καταιγίδας (26 Οκτωβρίου 2003 έως 31 Οκτωβρίου

Για τη μελέτη της απόδοσης του μοντέλου, τα αποτελέσματα πρόβλεψης VTEC του OKSM συγκρίνονται με τα αποτελέσματα πρόβλεψης από το Standard Persistence Model (SPM) και το VTEC που προέρχονται από το μοντέλο International Reference Ionosphere (IRI-2016). Το RMSE του OKSM είναι 1,9679 TECU, το MAE είναι 1,245 TECU και το MAPE είναι 9%, ενώ για το SPM, το RMSE είναι 4,8372 TECU, το MAE είναι 3,7496 TECU και το MAPE είναι 36%. Ομοίως, για το μοντέλο IRI-2016, το RMSE είναι 7,9 TECU, το MAE είναι 7,1976 TECU και το MAPE είναι 66%. Επομένως, οι προβλέψεις TEC από την OKSM είναι καλύτερες από τις SPM και IRI-2016. Τα αποτελέσματα δείχνουν ότι το OKSM είναι χρήσιμο για εφαρμογές σε ιονοσφαιρικές μελέτες.

2003).



Εικόνα 2. Μοντέλο OKSM

2.5 Τεχνικές Μοντελοποίησης DIAS

Η εργασία [20], περιγράφει τη χρήση των ιονόσφαιρων μετρήσεων στις τεχνικές μοντελοποίησης DIAS για την προδιαγραφή, την πρόβλεψη και την πρόβλεψη της ιονόσφαιρας στην ευρωπαϊκή περιοχή και περιγράφει λεπτομερώς τα τελικά προϊόντα που είναι διαθέσιμα στην κοινότητα χρηστών DIAS.

Δύο είναι οι κύριοι στόχοι του έργου DIAS (European Digital Upper Atmosphere Server). Πρώτον, δημιουργεί μια πανευρωπαϊκή αποθήκη ακατέργαστων και παράγωγων ψηφιακών δεδομένων που περιγράφει την κατάσταση του ιονόσφαιρου τμήματος της ανώτερης ατμόσφαιρας, η οποία είναι ικανή να απορροφά πληροφορίες σε πραγματικό χρόνο και να διατηρεί συλλογές ιστορικών δεδομένων που παρέχονται από τους περισσότερους σταθμούς ιονόσφαιρας που λειτουργούν στην Ευρώπη.

Δεύτερον, το σύστημα DIAS παράγει και διανέμει, με βάση τη συλλογή ακατέργαστων δεδομένων, διάφορα λειτουργικά προϊόντα που απαιτούνται από διάφορες ομάδες χρηστών για σκοπούς ιονόσφαιρας τώρα μετάδοσης, πρόβλεψης και πρόβλεψης. Το έργο ολοκληρώθηκε τον Μάιο του 2006 και ο διακομιστής ΔΙΑΣ λειτουργεί έκτοτε συνεχώς.


Τα βασικά προϊόντα που παραδίδονται είναι ιονογράμματα σε πραγματικό χρόνο και ιστορικά από όλους τους ιονοσφαιρικούς σταθμούς που συνδέονται με το DIAS, γραφήματα συχνότητων και χάρτες της ιονόσφαιρας στην Ευρώπη με βάση τις παραμέτρους foF2, M(3000)F2, MUF και πυκνότητας ηλεκτρονίων, καθώς και μακροπρόθεσμη πρόβλεψη και βραχυπρόθεσμη πρόβλεψη έως και 24 ώρες μπροστά.

2.6 Τεχνική Support Vector Machine (SVM)

Αυτό το έγγραφο [21], προτείνει μια μέθοδο για την πρόβλεψη της ιονοσφαιρικής κρίσιμης συχνότητας, χρησιμοποιώντας την προσέγγιση της μηχανής διανύσματος υποστήριξης (SVM). Είναι ένας αλγόριθμος υπολογιστή που μαθαίνει με το παράδειγμα να εκχωρεί ετικέτες σε αντικείμενα.

Οι είσοδοι στο δίκτυο SVM είναι η ώρα της ημέρας, οι εποχιακές πληροφορίες, ο μέσος αριθμός ηλιακών κηλίδων 2 μηνών σε λειτουργία (R2), ο μέσος όρος λειτουργίας 3 ημερών του πλανητικού μαγνητικού δείκτη, η ηλιακή γωνία ζενίθ, η παρούσα τιμή $f0F2(t)$ και η πρώτη και η δεύτερη προσαύξησή του, η παρατήρηση του $f0F2$ στις $t-23$ h, η μέση τιμή των 30 ημερών τη στιγμή, t , $fmF2(t)$ και ο τρέχων μέσος όρος των προηγούμενων 30 ημερών του $f0F2$ σε $t-23$ h $fmF2(t-23)$. Η έξοδος είναι η προβλεπόμενη $f0F2$ 1 ώρα μπροστά.

Το δίκτυο είναι εκπαιδευμένο να χρησιμοποιεί τα δεδομένα ηχογράφησης ιονόσφαιρας στους σταθμούς Haikou, Guangzhou, Chongqing, Lanzhou, Πεκίνο, Changchun και Manzhouli σε υψηλές και χαμηλές ηλιακές δραστηριότητες. Η απόδοση του μοντέλου SVM επαληθεύτηκε με δεδομένα που παρατηρήθηκαν. Δείχνεται ότι το προβλεπόμενο $f0F2$ έχει καλή συμφωνία με το παρατηρούμενο $f0F2$. Η απόδοση του μοντέλου SVM είναι ανώτερη από αυτή των μοντέλων αυτοσυσχέτισης και επιμονής και ότι είναι συγκρίσιμη με αυτή του μοντέλου νευρωνικών δικτύων.



Εικόνα 3. Τεχνική SVM

Κεφάλαιο 3^ο Σύστημα GNSS και Ατμόσφαιρα

3.1 Βασικές αρχές συστήματος GNSS

Τα Global Navigation Satellite Systems (GNSS) είναι παγκόσμια δορυφορικά συστήματα πλοήγησης και αναφέρονται σε αστερισμούς δορυφόρων που παρέχουν σήματα από το διάστημα που μεταδίδουν δεδομένα θέσης και χρονισμού σε δέκτες GNSS. Στη συνέχεια, οι δέκτες χρησιμοποιούν αυτά τα δεδομένα για να προσδιορίσουν τη θέση. Εξ ορισμού, το GNSS παρέχει παγκόσμια κάλυψη. Παραδείγματα GNSS περιλαμβάνουν το Galileo της Ευρώπης, το NAVigation Satellite Timing And Ranging Global Positioning System (NAVSTAR GPS) των ΗΠΑ, το GLObal Navigation Satellite System (GLONASS) της Ρωσίας, το δορυφορικό σύστημα πλοήγησης COMPASS της Κίνας, το Quasi-Zenith Satellite System (QZSS) της Ιαπωνίας και το Indian Regional Navigational Satellite System (IRNSS) καθώς και συμπληρωματικά συστήματα SBAS (EGNOS, WAAS) και συνεργασίες με διεθνείς οργανισμούς και υπηρεσίες Τηλεπικοινωνιών, Αεροπλοΐας κα.

Η απόδοση του GNSS αξιολογείται χρησιμοποιώντας τέσσερα κριτήρια:

- Ακρίβεια: η διαφορά μεταξύ της μέτρησης και της πραγματικής θέσης, της ταχύτητας ή του χρόνου ενός δέκτη
- Ακεραιότητα: η ικανότητα ενός συστήματος να παρέχει ένα κατώφλι εμπιστοσύνης και, σε περίπτωση ανωμαλίας στα δεδομένα τοποθέτησης, ένας συναγερμός.
- Συνέχεια: η ικανότητα ενός συστήματος να λειτουργεί χωρίς διακοπή.
- Διαθεσιμότητα: το ποσοστό χρόνου που ένα σήμα πληροί τα παραπάνω κριτήρια ακρίβειας, ακεραιότητας και συνέχειας.

Αυτή η απόδοση μπορεί να βελτιωθεί μέσω περιφερειακών συστημάτων αύξησης μέσω δορυφόρου (SBAS), όπως η Ευρωπαϊκή Υπηρεσία Επικάλυψης Πλοήγησης Γεωστατικών (EGNOS). Το EGNOS βελτιώνει την ακρίβεια και την αξιοπιστία των πληροφοριών GPS διορθώνοντας τα σφάλματα μέτρησης σήματος και παρέχοντας πληροφορίες σχετικά με την ακεραιότητα των σημάτων του.

3.2 Η ατμόσφαιρα της Γης

3.2.1 Εισαγωγικές Έννοιες

Η ατμόσφαιρα 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. 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 ατμόσφαιρα είναι ένα στρώμα αερίου ή στρώματα αερίων, που περιβάλλουν έναν πλανήτη και συγκρατούνται στη θέση τους από τη βαρύτητα του πλανητικού σώμα. Ένας πλανήτης διατηρεί μια ατμόσφαιρα όταν η βαρύτητα είναι μεγάλη και η θερμοκρασία της ατμόσφαιρας χαμηλή. Μια αστρική ατμόσφαιρα είναι η εξωτερική περιοχή ενός άστρου, η οποία περιλαμβάνει τα στρώματα πάνω από την αδιαφανή φωτόσφαιρα. αστέρια χαμηλής θερμοκρασίας μπορεί να έχουν εξωτερικές ατμόσφαιρες που περιέχουν μόρια ένωσης.

Η ατμόσφαιρα της Γης αποτελείται από άζωτο (78%), οξυγόνο (21%), αργό (0,9%), διοξείδιο του άνθρακα (0,04%) και ιχνοαέρια. Οι περισσότεροι οργανισμοί χρησιμοποιούν οξυγόνο για την αναπνοή. οι κεραυνοί και τα βακτήρια πραγματοποιούν δέσμευση αζώτου για να παράγουν αμμωνία που χρησιμοποιείται για την παραγωγή νουκλεοτιδίων και αμινοξέων. τα φυτά, τα φύκια και τα κυανοβακτήρια χρησιμοποιούν διοξείδιο του άνθρακα για φωτοσύνθεση. Η πολυεπίπεδη σύνθεση της ατμόσφαιρας ελαχιστοποιεί τις βλαβερές επιπτώσεις του ηλιακού φωτός, της υπερύδους 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.

3.2.2 Τα στρώματα της ατμόσφαιρας

Η ατμόσφαιρα αποτελείται από στρώματα με βάση τη θερμοκρασία. Αυτά τα στρώματα είναι η τροπόσφαιρα, η στρατόσφαιρα, η μεσόσφαιρα και η θερμόσφαιρα. Μια περαιτέρω περιοχή σε περίπου 500 km πάνω από την επιφάνεια της Γης ονομάζεται εξώσφαιρα.

Μπορεί να χωριστεί σε στρώματα με βάση τη θερμοκρασία της, όπως φαίνεται στο παρακάτω σχήμα. Αυτά τα στρώματα είναι η τροπόσφαιρα, η στρατόσφαιρα, η μεσόσφαιρα και η θερμόσφαιρα. Μια περαιτέρω περιοχή, που ξεκινά περίπου 500 km πάνω από την επιφάνεια της Γης, ονομάζεται εξώσφαιρα.


- **Η Τροπόσφαιρα**

Αυτό είναι το χαμηλότερο μέρος της ατμόσφαιρας - το μέρος στο οποίο ζούμε. Περιέχει το μεγαλύτερο μέρος του καιρού μας - σύννεφα, βροχή, χιόνι. Σε αυτό το τμήμα της ατμόσφαιρας η θερμοκρασία γίνεται πιο κρύα καθώς η απόσταση πάνω από τη γη αυξάνεται, κατά περίπου 6,5°C ανά χιλιόμετρο. Η πραγματική αλλαγή της θερμοκρασίας με το ύψος ποικίλλει από μέρα σε μέρα, ανάλογα με τον καιρό.

Η τροπόσφαιρα περιέχει περίπου το 75% του συνόλου του αέρα στην ατμόσφαιρα και σχεδόν το σύνολο των υδρατμών (που σχηματίζει σύννεφα και βροχή). Η μείωση της θερμοκρασίας με το ύψος είναι αποτέλεσμα της φθίνουσας πίεσης. Εάν ένα δέμα αέρα κινηθεί προς τα πάνω, διαστέλλεται (λόγω της χαμηλότερης πίεσης). Όταν ο αέρας διαστέλλεται, ψύχεται. Έτσι, ο αέρας ψηλότερα είναι πιο δροσερός από τον αέρα κάτω.

Το χαμηλότερο τμήμα της τροπόσφαιρας ονομάζεται οριακό στρώμα. Εδώ καθορίζεται η κίνηση του αέρα από τις ιδιότητες της επιφάνειας της Γης. Οι αναταράξεις δημιουργούνται καθώς ο άνεμος πνέει πάνω από την επιφάνεια της Γης και από θερμικές θερμοκρασίες που αναδύονται από τη γη καθώς θερμαίνεται από τον ήλιο. Αυτή η αναταραχή ανακατανέμει τη θερμότητα και την υγρασία εντός του οριακού στρώματος, καθώς και τους ρύπους και άλλα συστατικά της ατμόσφαιρας.

Η κορυφή της τροπόσφαιρας ονομάζεται τροπόπαυση. Αυτό είναι το χαμηλότερο στους πόλους, όπου είναι περίπου 7 - 10 km πάνω από την επιφάνεια της Γης. Είναι το υψηλότερο (περίπου 17 - 18 km) κοντά στον ισημερινό.



Εικόνα 4. Τα στρώματα της ατμόσφαιρας

- **Η Στρατόσφαιρα**

Αυτό εκτείνεται προς τα πάνω από την τροπόπαυση σε περίπου 50 km. Περιέχει μεγάλο μέρος του όζοντος στην ατμόσφαιρα. Η αύξηση της θερμοκρασίας με το ύψος συμβαίνει λόγω της απορρόφησης της υπεριώδους ακτινοβολίας (UV) από τον ήλιο από αυτό το όζον. Οι θερμοκρασίες στη στρατόσφαιρα είναι οι υψηλότερες στον καλοκαιρινό πόλο και οι χαμηλότερες στον χειμερινό πόλο.

Απορροφώντας την επικίνδυνη υπεριώδη ακτινοβολία, το όζον στη στρατόσφαιρα μας προστατεύει από τον καρκίνο του δέρματος και άλλες βλάβες στην υγεία. Ωστόσο, οι χημικές ουσίες (ονομαζόμενες CFC ή φρέον και halons) που χρησιμοποιούνταν κάποτε σε ψυγεία, σπρέι και πυροσβεστήρες έχουν μειώσει την ποσότητα του όζοντος στη

στρατόσφαιρα, ιδιαίτερα σε πολικά γεωγραφικά πλάτη, οδηγώντας στη λεγόμενη «τρύπα του όζοντος της Ανταρκτικής».

Τώρα οι άνθρωποι έχουν σταματήσει να παράγουν τους περισσότερους από τους επιβλαβείς CFC που αναμένουμε ότι η τρύπα του όζοντος θα ανακάμψει τελικά τον 21ο αιώνα, αλλά αυτή είναι μια αργή διαδικασία.

- **Η Μεσόσφαιρα**

Η περιοχή πάνω από τη στρατόσφαιρα ονομάζεται μεσόσφαιρα. Εδώ η θερμοκρασία μειώνεται και πάλι με το ύψος, φτάνοντας στο ελάχιστο τους -90°C περίπου στη «μεσόπαυση».

- **Η Θερμόσφαιρα και η Ιονόσφαιρα**

Η θερμόσφαιρα βρίσκεται πάνω από τη μεσόπαυση και είναι μια περιοχή στην οποία οι θερμοκρασίες αυξάνονται και πάλι με το ύψος. Αυτή η αύξηση της θερμοκρασίας προκαλείται από την απορρόφηση της ενεργητικής υπεριώδους ακτινοβολίας και των ακτίνων X από τον ήλιο.

Στην περιοχή της ατμόσφαιρας πάνω από περίπου 80 km 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 θερμοκρασία της θερμόσφαιρας ποικίλλει μεταξύ νύχτας και ημέρας και μεταξύ των εποχών, όπως και ο αριθμός των ιόντων και των ηλεκτρονίων που υπάρχουν. Η ιονόσφαιρα αντανακλά και απορροφά ραδιοκύματα, επιτρέποντάς μας να λαμβάνουμε ραδιοφωνικές εκπομπές βραχέων κυμάτων στη Νέα Ζηλανδία από άλλα μέρη του κόσμου.

- **Η Εξώσφαιρα**

Η περιοχή πάνω από περίπου 500 km ονομάζεται εξώσφαιρα. Περιέχει κυρίως άτομα οξυγόνου και υδρογόνου, αλλά είναι τόσο λίγα από αυτά που σπάνια συγκρούονται - ακολουθούν «βαλλιστικές» τροχιές υπό την επίδραση της βαρύτητας και μερικά από αυτά διαφεύγουν αμέσως στο διάστημα.

- **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 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 προοδευτικά 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 πάματος (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 πλασμασφαιρα ονομάζεται ιονόσφαιρα από την κορυφή.



Εικόνα 5. 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) [22], 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 [22]. 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 EIElectron 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 ακέραιων 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 $\pm 30^\circ$ 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 καν'να 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 θερμοσφαιρα, 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 θερμοσφαιρα 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-θερμόσφαιρας, 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 EIA 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 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 δεσεκατομμύρια 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 6. 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 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 «φυσαλίδων» του ισημερινού πλάσματος αυξάνουν την πιθανότητα εξασθένησης των μεταιονοσφαιρικών σημάτων, ειδικά κατά τη διάρκεια γεωμαγνητικών καταιγίδων. Οι αστάθειες του ιονοσφαιρικού πλάσματος στα «τοιχώματα» μιας φυσαλίδας με πυκνότητα ηλεκτρονίων μικρότερη από την τιμή του υποβάθρου χαρακτηρίζονται επίσης από έντονες διαβαθμίσεις της πυκνότητας ηλεκτρονίων. Για παράδειγμα, τα τοιχώματα των φυσαλίδων μπορούν επίσης να είναι πηγή ιονοσφαιρικών σπινθηρισμών. Επομένως, ο χωρικός προσανατολισμός της φυσαλίδας 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 «φυσαλίδες» 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. Κάποιοι 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 7. 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 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. Kohn, 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 αναπήδησεων, 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 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 Kp 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 $4 \frac{2}{3}$, το 5 είναι 5 και το 5+ είναι $5 \frac{1}{3}$. 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 Kp ως εξής:

Kp	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
Kp	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) 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 ζώνη του σέλαος που παράγεται από ενισχυμένα ιονοσφαιρικά ρεύματα που ρέουν κάτω και μέσα στο σέλας (Δαγκλής I., Σημειώσεις Διαστημικής Φυσικής, 2018). Προέρχεται από διακυμάνσεις του γεωμαγνητικού πεδίου στη συνιστώσα H 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 H 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 H να δείχνει προς τον τοπικό μαγνητικό βορρά και η γραμμή βάσης αφαιρείται. Τότε ο σταθμός με τη μεγαλύτερη τιμή H 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)).

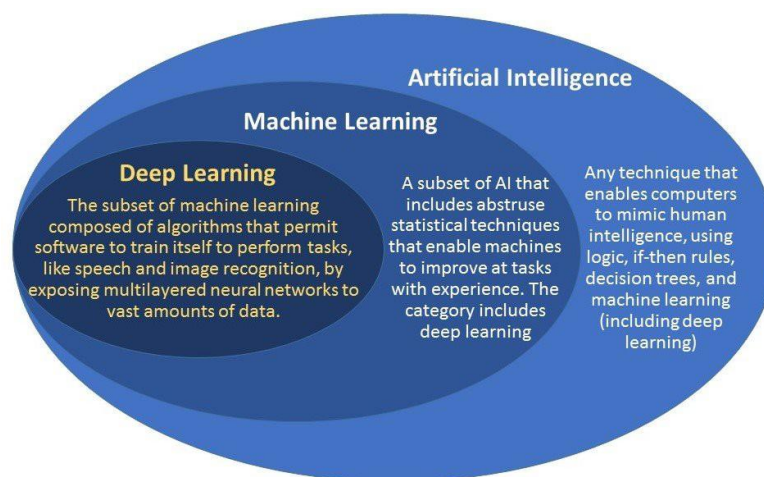
3.5.10 Disturbance storm time (Dst)

Ο δείκτης χρόνου διαταραχής καταιγίδας (Dst) 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.

Κεφάλαιο 4^ο Βασικές έννοιες Τεχνητής Νοημοσύνης

Όπως προαναφέρθηκε τόσο στην εισαγωγή όσο και στην βιβλιογραφική ανασκόπηση, σχεδόν όλοι οι αλγόριθμοι αντιμετώπισης του προβλήματος της αυτόματης εξαγωγής κτηρίων, εξαρτώνται από την δομή ενός αλγορίθμου βαθιάς μάθησης ή μηχανικής μάθησης. Η βαθιά μάθηση αποτελεί κομμάτι της μηχανικής μάθησης η οποία αποτελεί κομμάτι της τεχνητής νοημοσύνης όπως φαίνεται και στην Εικόνα 8. Γι' αυτό και στο ακόλουθο κεφάλαιο, πρώτα θα γίνει μια αναφορά στην μηχανική μάθηση και έπειτα στην επιστήμη της βαθιάς μάθησης, που χρησιμοποιεί νευρωνικά δίκτυα και πιο συγκεκριμένα επαναλαμβανόμενα νευρωνικά δίκτυα, συμφωνά με τα οποία υλοποιείται και η επιλογή των παραμέτρων επιρροής της ιονόσφαιρας.



Εικόνα 8. Τεχνητή νοημοσύνη και τα υποσύνολά της.

4.1 Μηχανική μάθηση (Machine Learning)

Νοημοσύνη ορίζεται ως η ικανότητα του ανθρώπου να επεξεργάζεται πληροφορία με σκοπό την λήψη οποιασδήποτε απόφασης. Κατ' επέκταση, Τεχνητή νοημοσύνη (Artificial Intelligence – AI) είναι η προσπάθεια του ανθρώπου να υλοποιήσει αλγορίθμους με σκοπό την επεξεργασία της πληροφορίας για την λήψη απόφασης.

Η μηχανική μάθηση είναι μέθοδος ανάλυσης δεδομένων που αυτοματοποιεί τη δόμηση αναλυτικών μοντέλων. Είναι ο κυριότερος κλάδος της τεχνητής νοημοσύνης και βασίζεται στην ιδέα ότι τα συστήματα μπορούν να μάθουν από δεδομένα, να εντοπίσουν πρότυπα και να πάρουν αποφάσεις με ελάχιστη ανθρώπινη παρέμβαση και χρησιμοποιώντας δεδομένα εκπαίδευσης. Χρησιμοποιείται κυρίως για τον εντοπισμό μίας τάσης που ακολουθούν τα δεδομένα, αλλά επικεντρώνονται και στην πρόβλεψη βάσει γνωστών πληροφοριών που μαθαίνουν από τα δεδομένα εκπαίδευσης.

Η μελέτη της μηχανικής μάθησης είναι σημαντική τόσο για την αντιμετώπιση αυτών των θεμελιωδών επιστημονικών και μηχανικών ερωτημάτων όσο και για το εξαιρετικά πρακτικό λογισμικό υπολογιστή που έχει παραγάγει και διαθέτει σε πολλές εφαρμογές. Η μηχανική μάθηση έχει προχωρήσει δραματικά τις τελευταίες δύο δεκαετίες, από την εργαστηριακή περιέργεια σε μια πρακτική τεχνολογία σε ευρεία εμπορική χρήση. Στο πλαίσιο της τεχνητής νοημοσύνης (AI), η μηχανική μάθηση έχει αναδειχθεί ως η μέθοδος επιλογής για την ανάπτυξη πρακτικού λογισμικού για όραση υπολογιστή, αναγνώριση ομιλίας, επεξεργασία φυσικής γλώσσας, έλεγχο ρομπότ και άλλες εφαρμογές.

Πολλοί προγραμματιστές συστημάτων AI αναγνωρίζουν τώρα ότι, για πολλές εφαρμογές, μπορεί να είναι πολύ πιο εύκολο να εκπαιδεύσετε ένα σύστημα δείχνοντάς του παραδείγματα επιθυμητής συμπεριφοράς εισόδου-εξόδου παρά να το προγραμματίσετε χειροκίνητα προβλέποντας την επιθυμητή απόκριση για όλες τις πιθανές εισόδους.

Στην μηχανική μάθηση, πολύ σημαντικός είναι ο επαναληπτικός παράγοντας, καθώς τα μοντέλα που κατασκευάζονται εκτίθενται σε νέα δεδομένα και μπορούν αυτόνομα να προσαρμοστούν στις ανάγκες τους. Μαθαίνουν, ουσιαστικά, από προηγούμενους υπολογισμούς να παράγουν αξιόπιστα επανειλημμένες αποφάσεις και αποτελέσματα.

Η μηχανική μάθηση διαφοροποιείται από άλλες μεθόδους, όπως η βαθιά μάθηση και η αναγνώριση προτύπων, ενώ είναι αρκετά πιο γενική μέθοδος τεχνητής νοημοσύνης σε σχέση με άλλες υπάρχουσες ως προς τους στόχους της. Οι δύο προαναφερθείσες μέθοδοι μοιάζουν μεταξύ τους, με την αναγνώριση προτύπων να ασχολείται με μεθόδους ταξινόμησης, ενώ η μηχανική μάθηση με αλγόριθμους που στοχεύουν στην εκμάθηση από τους εαυτούς τους. Η βαθιά μάθηση μπορεί να θεωρηθεί υποσύνολο της μηχανικής μάθησης, όπου το υπολογιστικό σύστημα είναι δυνατόν να εκπαιδευτεί μέσα από την αναπαράσταση των δεδομένων. Πρακτικά, ακόμη, η βαθιά μάθηση είναι ικανή να μετατρέψει ένα πρόβλημα περισσότερων διαστάσεων σε ένα αντίστοιχο με λιγότερες διαστάσεις.

Οι διάφορες κατηγορίες της μηχανικής μάθησης, δηλαδή εκπαίδευσης νευρωνικών δικτύων, παραδοσιακά χωρίζονται σε τρεις μεγάλες κατηγορίες ανάλογα με τη φύση των πληροφοριών που διατίθενται για το σύστημα εκμάθησης.

- **Επιβλεπόμενη μάθηση (Supervised Learning):** Παρέχονται από το χειριστή στον υπολογιστή παραδείγματα από δεδομένα και τα επιθυμητά τους αποτελέσματα με στόχο να εκπαιδευτεί στο γενικό κανόνα που αποτυπώνει τα δεδομένα εισόδου και εξόδου.
- **Μη επιβλεπόμενη μάθηση (Unsupervised Learning):** Δε δίνονται κατευθύνσεις στον υπολογιστή για το επιθυμητό αποτέλεσμα, επιτρέποντάς του να κατασκευάσει μόνος του ένα μοντέλο για τα δεδομένα εισόδου και να

αναγνωρίζει τη δομή τους. Έχει εφαρμογή συχνά σε προβλήματα ανάλυσης-σύνδεσης και ταξινόμησης.

- **Ενισχυτική Μάθηση (Reinforcement Learning):** Ένα υπολογιστικό πρόγραμμα αλληλοεπιδρά με ένα δυναμικό περιβάλλον εντός του οποίου πρέπει να εκτελέσει έναν συγκεκριμένο στόχο (π.χ. ο έλεγχος κίνησης ρομπότ), όπου ο αλγόριθμος εξοικειώνεται με μία στρατηγική ενεργειών. Καθώς ανακαλύπτει το χώρο του προβλήματος, ο υπολογιστής δίνει πληροφορίες για αυτό που είναι ανάλογες του κέρδους που θα έχει από την επίτευξη του στόχου, το οποίο προσπαθεί να μεγιστοποιήσει.

Η επιβλεπόμενη μάθηση χρησιμοποιείται όταν τα δεδομένα εισόδου και εξόδου ενώνονται από την σχέση:

$$Y = f(x) \quad (1.1)$$

Όπου f είναι ένα σύνολο παραμέτρων [8],

Έχουμε λοιπόν έναν ορισμό της αποστολής μας (T): να προβλέψουμε το y από το x από τον τύπο:

$$\hat{y} = w x.$$

Ένας τρόπος μέτρησης της απόδοσης του μοντέλου είναι ο υπολογισμός του μέσου τετραγωνικού σφάλματος του μοντέλου στο δοκιμαστικό σύνολο. Αν το y δίνει τις προβλέψεις του μοντέλου στο σύνολο δοκιμής, τότε το μέσο τετράγωνο σφάλμα δίνεται από τον τύπο:

$$MSE = 1/m \sum_i (y^{\hat{}} - y)_i^2. \quad (5.4)$$

Για να φτιάξουμε έναν αλγόριθμο μηχανικής μάθησης, πρέπει να σχεδιάσουμε έναν αλγόριθμο που θα βελτιώσει τα βάρη w με τρόπο που να μειώνει το MSE όταν επιτρέπεται στον αλγόριθμο να αποκτήσει εμπειρία παρατηρώντας ένα σύνολο εκπαίδευσης (X, y) .

Ένας διαισθητικός τρόπος για να γίνει αυτό είναι απλώς η ελαχιστοποίηση του μέσου τετραγώνου σφάλματος στο σύνολο εκπαίδευσης, MSE [8].

4.2 Πρόβλεψη και Νευρωνικά δίκτυα (Neural Networks)

Νευρωνικό δίκτυο (Neural Network ή NN) [8], ορίζεται ως ένα κύκλωμα διασυνδεδεμένων νευρώνων. Με αναφορά τον ανθρώπινο εγκέφαλο, τα βιολογικά νευρωνικά δίκτυα (Biological Neural Networks) αποτελούνται από ένα σύνολο νευρώνων με τις διασυνδέσεις τους που έχουν ως στόχο την επεξεργασία των σημάτων που δέχεται ο άνθρωπος καθημερινά. Τα τεχνητά νευρωνικά δίκτυα (Artificial neural networks - ANNs), αποτελούν μια μίμηση των βιολογικών καθώς δομούνται από κόμβους ή αλλιώς

νευρώνες πλήρως διασυνδεδεμένους μεταξύ τους, ενώ δέχονται και επεξεργάζονται σήματα με απώτερο στόχο την μάθηση. Η υλοποίηση αυτών γίνεται μέσω της ανάπτυξης αλγορίθμων ικανών να επεξεργαστούν οποιοδήποτε σήμα.

Προκειμένου να γίνει αντιληπτή η έννοια των τεχνητών νευρωνικών δικτύων, αξίζει να αναφερθεί το πιο βασικό νευρωνικό δίκτυο που συνάμα αποτελεί και έναν νευρώνα ή αλλιώς ένα επίπεδο νευρωνικού δικτύου ή αλλιώς perceptron. Εφευρέθηκε από τον Frank Rosenblatt το 1957 και είναι η πιο απλοϊκή δομή νευρωνικού δικτύου. Εκτελεί κυρίως διεργασίες ταξινόμησης σε πρότυπα (ή κλάσεις) δεδομένων τα οποία είναι πλήρως διαχωρίσιμα μέσω μία γραμμής ή αλλιώς ευθείας σε ένα επίπεδο στο χώρο (linearly separable) [8].

4.2.1 Συνάρτηση Απώλειας (Loss Function)

Ο στόχος της Γραμμικής Παλινδρόμησης είναι να βρει μια γραμμή που ελαχιστοποιεί το σφάλμα πρόβλεψης όλων των σημείων δεδομένων.

Το βασικό βήμα σε οποιοδήποτε μοντέλο μηχανικής μάθησης είναι η αξιολόγηση της ακρίβειας του μοντέλου. Οι μετρήσεις Μέσο Τετραγωνικό Σφάλμα, Μέσο Απόλυτο Σφάλμα, Ρίζα Μέσου Τετραγωνικού Σφάλματος και R-Squared ή Συντελεστής προσδιορισμού χρησιμοποιούνται για την αξιολόγηση της απόδοσης του μοντέλου στην ανάλυση παλινδρόμησης.

Στην παρούσα διπλωματική θα μας απασχολήσουν το MAE και το MSE

Το μέσο απόλυτο σφάλμα 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.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

Where,

\hat{y} – predicted value of y
 \bar{y} – mean value of y

Εικόνα 9. Συνάρτηση απώλειας Mean Absolute Error (MAE)

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

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

Εικόνα 10. Συνάρτηση απώλειας Mean Square Error (MSE)

Οι διαφορές μεταξύ των παραπάνω είναι οι εξής:

- Το μέσο τετραγωνικό σφάλμα (MSE) και το ριζικό μέσο τετραγωνικό σφάλμα τιμωρούν τα μεγάλα σφάλματα πρόβλεψης νι-a-vis. Μέσο απόλυτο σφάλμα (MAE). Ωστόσο, το RMSE χρησιμοποιείται ευρέως από το MSE για την αξιολόγηση της απόδοσης του μοντέλου παλινδρόμησης με άλλα τυχαία μοντέλα, καθώς έχει τις ίδιες μονάδες με την εξαρτημένη μεταβλητή (άξονας Y).
- Το MSE είναι μια διαφοροποιήσιμη συνάρτηση που διευκολύνει την εκτέλεση μαθηματικών πράξεων σε σύγκριση με μια μη διαφοροποιήσιμη συνάρτηση όπως η MAE. Επομένως, σε πολλά μοντέλα, το RMSE χρησιμοποιείται ως προεπιλεγμένη μέτρηση για τον υπολογισμό της Συνάρτησης Απώλειας παρόλο που είναι πιο δύσκολο να ερμηνευτεί από το MAE.
- Το MAE είναι πιο ανθεκτικό σε δεδομένα με ακραίες τιμές.
- Η χαμηλότερη τιμή των MAE, MSE και RMSE συνεπάγεται υψηλότερη ακρίβεια ενός μοντέλου παλινδρόμησης. Ωστόσο, μια υψηλότερη τιμή του τετραγώνου R θεωρείται επιθυμητή.

Επομένως, εάν συγκρίνετε την ακρίβεια πρόβλεψης μεταξύ διαφορετικών μοντέλων γραμμικής παλινδρόμησης (LR), τότε το RMSE είναι μια καλύτερη επιλογή καθώς είναι απλό στον υπολογισμό και διαφοροποιήσιμο. Ωστόσο, εάν το σύνολο δεδομένων σας έχει ακραίες τιμές, τότε επιλέξτε MAE έναντι RMSE.

Επιπλέον, ο αριθμός των μεταβλητών πρόβλεψης σε ένα μοντέλο γραμμικής παλινδρόμησης προσδιορίζεται με προσαρμοσμένο τετράγωνο R και επιλέξτε RMSE έναντι προσαρμοσμένου R τετράγωνο εάν ενδιαφέρεστε για την αξιολόγηση της ακρίβειας πρόβλεψης μεταξύ διαφορετικών μοντέλων LR. [23]

4.2.2 Συναρτήσεις Ενεργοποίησης

Γενικά, στα νευρωνικά δίκτυα, η έξοδος του νευρώνα προκύπτει από εφαρμογή της συνάρτησης ενεργοποίησης στην συνολική του έξοδο y . Η συνάρτηση αυτή παίρνει το σήμα εξόδου από τον προηγούμενο νευρώνα και το μετατρέπει, σε μία μορφή ώστε να μπορεί να χρησιμοποιηθεί ως είσοδο στον επόμενο νευρώνα. Οι συναρτήσεις αυτές, χρησιμοποιούνται κυρίως, με σκοπό να βοηθήσουν την διατήρηση της τιμής εξόδου από τον νευρώνα σε ένα ορισμένο όριο, σύμφωνα με τις απαιτήσεις του σχεδιαστή του αλγορίθμου. Η είσοδος της συνάρτησης ενεργοποίησης αποτελείται από το εσωτερικό γινόμενο $x_i W_i$ με την πρόσθεση της τιμής b . Η τιμή που αναφέρθηκε, αν δεν είναι περιορισμένη εντός συγκεκριμένου ορίου, μπορεί να γίνει η αιτία σε υπολογιστικά θέματα. Οι συναρτήσεις ενεργοποίησης, είναι είτε γραμμικές, είτε μη γραμμικές. Οι μη γραμμικές προτιμώνται σε σχέση με τις γραμμικές καθώς αντικατοπτρίζουν πραγματικά δεδομένα τα οποία είναι πάντοτε μη γραμμικά.

Αξίζει να αναφερθεί, πως στην παρούσα εργασία χρησιμοποιούνται οι συναρτήσεις ενεργοποίησης, η Ανορθωτική Γραμμική Συνάρτηση (Rectified Linear activation Unit-ReLU) και η Συνάρτηση Υπερβολικής Εφαπτομένης (Hyperbolic Tangent Function –tanh). Η ReLU, γενικώς χρησιμοποιείται ως συνάρτηση ενεργοποίησης για τα κρυφά επίπεδα (Hidden Layers) στη βαθιά μάθηση. Έχει ισχυρά βιολογικά και μαθηματικά θεμέλια. Η συνάρτηση αυτή μετατρέπει τις αρνητικές τιμές σε μηδέν, ενώ τις θετικές τιμές τις διατηρεί. Αποτελεί συνήθη επιλογή κατά τη διαδικασία της μάθησης καθώς έχει σταθερή παράγωγο για τις θετικές τιμές .

Όσο αφορά τη Συνάρτηση Υπερβολικής Εφαπτομένης, είναι μία συνάρτηση που χρησιμοποιείται επίσης, αρκετά συχνά σε αλγορίθμους βαθιάς μάθησης. Είναι μία ομαλή συνάρτηση με κέντρο το μηδέν, όπου το εύρος της κυμαίνεται από τιμές μείον ένα έως ένα (-1,1). Η συνάρτηση αυτή, μοιάζει με τη σιγμοειδή (sigmoid), προτιμάται όμως περισσότερο καθώς δίνει καλύτερες επιδόσεις κατά την εκπαίδευση σε πολυεπίπεδα νευρωνικά δίκτυα. Η συνάρτηση tanh βοηθάει σε προβλήματα οπισθοδιάδοσης (back-propagation).

4.3 Βαθιά μάθηση (Deep Learning)

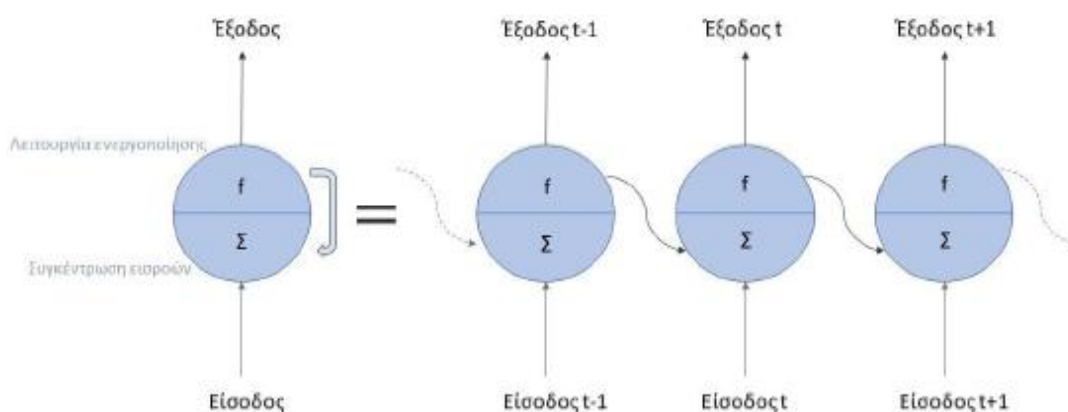
Η βαθιά μάθηση εστιάζει σύμφωνα με τη χρήση νευρωνικών δικτύων στην αυτόματη εξαγωγή προτύπων/οντοτήτων (patterns/features) μέσα από πρωτογενή δεδομένα, χρησιμοποιώντας τα για την υλοποίηση ορισμένων εργασιών όπως είναι π.χ. η σημασιολογική κατάτμηση. Οι αλγόριθμοι βαθιάς μάθησης χρησιμοποιούνται κυρίως επειδή μπορούν να παράγουν κατευθείαν οντότητες σε μια ιεραρχική δομή. Παραδείγματος χάριν για την αναγνώριση κτηρίων μέσα από τις εικόνες μια χρήσιμη οντότητα που παράγεται είναι ο υπολογισμός ακμών, ιεραρχικά τουλάχιστον τέσσερις ακμές ορίζουν ένα κλειστό πολύγωνα που μπορεί να οριστεί ως οικία, αυτές οι οικίες άμα είναι συγκεντρωμένες μαζί αποτελούν τον αστικό ιστό κ.λπ. Αυτές οι οντότητες βοηθούν τους αλγορίθμους της βαθιάς μάθησης να υπολογίσουν την πιθανότητα μια συστάδα από pixel ή γενικότερα ένα σύνολο δεδομένων εισόδου να ανήκουν σε μια κατηγορία.

Βασικό κεφάλαιο της βαθιάς μάθησης με πληθώρα εφαρμογών στην καθημερινότητα, αποτελούν τα αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Networks – RNN). Αξίζει να σημειωθεί πως στην οικογένεια της βαθιάς μάθησης ανήκουν και άλλα νευρωνικά δίκτυα πέραν των αναδρομικών, όπως είναι τα συνελκτικά νευρωνικά δίκτυα (Convolutional neural networks – CNN). Ωστόσο σε αυτή την διπλωματική εργασία, θα γίνει εστίαση αποκλειστικά στα RNN καθώς και σε εξειδικευμένης μορφής αλγορίθμους αυτών, όπως οι αλγόριθμοι LSTM (Long Short-Term Memory), καθώς αποτελούν και το βασικό μοντέλο επίλυσης του προβλήματος. [24] [25].

4.4 Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural networks)

Τα Αναδρομικά Νευρωνικά Δίκτυα (RNN) είναι μία κατηγορία τεχνητών νευρωνικών δικτύων τα οποία αξιοποιούν την τοπολογία, η οποία είναι εμπνευσμένη από τον ανθρώπινο εγκέφαλο, στοχεύοντας στην μάθηση μέσα από τα δεδομένα που τους δίνονται και με την σειρά με την οποία αυτά προσλαμβάνονται, προσπαθώντας να δημιουργήσουν νέο περιεχόμενο βάσει αυτών. Γενικά η ονομασία RNN δίνεται συχνά όταν πρόκειται για δύο κατηγορίες δεδομένων που παρουσιάζουν κοινή δομή, όπου το ένα έχει πεπερασμένη ώθηση ενώ το άλλο άπειρη ώθηση, ενώ και οι δύο παρουσιάζουν δυναμική συμπεριφορά.

Τα RNN είναι σχεδιασμένα για να δουλεύουν με ακολουθιακά δεδομένα, όπως χρονοσειρές, γραφή, φωνή, οπτική πληροφορία, που προκύπτει από μία δράση ή κίνηση. Ο τρόπος λειτουργίας τους διαφέρει από τα απλά νευρωνικά δίκτυα, καθώς στέλνει το τελικό αποτέλεσμα πίσω στον εαυτό του, ενώ τα κελιά που λαμβάνουν αυτά τα αποτελέσματα ονομάζονται κελιά μνήμης. Εφόσον στο νέο νευρώνα εισάγονται δεδομένα από προηγούμενο, αυτό σημαίνει πως υπάρχει μία μορφή μνήμης σε αυτά και ιστορικών δεδομένων.



Εικόνα 11. Αναπαράσταση δικτύων αναδρομικών νευρωνικών δικτύων

Μαθηματικά αυτό χαρακτηρίζεται από την ακόλουθη σχέση, όπου x_t είναι η είσοδος τη χρονική στιγμή t , $f()$ η συνάρτηση που περιγράφει την επίδραση του αναδρομικού νευρωνικού δικτύου στην είσοδο και h_t η έξοδος:

$$h_t = f(x_t, h_{t-1}) = f(x_t, f(x_{t-1}, h_{t-2})) = \dots = (x_t, (x_{t-1}, \dots, (f(x_1, h_0)) \dots))$$

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. Ακόμη, λόγω του προβλήματος που εμφανίζουν, ονομαζόμενο ως εξαφάνιση ή εκτόξευση της κλίσης (vanishing and exploding gradient problem), τα αναδρομικά νευρωνικά δίκτυα κατά τη διαδικασία εκπαίδευσης δεν εντοπίζουν σε ικανοποιητικό βαθμό καλές τιμές για τα βάρη του μοντέλου. Για τους λόγους αυτούς, είναι αναγκαία μία μορφή μακράς μνήμης για τα δίκτυα προκειμένου να διορθωθούν αυτές οι δυσλειτουργίες.

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

Οι νευρώνες μακράς-βραχείας διάρκειας μνήμης (Long Short-Term Memory - LSTM), αποτελούν μία εξειδικευμένη μορφή αλγορίθμων Επαναλαμβανόμενων Νευρωνικών Δικτύων (Recurrent Neural Networks –RNN), οι οποίοι είναι ικανοί να μαθαίνουν βραχυπρόθεσμες εξαρτήσεις, συστήθηκαν από τους Hochreiter & Schmidhuber (1997) και πλέον χρησιμοποιούνται ευρέως για την αντιμετώπιση πληθώρας προβλημάτων. Οι αλγόριθμοι LSTM έχουν σχεδιαστεί έτσι ώστε να αποφύγουν το πρόβλημα της βραχυπρόθεσμης μνήμης και θυμούνται πληροφορίες μεγάλων χρονικών περιόδων [26].

Ένα δίκτυο LSTM είναι μια παραλλαγή του κλασικού μοντέλου RNN, εμπλουτισμένο με αργά μεταβαλλόμενα βάρη για την αντιμετώπιση του προβλήματος της εξαφάνισης της κλίσης από το οποίο πάσχει το RNN. Τα δίκτυα LSTM έχουν εσωτερικούς μηχανισμούς που ονομάζονται πύλες, οι οποίες ρυθμίζουν τη ροή των πληροφοριών, διατηρούν την αξία προς θύμηση πληροφορία και ξεχνούν τις περιττές.

Τα LSTM έχουν παρόμοια δομή με το μοντέλο επαναλαμβανόμενης παλινδρόμησης, αλλά κάθε κόμβος στο κρυφό επίπεδο αντικαθίσταται από ένα κελί μνήμης, αντί για ένα μόνο νευρώνα [27]. Επεξεργάζεται τα διαθέσιμα δεδομένα μεταβιβάζοντας πληροφορίες καθώς αυτές διαδίδονται προς τα εμπρός.

Το κελί μνήμης (Εικόνα 12) περιέχει τρία διαφορετικά στοιχεία: (i) την πύλη λήθης, (ii) την είσοδο πύλη και (iii) η πύλη εξόδου. Κάθε στοιχείο εφαρμόζει μια μη γραμμική σχέση με το εσωτερικό γινόμενο μεταξύ των διανυσμάτων εισόδου και των αντίστοιχων βαρών (εκτιμώνται μέσω μιας εκπαιδευτικής διαδικασίας). Κάποια από τα συστατικά έχουν τη σιγμοειδή συνάρτηση, εκφρασμένη ως $s()$, ενώ άλλα έχουν την υπερβολική εφαπτομένη συνάρτηση, $\tanh()$.

Προσθήκη μηχανισμού «ξέχασης».

Το μοντέλο υιοθετεί μια ξεχωριστή λήθη/θυμητή μηχανισμός; αυτό το τμήμα της κυτταρικής μνήμης LSTM είναι υπεύθυνο για να αποφασίσει ποιο μέρος των πληροφοριών πρέπει να παραλειφθεί.


Προσθήκη μηχανισμού «αποθήκευσης».

Κυρίως, με την έλευση μιας νέας εισόδου, του κυττάρου μνήμης ο μηχανισμός ξεχνά κάθε άχρηστη πληροφορία από προηγούμενους όρους, για να μάθει στη συνέχεια το υπόλοιπο μέρος της εισόδου που εισέρχεται στο μοντέλο.

Εστιάζοντας τη μακροπρόθεσμη μνήμη στη μνήμη εργασίας. Τέλος, ξεχάστε ότι οι πύλες μπορούν να μάθουν και να επαναφέρουν την εσωτερική κατάσταση της κυψέλης μνήμης όταν οι αποθηκευμένες πληροφορίες δεν χρειάζονται πλέον.

Η πύλη λήθης $f(t)$ διαχωρίζει τις πληροφορίες που αξίζει να θυμόμαστε από τις περιττές, κατακρατώντας το τελευταίο έξω από το κελί μνήμης [28]. Ομοίως, ο κόμβος εισόδου $g(t)$ ενεργοποιείται κατάλληλα την αντίστοιχη κατάσταση (αληθής ή ψευδής έξοδος από την ενεργοποίηση \tanh). Η πύλη εισόδου $i(t)$ ρυθμίζει εάν η αντίστοιχη κρυφή κατάσταση είναι «αρκετά σημαντική» για την ακριβή εκτίμηση της κατακόρυφης τιμής TEC (VTEC). Η πύλη εξόδου $o(t)$ ρυθμίζει εάν η απόκριση της τρέχουσας κυψέλης μνήμης είναι "αρκετά σημαντική" ώστε να συνεισφέρει στο επόμενο κύτταρο.

$$\begin{bmatrix} i(t) \\ f(t) \\ o(t) \\ g(t) \end{bmatrix} = \begin{bmatrix} \sigma \\ \sigma \\ \sigma \\ \tanh \end{bmatrix} W \begin{bmatrix} x(t) \\ h(t-1) \end{bmatrix} + \begin{bmatrix} b_f \\ b_g \\ b_o \\ b_i \end{bmatrix}$$



Εικόνα 12. Μνήμη κελιού ενός LSTM δικτύου

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. Στην προσέγγισή μας προσπαθούμε να μοντελοποιήσουμε καθημερινές παραλλαγές της ιονόσφαιρας και όχι αντίστοιχες μακροπρόθεσμες.

Κεφάλαιο 5^ο Η γλώσσα προγραμματισμού Python

5.1 Γενικά για την γλώσσα προγραμματισμού Python

Για την εκπόνηση της συγκεκριμένης διπλωματικής εργασίας χρησιμοποιήθηκε η γλώσσα προγραμματισμού Python και συγκεκριμένα Python 3.6.

Η Python είναι διερμηνεύσιμη (interpreted), γενικού σκοπού (general-purpose) και υψηλού επιπέδου, γλώσσα προγραμματισμού. Ανήκει στις γλώσσες προστακτικού προγραμματισμού (Imperative programming) και υποστηρίζει τόσο το διαδικαστικό (procedural programming) όσο και το αντικειμενοστραφές (object-oriented programming) προγραμματιστικό υπόδειγμα (programming paradigm). Είναι δυναμική γλώσσα προγραμματισμού (dynamically typed) και υποστηρίζει συλλογή απορριμμάτων (garbage collection ή GC)[54], [55].

Δημιουργήθηκε από τον Ολλανδό Γκίντο βαν Ρόσσουμ (Guido van Rossum) στο ερευνητικό κέντρο Centrum Wiskunde & Informatica (CWI) το 1989 και κυκλοφόρησε για πρώτη φορά το 1991.

Ο κύριος στόχος της είναι η αναγνωσιμότητα του κώδικά της και η ευκολία χρήσης της. Το συντακτικό της, επιτρέπει στους προγραμματιστές να εκφράσουν έννοιες σε λιγότερες γραμμές κώδικα από ότι θα ήταν δυνατόν σε γλώσσες όπως η C++ ή η Java. Διακρίνεται λόγω του ότι έχει πολλές βιβλιοθήκες που διευκολύνουν ιδιαίτερα αρκετές συνηθισμένες εργασίες και για την ταχύτητα εκμάθησής της. Μειονεκτεί στο ότι επειδή είναι διερμηνεύσιμη 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.

Η Python αποτελεί μία εύκολη στην κατανόηση της γλώσσα προγραμματισμού, κυρίως λόγω της εύκολης ανάγνωσής της. Χρησιμοποιεί αγγλικούς χαρακτήρες και δεν χρησιμοποιεί τονισμούς. Σε σχέση με άλλες γλώσσες προγραμματισμού, δεν χρησιμοποιεί αγκύλες και τα ερωτηματικά μετά τις δηλώσεις επιτρέπονται αλλά είναι σπάνια. Σύμφωνα με τον Guido Van Rossum « Το όμορφο είναι καλύτερο από το άσχημο»

Η γλώσσα αυτή είναι ανοιχτού λογισμικού και διατίθεται από τον μη κερδοσκοπικό οργανισμό Python Software Foundation. Ο κώδικας διανέμεται με την άδεια Python Software Foundation License η οποία είναι συμβατή με την GPL (Γενική Άδεια Δημόσιας Χρήσης GNU) [54].

Για να εκτελεστούν διαδραστικά (interactively) μεμονωμένες εντολές ή προγράμματα είναι απαραίτητη η εγκατάσταση του διερμηνυτή της Python, ο οποίος είναι ελεύθερα διαθέσιμος για «κατέβασμα» (download) από τον επίσημο ιστότοπό της (www.python.org). Για Microsoft Windows υπάρχουν εκδόσεις των 32 ή 64 bits. Στα λειτουργικά συστήματα Linux και Mac OS X συνηθίζεται να είναι προεγκατεστημένη, πιθανότατα όμως να είναι μια παλαιότερη έκδοσή της[54].

Για την υλοποίηση της γλώσσας προγραμματισμού, είναι απαραίτητος ένας κειμενογράφος, είτε ένα ολοκληρωμένο περιβάλλον ανάπτυξης (Integrated Development Environment – IDE), το οποίο αποτελεί λογισμικό για την ανάπτυξη των εφαρμογών. Η Python, συνοδεύεται από ένα απλό περιβάλλον ανάπτυξης με την ονομασία IDLE (Interactive DeveLopment Environment). Το περιβάλλον αυτό είναι γραμμένο σε Python από τον Guido Van Rossum, χρησιμοποιεί τη βιβλιοθήκη γραφικών Tkinter, οπότε μπορεί να εκτελεσθεί σε περιβάλλον Linux, Windows και Mac OS X. Δίνει τη δυνατότητα να χρησιμοποιείται διαδραστικά ο διερμηνευτής της γλώσσας, να γραφτούν και να επεξεργαστούν και να εκτελεστούν προγράμματα, καθώς επίσης εκτελείται η διαδικασία της αποσφαλμάτωσης (debugging). [54]. Υπάρχει πληθώρα περιβάλλοντων ανάπτυξης που διατίθενται για κάθε τύπο λειτουργικού συστήματος (Windows, Linux, Mac OS X και άλλα), μερικά από αυτά είναι το PyCharm, Spyder, IDLE, Microsoft Visual Studio, PyDev, Eclipse και άλλα.

5.2 Η συμβολή της γλώσσας Python στην ανάπτυξη του δικτύου: Google Colaboratory

Στην παρούσα εργασία, για την εκπόνησή της, χρησιμοποιείται το διαδραστικό περιβάλλον προγραμματισμού (Interactive Python Programming Environment), Google Colaboratory (Google Colab). Το Google Colab, αποτελεί ένα προϊόν της Google Research που επιτρέπει στους προγραμματιστές να γράφουν και να εκτελούν κώδικες γλώσσας προγραμματισμού Python, μέσω του προγράμματος περιήγησής τους. Το περιβάλλον αυτό αποτελεί εξαιρετικό εργαλείο για εργασίες που απαιτούν βαθιά μάθηση. Ουσιαστικά, είναι μία εξειδικευμένη μορφή του Jupyter notebook, που δεν χρειάζεται κάποια εγκατάσταση. Το Google Colab, αποτελεί ένα κατά βάση ανοιχτό περιβάλλον προγραμματισμού, προσφέροντας υπολογιστικούς πόρους, όπως GPU και TPU, οι οποίες αποτελούν μονάδες επεξεργασίας γραφικών και μειώνουν σημαντικά τον χρόνο που απαιτείται για την εκτέλεση ενός προγράμματος. 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. [59].

5.3 Σημαντικές βιβλιοθήκες Python που χρησιμοποιήθηκαν

Ο λόγος που χρησιμοποιήθηκε η συγκεκριμένη γλώσσα προγραμματισμού είναι, πρώτον ο χαρακτήρας της ως μια ανοιχτού κώδικα γλώσσα προγραμματισμού, που σημαίνει πως για την εγκατάστασή της και την λειτουργία της έχει μηδενικό κόστος. Το δεύτερο και σημαντικότερο πλεονέκτημα, της γλώσσας είναι η δυνατότητα προγραμματισμού νευρωνικών δικτύων με την βιβλιοθήκη tensorflow και το application programming interface (API) του το Keras.

Το **TensorFlow** [60], 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** [62], 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 Keras με λίγα λόγια είναι μια πλατφόρμα:

- **Απλή - αλλά όχι απλοϊκή.** Το Keras μειώνει το γνωστικό φορτίο του προγραμματιστή για να ελευθερώσει τον ερευνητή και να τον βοηθήσει να εστιάσει με ευκολία στα μέρη του προβλήματος που πραγματικά έχουν σημασία.
- **Ευέλικτη** - Το Keras υιοθετεί την αρχή της προοδευτικής αποκάλυψης της πολυπλοκότητας: οι απλές ροές εργασίας πρέπει να είναι γρήγορες και εύκολες, ενώ αυθαίρετα προηγμένες ροές εργασίας θα πρέπει να είναι δυνατές μέσω μιας σαφούς διαδρομής που βασίζεται σε αυτό που είναι ήδη γνωστό.
- **Ισχυρή** - Το Keras παρέχει απόδοση και επεκτασιμότητα στη βιομηχανία: χρησιμοποιείται από οργανισμούς και εταιρείες.

Άλλες βιβλιοθήκες που χρησιμοποιήθηκαν ήταν η Pandas, η NumPy και η Matplotlib.

Η βιβλιοθήκη **Pandas** [60] 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** [56], αποτελεί μια βιβλιοθήκη της python η οποία υλοποιήθηκε με στόχο την επεξεργασία και την διαχείριση μαθηματικών προβλημάτων μέσω της δομής πινάκων. 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** [64] 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 [64]. Στην εργασία, χρησιμοποιείται με σκοπό να αποδοθούν τα απαραίτητα γραφήματα.

5.4 Υλοποίηση σε Python

5.4.1 Εκπαίδευση δικτύου

Γνωρίζοντας την συνεισφορά των βιβλιοθηκών της γλώσσας Python στο ακόλουθο κεφάλαιο θα γίνει εκτενής ανάλυση των συναρτήσεων που χρησιμοποιήθηκαν για την υλοποίηση του αλγορίθμου.



```
#path = "/content/drive/MyDrive/dedomena/feb_1.csv"  
#Data = pd.read_csv(path, sep=",")
```

Αρχικά διαβάζονται τα δεδομένα για τον κάθε μήνα. από το path και τα εισάγουμε σε ένα pandas dataframe



```
InputDataFrame = Data[[ ... ]  
OutputDataFrame = Data[['stec']]  
OutputDataFrame = Data[['vtec']]
```

Στην συνέχεια επιλέγουμε για κάθε σενάριο τις μεταβλητές που θα δέχεται το δίκτυο ως είσοδο και ως έξοδο. Οι παράμετροι έχουν εξηγηθεί στο κεφάλαιο 3.



```
max_values = dict.fromkeys(InputVariables)  
for i in InputVariables:  
  
    InputDataColumn = InputDataFrame[i]  
    max_values[i] = InputDataColumn.max()
```

Με τη συγκεκριμένη εντολή, οι μεγιστες τιμές υποθηκεύονται για κάθε χαρακτηριστικό εισόδου (input ariable) στο dictionary max value



```

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

```

Με αυτή την εντολή μετατρέπονται τα δεδομένα σε πίνακα numpy.



```

InputArrayNormalized = np.empty([InputArray.shape[0], InputArray.shape[1]])
OutputArrayNormalized = np.empty([OutputArray.shape[0], OutputArray.shape[1]])

for i in range(0,11):
    invar = InputVariables[i]
    InputArrayNormalized[:,i] = InputArray[:,i]/max_values[invar]

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

```

Τα δεδομένα στη συνέχεια κανονικοποιούνται διαιρώντας για κάθε τιμή την μέγιστη κάθε κατηγορίας.



```

IntermediateArrayNormalized = np.empty([(InputArray.shape[0]-
7), 7])
Input3DArrayNormalized = np.empty([(InputArray.shape[0]-
7), 7])
for i in range(0,11):
    invar = InputVariables[i]
    for j in range(0,(InputArray.shape[0]-7)):
IntermediateArrayNormalized[j,:] = InputArrayNormalized[j:j+7,
i]

Input3DArrayNormalized =np.dstack((Input3DArrayNormalized, Int
ermidiateArrayNormalized))

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(OutputArrayNormal
                                             ized[j:j + 7])
Y = Output3DArrayNormalized.reshape(Output3DArrayNormalized.sh
                                     ape[0], Output3DArrayNormalized.shape[1], 1)

```

Τα δεδομένα στη συνέχεια φορτώνονται σε τρισδιάστατους τανυστές με βάθος 7 ημερών

Από προεπιλογή, η έξοδος ενός επιπέδου RNN περιέχει ένα μόνο διάνυσμα ανά δείγμα. Αυτό το διάνυσμα είναι η έξοδος κελιών RNN που αντιστοιχεί στο τελευταίο χρονικό βήμα, που περιέχει πληροφορίες για ολόκληρη την ακολουθία εισόδου. Το σχήμα αυτής της εξόδου είναι (batch_size, units) όπου οι μονάδες αντιστοιχούν στο όρισμα μονάδων που μεταβιβάστηκε στον κατασκευαστή του επιπέδου.

Ένα επίπεδο RNN μπορεί επίσης να επιστρέψει ολόκληρη την ακολουθία εξόδων για κάθε δείγμα (ένα διάνυσμα ανά χρονικό βήμα ανά δείγμα), εάν ορίσετε return_sequences=True. Το σχήμα αυτής της εξόδου είναι (batch_size, timesteps, units).



```

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]

```

Τέλος οι χρονοσειρές βάθους 7 ημερών «ανακατεύονται» μέχρι το τέλος του dataset



```

hidden_units= 64
conv_filters = 64
epochs = 100

```

Με αυτή την εντολή πραγματοποιείται η εισαγωγή των βασικών παραμέτρων των νευρωνικών δικτύων. Πιο συγκεκριμένα αναγράφονται τα φίλτρα-υπερπαραμέτροι που θα χρησιμοποιηθούν στα δεδομένα εισόδου (64) και ο αριθμός των εποχών (100).

🚩 Ακολουθεί το δίκτυο RNN και η αρχιτεκτονική του

`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((SimpleRNN(hidden_units, return_sequences=True)))`

`model_simpleRNN.add((SimpleRNN(X.shape[1], return_sequences=True)))`

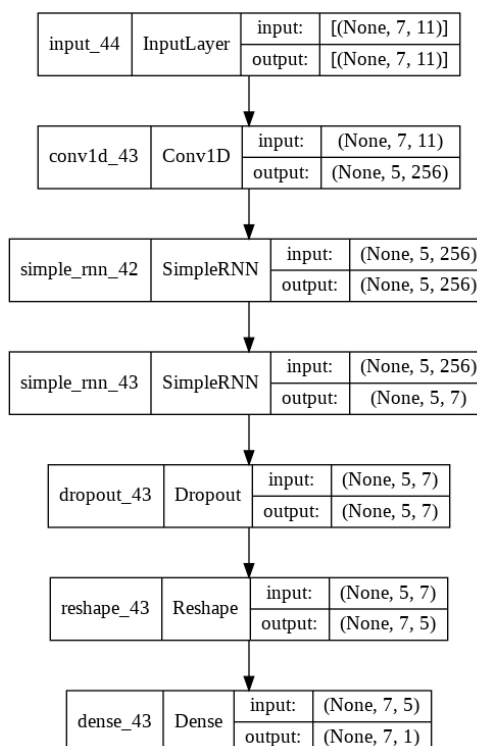
`model_simpleRNN.add(Dropout(0.1))`

`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())`

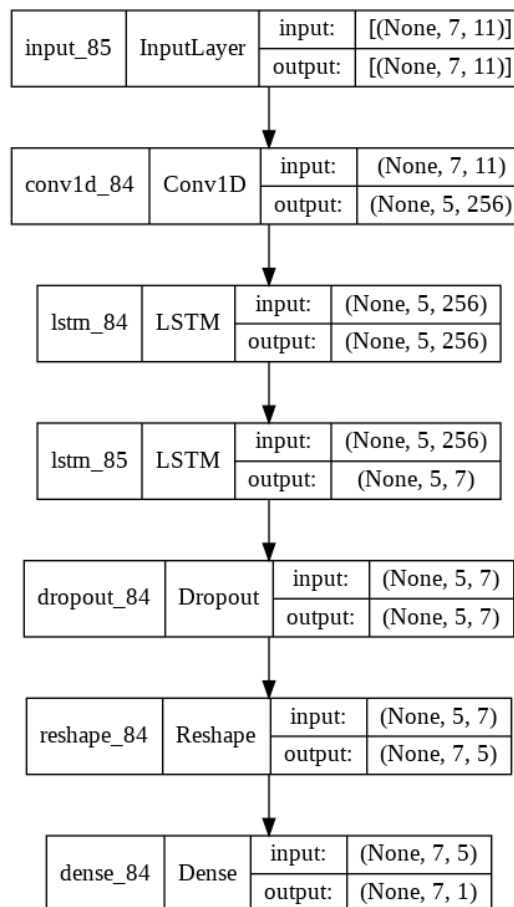


✚ Ομοίως το δίκτυο LSTM και η αρχιτεκτονική του

```

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())

```



Οι βασικότερες εντολές που καθιστούν λειτουργικά αυτά τα δυο νευρωνικά δίκτυα αποτελούν τις ακόλουθες 2 :

Για το LSTM δίκτυο:

➤ `model_LSTM.add(Conv1D(conv_filters, 3, activation='relu')) # convolutional layer`

δηλαδή 1D επίπεδο συνέλιξης (π.χ. χρονική συνέλιξη).

Αυτό το επίπεδο δημιουργεί έναν πυρήνα συνέλιξης που συνελίσσεται με την είσοδο του στρώματος σε μια ενιαία χωρική (ή χρονική) διάσταση για την παραγωγή ενός τανυστή εξόδου. Εάν το `use_bias` είναι `True`, δημιουργείται ένα διάνυσμα πόλωσης και προστίθεται στις εξόδους. Τέλος, αν η ενεργοποίηση δεν είναι `None`, εφαρμόζεται και στις εξόδους.

Όταν χρησιμοποιείται αυτό το επίπεδο ως το πρώτο επίπεδο σε ένα μοντέλο, παρέχεται ένα όρισμα `input_shape` (πλήθος ακεραίων ή Κανένα), π.χ. (10, 128) για ακολουθίες 10 διανυσμάτων διανυσμάτων 128 διαστάσεων ή (Κανένα, 128) για μεταβλητό μήκος ακολουθίες διανυσμάτων 128 διαστάσεων.

Επιχειρήματα:

- **filters:** Ακέραιος, η διάσταση του χώρου εξόδου (δηλαδή ο αριθμός των φίλτρων εξόδου στη συνέλιξη).
- **kernel_size:** Ένας ακέραιος ή πλειάδα/λίστα ενός μόνο ακέραιου, που καθορίζει το μήκος του παραθύρου συνέλιξης 1D.
- **strides:** Ένας ακέραιος ή πλειάδα/λίστα ενός μόνο ακέραιου αριθμού, που καθορίζει το μήκος του βήματος της συνέλιξης. Ο καθορισμός οποιασδήποτε τιμής διασκελισμού $\neq 1$ δεν είναι συμβατός με τον καθορισμό οποιασδήποτε τιμής διαστολής ρυθμού $\neq 1$.
- **padding:** Ένα από τα "έγκυρο", "ίδιο" ή "αιτιακό" (χωρίς διάκριση πεζών-κεφαλαίων). "έγκυρο" σημαίνει χωρίς γέμιση. Το "ίδιο" έχει ως αποτέλεσμα την πλήρωση με μηδενικά ομοιόμορφα αριστερά/δεξιά ή πάνω/κάτω της εισόδου έτσι ώστε η έξοδος να έχει την ίδια διάσταση ύψους/πλάτους με την είσοδο. Το "αιτιακό" έχει ως αποτέλεσμα αιτιακές (διασταλμένες) συνελίξεις, π.χ. Η έξοδος[t] δεν εξαρτάται από την είσοδο[t+1:]. Χρήσιμο κατά τη μοντελοποίηση χρονικών δεδομένων όπου το μοντέλο δεν πρέπει να παραβιάζει τη χρονική σειρά.
- **data_format:** Μια συμβολοσειρά, ένα από το `channels_last` (προεπιλογή) ή το `channels_first`.
- **dilation_rate:** ένας ακέραιος ή πλειάδα/λίστα ενός μόνο ακέραιου αριθμού, που καθορίζει τον ρυθμό διαστολής που θα χρησιμοποιηθεί για διευρυμένη συνέλιξη. Επί του παρόντος, ο καθορισμός οποιασδήποτε τιμής `dilation_rate` $\neq 1$ δεν είναι συμβατός με τον καθορισμό οποιασδήποτε τιμής βηματοδότησης $\neq 1$.
- **groups:** Ένας θετικός ακέραιος αριθμός που καθορίζει τον αριθμό των ομάδων στις οποίες η είσοδος χωρίζεται κατά μήκος του άξονα του καναλιού. Κάθε ομάδα συνδυάζεται χωριστά με φίλτρα / φίλτρα ομάδων. Η έξοδος είναι η

συνένωση όλων των αποτελεσμάτων των ομάδων κατά μήκος του άξονα του καναλιού. Τα κανάλια εισόδου και τα φίλτρα πρέπει να διαίρονται με ομάδες.

- **activation:** Λειτουργία ενεργοποίησης προς χρήση. Εάν δεν καθορίσετε τίποτα, δεν εφαρμόζεται καμία ενεργοποίηση
- **use_bias:** Boolean, εάν το επίπεδο χρησιμοποιεί ένα διάνυσμα πόλωσης.
- **kernel_initializer:** Initializer for the **kernel** weights matrix (see [keras.initializers](#)). Defaults to 'glorot_uniform'.
- **bias_initializer:** Initializer για τον πίνακα βαρών πυρήνα (βλ. [keras.initializers](#)). Οι προεπιλογές είναι «glorot_uniform».
- **kernel_regularizer:** Η συνάρτηση ρυθμιστή που εφαρμόζεται στον πίνακα βαρών πυρήνα
- **bias_regularizer:** Η συνάρτηση ρυθμιστή που εφαρμόζεται στο διάνυσμα πόλωσης
- **activity_regularizer:** Η λειτουργία ρυθμιστή εφαρμόζεται στην έξοδο του στρώματος.
- **kernel_constraint:** Συνάρτηση περιορισμού που εφαρμόζεται στον πίνακα πυρήνα.
- **bias_constraint:** Συνάρτηση περιορισμού που εφαρμόζεται στο διάνυσμα πόλωσης

➤ `model_LSTM.add((LSTM(hidden_units, return_sequences=True)))`

➤ `model_LSTM.add((LSTM(X.shape[1], return_sequences=True)))`

Ομοίως για το δίκτυο RNN

➤ `model_simpleRNN.add((SimpleRNN(hidden_units, return_sequences=True)))`

➤ `model_simpleRNN.add((SimpleRNN(X.shape[1], return_sequences=True)))`

Σημειώνεται πως για την ταχύτερη εκτέλεση όλων των πειραμάτων οι υπερπαράμετροι δίνονται στην αρχή του κώδικα

5.4.2 Έλεγχος δικτύου

Για τον έλεγχο του δικτύου χρησιμοποιήθηκε ο κάτωθι κώδικας με τον οποίο υπολογίζεται το Mean Square Error (MSE) και το Mean Absolute Error (MAE)

```
# 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))
```

5.4.3 Οπτικοποίηση αποτελεσμάτων

Για την οπτικοποίηση των γραφημάτων χρησιμοποιήθηκε η βιβλιοθήκη matplotlib. Το Matplotlib είναι μια ολοκληρωμένη βιβλιοθήκη για τη δημιουργία στατικών, κινούμενων και διαδραστικών απεικονίσεων στην Python. Το Matplotlib κάνει τα εύκολα πράγματα εύκολα και τα δύσκολα δυνατά.

```
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()
```

```
import matplotlib.pyplot as plt
x = yh
y = yg
plt.scatter(x, y, label = "test set predictions")
plt.ylabel(" Predicted STEC")
plt.xlabel(" Ground truth STEC")
plt.legend()
plt.show()
```

Ο παραπάνω κώδικας χρησιμοποιείται για την οπτικοποίηση των αποτελεσμάτων στο σετ ελέγχου, όπου πλοτάρει σε διάγραμμα διασποράς τις πραγματικές τιμές προς τις προβλεπόμενες από το δίκτυο.

Αναλυτικά ο κώδικας και για τα δύο νευρωνικά δίκτυα, για τιμές stec και για vtec παρατίθενται στο Παράρτημα Γ της παρούσης διπλωματικής εργασίας.

Κεφάλαιο 6^ο Πειραματική διαχείριση – Περιγραφή και επεξεργασία αρχικών 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.

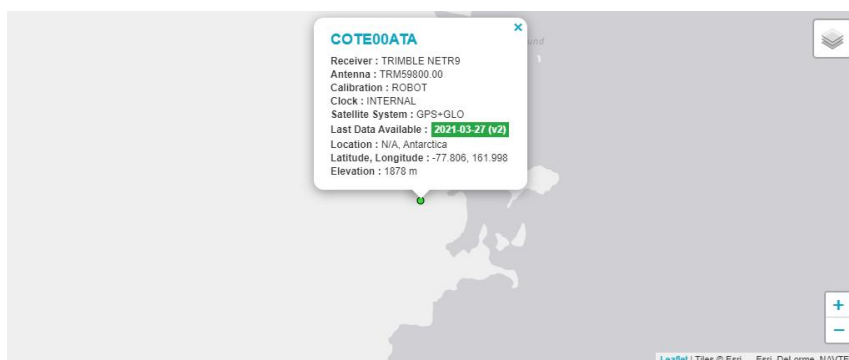
6.2 Περιγραφή των δεδομένων

6.2.1 Observation Files του σταθμού COTE00ATA

Στην παρούσα διπλωματική εργασία ακολουθήθηκαν κάποια συγκεκριμένα βήματα.

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.

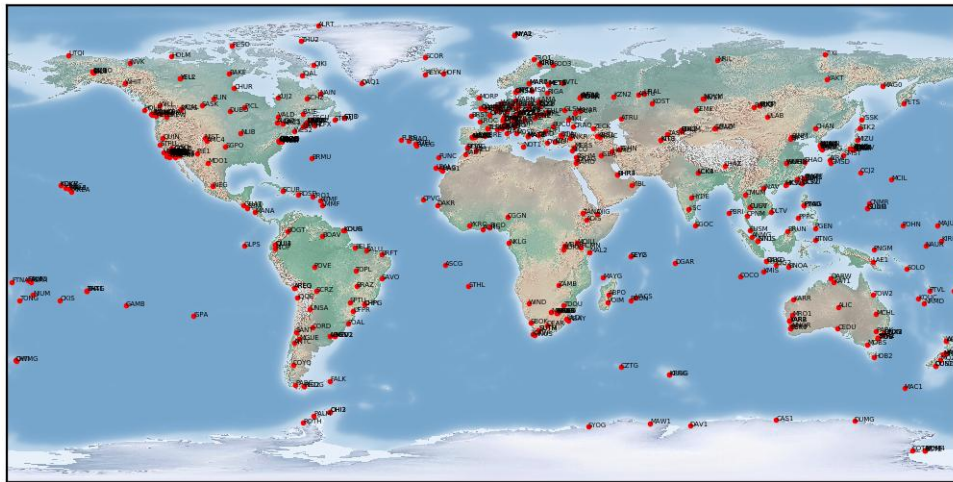


Εικόνα 13. Σταθμός COTE00ATA (Πηγή: IGS)

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 ανθρωπίνες παρεμβάσεις (κατασκευές, δίκτυα τηλεφωνίας κτλ)



Εικόνα 14. 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 (Εικόνα 15) 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 SCS.8 -xarch=amd64|+=|+=|
0.000      (antenna height)      COMMENT
-77.80590314 (latitude)      COMMENT
+161.99781078 (longitude)      COMMENT
1878.374 (elevation)      COMMENT
$IT 2 OF LLI FLAGS DATA COLLECTED UNDER A/S CONDITION
COTE      MARKER NAME
56096M001  MARKER NUMBER
Terry Wilson Ohio State University OBSERVER / AGENCY
5034K69672 TRIMBLE NETR9 5.10 REC # / TYPE / VERS
4852A62823 TRMS9800.00 SC15 ANT # / TYPE
-1285757.4165 417822.4915 -6214230.8474 APPROX POSITION XYZ
0.0000 0.0000 0.0000 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 Decimation 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 or 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/TSGT5KGN COMMENT
End of DB comments COMMENT
$SR 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
G25R23G19G12R16G02G06R14G24G03
112379164.792 8 87406084.335 7 21000737.836 21000740.309 21000736.313
48.500 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 15. Τυπική μορφή αρχείου RINEX.

6.2.1.1 CDDIS

Το Crustal Dynamics Data Information System (CDDIS) 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) 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) 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 Hatanaka 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_GOPi [29]

Εν συνεχεία με τη χρήση του προγράμματος GBS_GOpI, 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 Εικόνα 16 παρουσιάζεται η συμπεριφορά των τιμών TEC ανά ώρα με βάση το γεωγραφικό πλάτος.



Εικόνα 16.Συμπεριφορά των τιμών TEC ανά ώρα με βάση το γεωγραφικό πλάτος

Στη συνέχεια της επεξεργασίας των δεδομένων προκύπτουν τα αποτελέσματα της Εικόνας 17. 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 .

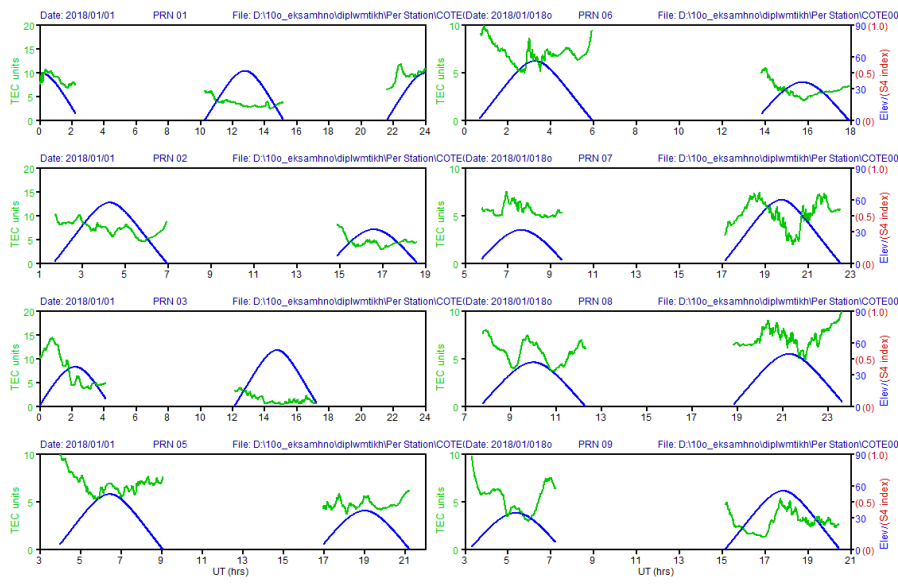


Εικόνα 17. Τιμές TEC ανά Δορυφόρο

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 18. 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 18. 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

Όπως υποδηλώνει και ο τίτλος της παρούσας διπλωματικής εργασίας για την πρόβλεψη της ιονοσφαιρικής δραστηριότητας, χρησιμοποιήθηκαν ως τιμές εισόδου, τιμές των 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)	ap	D	SML	SMJ	Fluxtime	Fluxmjlan	Fluxcarriington	Fluxbobusflux	Fluxaoflux	Fluxusrs	Daily Total Sunspot Number	Daily North Sunspot Number	Daily South Sunspot Number	Standard Deviation of New Daily Total Sunspot Data	Standard Deviation of New Daily North Sunspot Data	Standard Deviation of New Daily South Sunspot Data	Number of Observations for Daily Total Sunspot Number	Number of Observations for Daily North Sunspot Number	Number of Observations for Daily South Sunspot Number
0	11.387	5.032296	4	2.687	12	1	-98.39444	13.3	0	F	2458149.9875	2200.45	89.15	79.25	62.825	12	12	0	1.1	0.3	0	39	6	
3	13.92384	4.205202	4	0.333	2	1	-50.03333	30.893333	3	F	2458149.9875	2200.4275	86.475	73.125	77.1	12	12	0	1.1	0.3	0	39	6	
6	12.55902	5.767602	4	0.333	2	1	-32.01667	40.488889	6	F	2458149.738	2200.405	84.2	74	75.45	12	12	0	1.1	0.3	0	39	6	
9	8.89971	5.917169	4	0.333	2	1	-26.26111	40.716667	9	F	2458150.1125	2200.3825	81.725	77.875	78.4	12	12	0	1.1	0.3	0	39	6	
12	7.100499	2.999661	4	0.333	2	1	-26.33889	34.016667	12	F	2458150.089	2200.36	79.25	76.75	72.15	12	12	0	1.1	0.3	0	39	6	
15	7.448446	1.124223	4	0	0	1	-21.57222	41.338889	15	F	2458150.8675	2200.3375	76.775	75.625	70.5	12	12	0	1.1	0.3	0	39	6	
18	10.12964	1.74801	4	1.333	5	1	-70.20336	40.488889	18	F	2458151.239	2200.295	89.3	80.3	80.9	12	12	0	1.1	0.3	0	39	6	
21	11.48287	1.846976	4	1.333	5	1	-98.03889	30.866667	21	F	2458151.364	2200.2995	89.15	87.15	80.4	12	12	0	1.1	0.3	0	39	6	
0	11.02461	6.127965	4	2	7	1	-114.7	56.794444	0	F	2457985.548	2194.11445	84.15	79.95	72.6	15	15	0	1.3	0.6	0	42	5	
3	14.5009	6.71257	4	1	4	1	-47.8	64.333333	3	F	2458008.167	2194.94725	82.125	78.225	70.95	15	15	0	1.3	0.6	0	42	5	
6	13.37796	5.899511	4	0.667	3	1	-45.22222	70.855556	6	F	2458030.782	2195.7786	80.1	76.5	69.5	15	15	0	1.3	0.6	0	42	5	
9	10.22784	4.946613	4	0.667	3	1	-40.60256	47.805556	9	F	2458053.399	2196.609675	78.075	74.775	67.65	15	15	0	1.3	0.6	0	42	5	
12	7.644871	1.446722	4	0.667	3	1	-56.03333	31.05	12	F	2458076.026	2197.44075	76.05	73.05	66	15	15	0	1.3	0.6	0	42	5	
15	7.847871	1.405064	4	0.333	2	1	-35.47778	20.983333	15	F	2458098.633	2198.271825	74.025	71.325	64.35	15	15	0	1.3	0.6	0	42	5	
18	10.48238	1.209906	4	0.333	2	1	-48.37222	39.838889	18	F	2458121.25	2199.1029	72	69.6	62.7	15	15	0	1.3	0.6	0	42	5	
21	12.71279	1.157182	4	0	0	1	-17.06667	27.016667	21	F	2458131.364	2200.2095	69.15	67.15	60.4	15	15	0	1.3	0.6	0	42	5	
0	14.90846	6.999549	3	0.333	2	1	-20.96667	28.45	0	F	2458156.988	2200.413	75.75	74.3	66.6	16	16	0	2.1	0	0	39	9	
3	16.25384	7.33952	3	0.333	2	1	-23.96667	27.311111	3	F	2458156.363	2200.3905	74.775	73.25	65.7	16	16	0	2.1	0	0	39	9	
6	16.28789	7.472127	3	1	4	1	-51.16667	27.4	6	F	2458156.788	2200.368	71.8	72.2	64.8	16	16	0	2.1	0	0	39	9	
9	12.49902	5.881206	3	1	4	1	-93.96667	30.4	9	F	2458155.113	2200.3455	72.825	71.15	63.9	16	16	0	2.1	0	0	39	9	
12	9.00854	1.987227	3	0.333	2	1	-28.56667	28.027778	12	F	2458154.489	2200.333	71.85	71.1	63	16	16	0	2.1	0	0	39	9	
15	8.07335	3.326919	3	0.333	2	1	-49.22778	25.411111	15	F	2458155.864	2200.3005	70.975	69.05	62.1	16	16	0	2.1	0	0	39	9	
18	11.09977	5.05291	3	1.667	6	1	-92.10556	35.222222	18	F	2458153.239	2200.278	69.9	68	61.2	16	16	0	2.1	0	0	39	9	
21	14.01269	6.702707	3	1.333	3	1	-52.03333	31.666667	21	F	2458152.624	2200.2655	68.925	66.95	60.3	16	16	0	2.1	0	0	39	9	
0	15.02241	6.942085	3	0.667	3	1	-63.18889	25.911111	0	F	2458157.988	2200.45	71.4	69.4	62.6	0	0	0	0	0	0	0	41	33
3	16.34994	7.132741	3	0	0	1	-23.27222	27.166667	3	F	2458157.383	2200.4275	71.25	69.25	62.45	0	0	0	0	0	0	0	41	33
6	15.68616	7.118461	3	0	0	1	-52.17222	26.338889	6	F	2458156.788	2200.405	71.1	69.1	62.3	0	0	0	0	0	0	0	41	33
9	11.48895	5.051058	3	0.333	2	1	-25.20556	28.438889	9	F	2458156.113	2200.3825	70.95	68.95	62.15	0	0	0	0	0	0	0	41	33
12	7.88413	1.242493	3	0.333	2	1	-16.47778	26.372222	12	F	2458153.489	2200.36	70.8	68.8	62	0	0	0	0	0	0	0	41	33
15	8.82079	1.718831	3	1	4	1	-93.38889	28.311111	15	F	2458154.864	2200.3375	70.65	68.65	61.85	0	0	0	0	0	0	0	41	33
18	9.864578	1.819399	3	2.333	9	1	-129.36111	48.394444	18	F	2458154.239	2200.315	70.5	68.5	61.7	0	0	0	0	0	0	0	41	33
21	13.93468	6.378819	3	1	4	1	-16.93997	37.394444	21	F	2458153.624	2200.2925	70.35	68.35	61.55	0	0	0	0	0	0	0	41	33
0	18.50056	10.22966	8	2.667	12	1	-118.07778	46.494444	0	F	2458158.988	2200.4915	89.15	86.6	78.05	0	0	0	0	0	0	0	47	41
3	18.83089	9.931878	8	2	7	1	-57.3	42.216667	3	F	2458158.383	2200.4825	86.675	84.2	78.875	0	0	0	0	0	0	0	47	41
6	17.9389	9.577352	8	2	7	1	-126.36667	51.666667	6	F	2458157.788	2200.445	84.2	81.8	79.7	0	0	0	0	0	0	0	47	41
9	10.80384	6.100525	8	1.667	6	1	-143.77778	52.066667	9	F	2458157.113	2200.42175	81.725	79.4	71.525	0	0	0	0	0	0	0	47	41
12	7.433514	4.273262	8	3	15	1	-39.85	77.827778	12	F	2458156.489	2200.3985	79.25	77	69.35	0	0	0	0	0	0	0	47	41
15	6.904499	1.891605	8	2.333	9	1	-125.7944	62.361111	15	F	2458155.864	2200.37625	78.775	76.6	67.175	0	0	0	0	0	0	0	47	41
18	9.19237	1.178892	8	1	4	1	-88.22778	34.855556	18	F	2458155.239	2200.352	74.3	72.2	65	0	0	0	0	0	0	0	47	41
21	12.29593	7.084651	8	0.333	2	1	-14.19333	23.4	21	F	2458154.624	2200.32875	71.825	69.8	64.8	0	0	0	0	0	0	0	47	41

Για το σωστό έλεγχο και την αξιοπιστία του προς εκπαίδευση νευρωνικού δικτύου αποφασίστηκε η πραγματοποίηση αρκετών 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):
#iii ii ii ff,f ff,ff fffff,fffff fffff,fffff ff,fff iiiii 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 19. 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 13).



Εικόνα 20. 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 14.

<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 21. 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 Kyoto. 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 χιλιοστά 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 22. 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 = 10-22W m-2 Hz-1). Τα αρχεία είναι txt της μορφής:

- Ημερομηνία καταγραφής
- Ωρα
- 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	2458149.36275	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 23. 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:

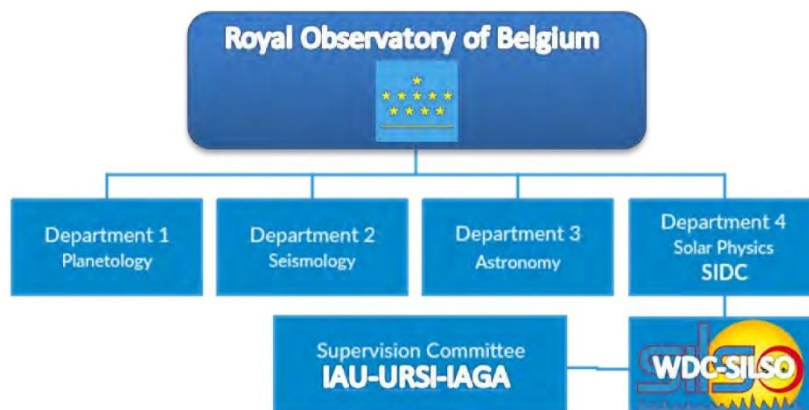
- Ημερομηνία
- Ημερήσιος συνολικός αριθμός ηλιακών κηλίδων
- Ημερήσιος αριθμός βόρειων ηλιακών κηλίδων
- Ημερήσιος αριθμός νότιων ηλιακών κηλίδων
- Τυπική απόκλιση των ακατέργαστων ημερήσιων συνολικών δεδομένων ηλιακών κηλίδων

- 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 24. Υπόδειγμα δεδομένων Sunspot Number



Εικόνα 25. 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.

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 28.

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/s]	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 05:48:05	315	28	100	182	369	5.8*1	2.4e+15	1.2e+29	301	C2 PHTX C3 DST Java	Very Poor Event
2018/01/02 12:05	48	12	377	307	0	-67.5*1	----	----	51	C2 PHTX C3 DST Java	Very Poor Event; Only C2
2018/01/03 12:05	104	9	244	301	355	4.0*1	----	----	111	C2 PHTX C3 DST Java	Poor Event
2018/01/04 03:48:05	278	26	128	175	402	6.4*1	4.6e+13	3.7e+27	276	C2 PHTX C3 DST Java	Very Poor Event; Only C2
2018/01/04 20:24:05	191	39	241	394	782	25.0*1	5.8e+13	1.7e+28	192	C2 PHTX C3 DST Java	Poor Event

Εικόνα 28. 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 1. 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 1 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 τριώρα 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 1). Τέλος, παρήχθησαν 3 αρχεία xlsx για κάθε μήνα ώστε να μπορεί να χρησιμοποιηθεί από τα προγράμματα RNN και LSTM.

Κεφάλαιο 7^ο Χρήση παραμέτρων δεδομένων TEC – Σενάρια και αξιολόγηση αυτών

Το αποθετήριο δεδομένων περιέχει τιμές από οκτώ (8) παραμέτρους, όπως αυτές παρουσιάστηκαν στον Πίνακα 1 του Κεφαλαίου 3. Για την εύρεση του βέλτιστου συνδυασμού των εν λόγω παραμέτρων πραγματοποιήθηκαν επτά (7) σενάρια συνδυασμού αυτών, για τους μήνες όπου είχαν συλλεχθεί δεδομένα (Ιανουάριος, Φεβρουάριος, Μάρτιος) και για την εξαγωγή αποτελεσμάτων STEC και VTEC αντίστοιχα.

Στον ακόλουθο πίνακα παρουσιάζονται ο αριθμός των σεναρίων και οι παράμετροι που χρησιμοποιήθηκαν στο καθένα από αυτά.

Πίνακας 3. Σενάρια για επιλογή καταλληλότερων παραμέτρων

ΣΕΝΑΡΙΟ	ΠΑΡΑΜΕΤΡΟΙ	ΑΡΙΘΜΟΣ ΕΠΟΧΩΝ	ΑΡΙΘΜΟΣ ΦΙΛΤΡΩΝ ΓΙΑ ΔΕΔΟΜΕΝΑ ΕΙΣΟΔΟΥ	ΠΡΟΣ ΕΚΠΑΙΔΕΥΣΗ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ
1	ΟΛΕΣ	100	64,128,256	RNN, LSTM
2	Daily geomagnetic activity average (K)	100	64,128,256	RNN,LSTM
	Solar Radio Flux			
3	Daily geomagnetic activity average (K)	100	64,128,256	RNN, LSTM
	Solar Radio Flux			
	Sunspot Number			
4	Daily geomagnetic activity average (K)	100	64,128,256	RNN, LSTM
	Coronal Mass Ejections			
5	Daily geomagnetic activity average (K)	100	64,128,256	RNN, LSTM
	Solar Radio Flux			
	Solar Flares			
	Coronal Mass Ejections			
6	Daily geomagnetic activity average (K)	100	64,128,256	RNN, LSTM
	Solar Radio Flux			
	Coronal Mass Ejections			

7	Daily geomagnetic activity average (K)	100	64,128,256	RNN, LSTM
	Solar Radio Flux			
	Sunspot Number			
	Energetic Particle Flux			

Πιο συγκεκριμένα το κάθε σενάριο χωρίζεται σε υποσενάρια, τα οποία χαρακτηρίζονται από τον αριθμό **των φίλτρων που εισάγονται** (υπερπαράμετροι (64 ή 128 ή 256) και **από το προς εκπαίδευση νευρωνικό δίκτυο**. Στη συγκεκριμένη διπλωματική εργασία, όπως προαναφέρθηκε και στο κεφάλαιο 4, εκπαιδεύτηκαν δύο είδη νευρωνικών δικτύων, το Recurrent neural network (RNN) και οι νευρώνες μακράς-βραχείας διάρκειας μνήμης (Long Short-Term Memory - LSTM) που αποτελούν μία εξειδικευμένη μορφή αλγορίθμων RNN δικτύων.

Στα επόμενα υποκεφάλαια παρατίθενται αναλυτικά κάποια από τα σενάρια, καθώς και οι μετρητικοί δείκτες που χρησιμοποιήθηκαν για την αξιολόγηση των αποτελεσμάτων.

7.1 Μετρητικοί δείκτες αξιολόγησης αποτελεσμάτων

Στην ενότητα αυτή, ακολουθεί η παρουσίαση των μετρικών δεικτών, οι οποίοι εφαρμόστηκαν σε κάθε σενάριο για την αξιολόγηση της ακρίβειας των αποτελεσμάτων.

7.1.1 Mean Square error (MSE) - Mean Absolute error (MAE)


Ο στόχος της Γραμμικής Παλινδρόμησης είναι να βρει μια γραμμή που ελαχιστοποιεί το σφάλμα πρόβλεψης όλων των σημείων δεδομένων. Το βασικό βήμα σε οποιοδήποτε μοντέλο μηχανικής μάθησης είναι η αξιολόγηση της ακρίβειας του μοντέλου. Οι μετρήσεις Μέσο τετραγωνικό Σφάλμα (mse) και Μέσο Απόλυτο Σφάλμα (mae) χρησιμοποιούνται για την αξιολόγηση της απόδοσης του μοντέλου στην ανάλυση παλινδρόμησης.

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.

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 ο αριθμός των MAE – MSE είναι μικρός και σχεδόν ίδιος, τόσο καλύτερα προσδιορίζεται το μοντέλο και αποφεύγονται τα χωρικά ακρότατα. Στα ακόλουθα σχήματα παρατηρείται πως οι τιμές MSE, MAE είναι αρκετά μικρές αριθμητικά και σε κάποιες περιπτώσεις σχεδόν ταυτίζονται. Το σφάλμα λοιπόν έχει μικρή διασπορά και ο προσδιορισμός του μοντέλου είναι ικανοποιητικός.

	MSE	MAE
RNN_64	0.7	0.67
LSTM_64	0.55	0.57
RNN_128	0.84	0.68
LSTM_128	0.54	0.56
RNN_256	0.62	0.63
LSTM_256	0.54	0.59



Εικόνα 29. Ικανοποιητικός προσδιορισμός μοντέλου, μέσω των μετρητικών σχέσεων MSE-MAE

Στο ακόλουθο σχήμα παρουσιάζεται η γραμμή που ελαχιστοποιεί το σφάλμα πρόβλεψης όλων των σημείων δεδομένων. Όπως φαίνεται η ακρίβεια του μοντέλου είναι ικανοποιητική καθώς δεν υπάρχουν χωρικά ακρότατα.



Εικόνα 30. Γραμμική παλινδρόμηση

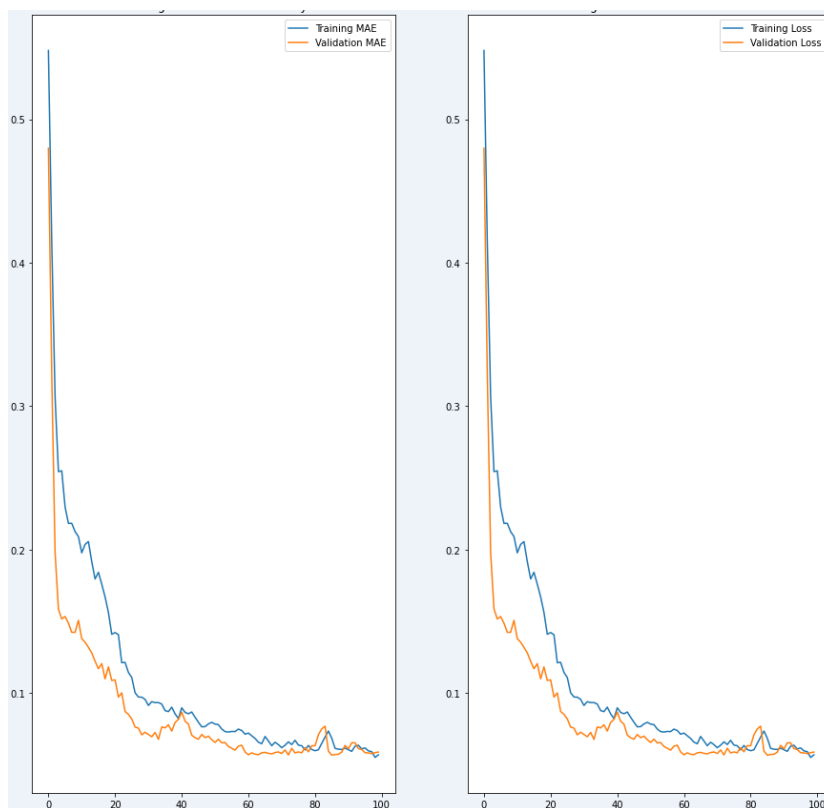
7.1.2 Ακρίβεια (Accuracy) – Σφάλμα (loss) στο σετ δεδομένων

Ο δείκτης accuracy και Loss 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. Γραφικό παράδειγμα φαίνεται στη Εικόνα 30.



Εικόνα 31. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης

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 αυτό ερμηνεύεται ως υπερπροσαρμογή του νευρωνικού δικτύου στα δεδομένα.

7.1.2.1 Υπερπροσαρμογή νευρωνικού δικτύου

Η υπερπροσαρμογή συμβαίνει όταν το μοντέλο μας γίνεται πολύ καλό στο να μπορεί να ταξινομήει ή να προβλέπει δεδομένα που περιλαμβάνονταν στο σετ εκπαίδευσης, αλλά

δεν είναι τόσο καλό στην ταξινόμηση δεδομένων στα οποία δεν είχε εκπαιδευτεί. Έτσι ουσιαστικά, το μοντέλο έχει υπερπροσαρμόσει τα δεδομένα στο σετ εκπαίδευσης.

Η υπερβολική τοποθέτηση είναι ένα απίστευτα κοινό πρόβλημα. Η μείωση της πραγματοποιείται με τους κάτωθι τρόπους:

- **Προσθήκη περισσότερων δεδομένων στο σετ εκπαίδευσης**

Το πιο εύκολο πράγμα που μπορούμε να κάνουμε, εφόσον έχουμε πρόσβαση σε αυτό, είναι να προσθέσουμε περισσότερα δεδομένα. Όσο περισσότερα δεδομένα μπορούμε να εκπαιδεύσουμε το μοντέλο μας, τόσο περισσότερα θα μπορεί να μάθει από το σετ εκπαίδευσης. Επίσης, με περισσότερα δεδομένα, ελπίζουμε να προσθέσουμε περισσότερη ποικιλομορφία και στο σετ εκπαίδευσης. Αυτό πραγματοποιείται στην παρούσα διπλωματική με την προσθήκη περισσότερων παραμέτρων επιρροής TEC από το σετ δεδομένων (διάφορα σενάρια).

- **Επαύξηση Δεδομένων**

Μια άλλη τεχνική που μπορούμε να εφαρμόσουμε για να μειώσουμε την υπερπροσαρμογή είναι η χρήση της αύξησης δεδομένων. Αυτή είναι η διαδικασία δημιουργίας πρόσθετων επαυξημένων δεδομένων τροποποιώντας εύλογα τα δεδομένα στο σετ εκπαίδευσής μας.

Η γενική ιδέα της αύξησης δεδομένων μάς επιτρέπει να προσθέτουμε περισσότερα δεδομένα στο εκπαιδευτικό μας σύνολο που είναι παρόμοια με τα δεδομένα που έχουμε ήδη, αλλά απλώς τροποποιούνται εύλογα σε κάποιο βαθμό, ώστε να μην είναι ακριβώς το ίδιο.

- **Μείωση της πολυπλοκότητας του μοντέλου**

Θα μπορούσε να μειωθεί η πολυπλοκότητα του μοντέλου κάνοντας απλές αλλαγές, όπως η αφαίρεση ορισμένων επιπέδων από το μοντέλο ή η μείωση του αριθμού των νευρώνων στα επίπεδα. Αυτό μπορεί να βοηθήσει το μοντέλο μας να γενικεύσει καλύτερα σε δεδομένα που δεν έχει δει στο παρελθόν. Αυτό πραγματοποιείται στην παρούσα διπλωματική με την αφαίρεση κάποιων παραμέτρων επιρροής TEC από το σετ δεδομένων (διάφορα σενάρια).

- **Εγκατάλειψη**

Η γενική ιδέα πίσω από την εγκατάλειψη είναι ότι, εάν το προστεθεί σε ένα μοντέλο, θα αγνοήσει τυχαία κάποιο υποσύνολο κόμβων σε ένα δεδομένο επίπεδο κατά τη διάρκεια της εκπαίδευσης, δηλαδή, θα απορρίψει τους κόμβους από το επίπεδο. Ως εκ τούτου, το όνομα εγκατάλειψη. Αυτό θα αποτρέψει αυτούς τους κόμβους που εγκαταλείφθηκαν από το να συμμετέχουν στην παραγωγή μιας πρόβλεψης για τα δεδομένα. Αυτή η τεχνική μπορεί επίσης να βοηθήσει το μοντέλο μας να γενικεύσει καλύτερα σε δεδομένα που δεν έχει δει στο παρελθόν. Θα καλύψουμε την πλήρη έννοια της εγκατάλειψης ως τεχνικής τακτοποίησης σε άλλη ανάρτηση και εκεί θα καταλάβουμε γιατί αυτό έχει νόημα.

7.2 Σενάριο 1^ο (για τον μήνα Ιανουάριου 2018)

Κατά τη διεξαγωγή του πρώτου σεναρίου, επιλέχθηκαν να εισαχθούν στο νευρωνικό δίκτυο, τα δεδομένα από όλες τις παραμέτρους επιρροής των τιμών TEC (Γεωμαγνητικές και ηλιακής δραστηριότητας). Επιλέχθηκε ως αριθμός εποχών το 100, και πραγματοποιήθηκαν τρία τεστ για κάθε είδος νευρωνικού δικτύου ξεχωριστά (RNN, LSTM). Ο αριθμός τρία υποδηλώνει τον διαφορετικό αριθμό φίλτρων που χρησιμοποιήθηκαν στα δεδομένα εισόδου κάθε φορά (64, 128, 256). Για κάθε αριθμό υπερπαραμέτρων υπήρχε και διαφορετικός αριθμός παραμέτρων εκπαίδευσης του αλγορίθμου. Τέλος η παραπάνω διαδικασία έγινε δύο φορές για τον μήνα Ιανουάριο καθώς στην πρώτη περίπτωση τα δεδομένα εξόδου ήταν τιμές STEC και στη δεύτερη περίπτωση τιμές VTEC. Αναλυτικά ο τρόπος διεξαγωγής του Σεναρίου Νο1 στον Πίνακα 4.

Πίνακας 4. Πρώτο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας


ΣΕΝΑΡΙΟ	ΠΑΡΑΜΕΤΡΟΙ	ΑΡΙΘΜΟΣ ΕΠΟΧΩΝ	ΠΡΟΣ ΕΚΠ/ΣΗ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ	ΑΡΙΘΜΟΣ ΦΙΛΤΡΩΝ ΓΙΑ ΔΕΔΟΜΕΝΑ ΕΙΣΟΔΟΥ	ΑΡΙΘΜΟΣ ΠΑΡΑΜΕΤΡΩΝ ΕΚ/ΣΗΣ ΑΛΓΟΡΙΘΜΟΥ	ΤΙΜΕΣ ΕΞΟΔΟΥ
1	ΟΛΕΣ	100	RNN	64	10.942	STEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	
			RNN	64	10.942	VTEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	

7.2.1 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου STEC.


Στη συγκεκριμένη υποενότητα θα εξεταστεί ο βαθμός εκπαίδευσης των δικτύων RNN, LSTM, με διαφορετικό κάθε φορά αριθμό παραμέτρων εκπαίδευσης του αλγορίθμου. Μελετάται η ακρίβεια των δεδομένων εξόδου STEC.

7.2.1.1 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 64.

Τα αποτελέσματα της συγκεκριμένης περίπτωσης αποτυπώνονται στα κάτωθι γραφήματα.



Εικόνα 32. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης



Εικόνα 33. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

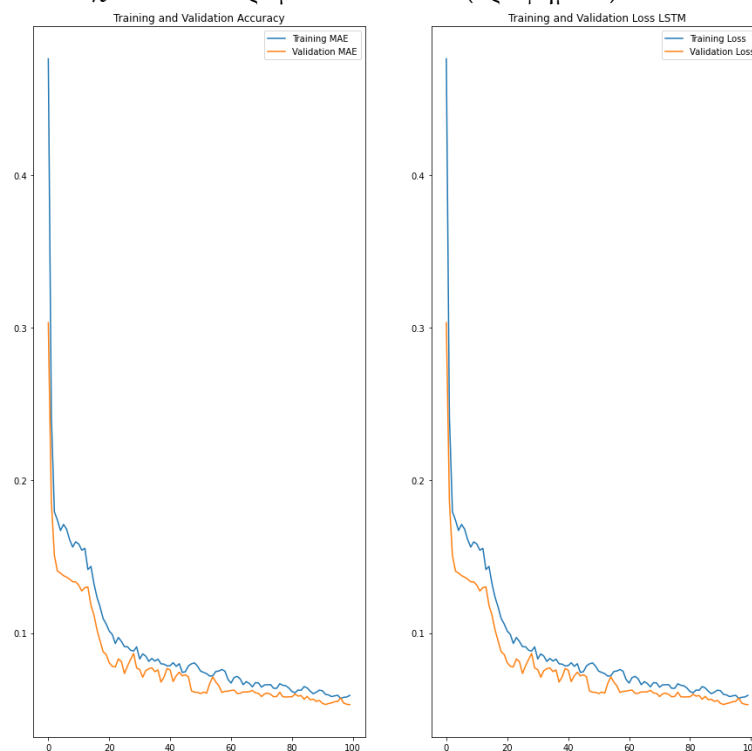
Ένα σετ δεδομένων προσδιορίζεται από τις τιμές εκπαίδευσης (training) και τις τιμές αξιολόγησης (validation). Για να είναι ακριβές το μοντέλο θα πρέπει αυτά τα δύο να συνάδουν. Γενικότερα, η μπλε γραμμή αποτυπώνει τα δεδομένα εκπαίδευσης και η πορτοκαλί τα δεδομένα αξιολόγησης. Όταν η πορτοκαλί γραμμή 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 αυτό ερμηνεύεται ως υπερπροσαρμογή του νευρωνικού δικτύου στα δεδομένα.

Όπως φαίνεται λοιπόν στο γράφημα της Εικόνας 32, τα δεδομένα εκπαίδευσης δεν ταυτίζονται με τα δεδομένα αξιολόγησης, και αυτό μας οδηγεί στο συμπέρασμα ότι το νευρωνικό δίκτυο υπερπροσαρμόστηκε. Αυτό μπορεί να οφείλεται στο γεγονός, πως έχουν εισαχθεί τα δεδομένα όλων των παραμέτρων επιρροής τιμών TEC, κάποιες από τις οποίες δεν βοηθούν στην εξαγωγή σωστών συμπερασμάτων, δηλαδή δεν διαδραματίζουν τόσο σημαντικό ρόλο στην εκπαίδευση του μοντέλου.


Ομοίως για το γράφημα της Εικόνας 33, παρατηρείται μέσω της γραμμικής παλινδρόμησης ότι το σφάλμα πρόβλεψης δεν ελαχιστοποιείται καθώς παρατηρούνται αρκετά χωρικά ακρότατα.

7.2.1.2 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 64.

Στην εκπαίδευση του LSTM δικτύου, παρόλο που όλα τα κριτήρια είναι ίδια όπως προηγουμένως, παρατηρείται καλύτερη προσαρμογή του σετ δεδομένων, καθώς τα δεδομένα εκπαίδευσης και αξιολόγησης τείνουν να ταυτιστούν (Γράφημα 2α). Τα χωρικά ακρότατα δείχνουν να παραμένουν τα ίδια (Γράφημα 2β).




Εικόνα 34. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 35. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.2.1.3 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 128.

Στη συγκεκριμένη περίπτωση παρατηρείται μία αλλαγή στην ελαχιστοποίηση του σφάλματος καθώς παρατηρούνται περισσότερα χωρικά ακρότατα. Το RNN δίκτυο δείχνει να μην ανταποκρίνεται καλά στα δεδομένα εισόδου.



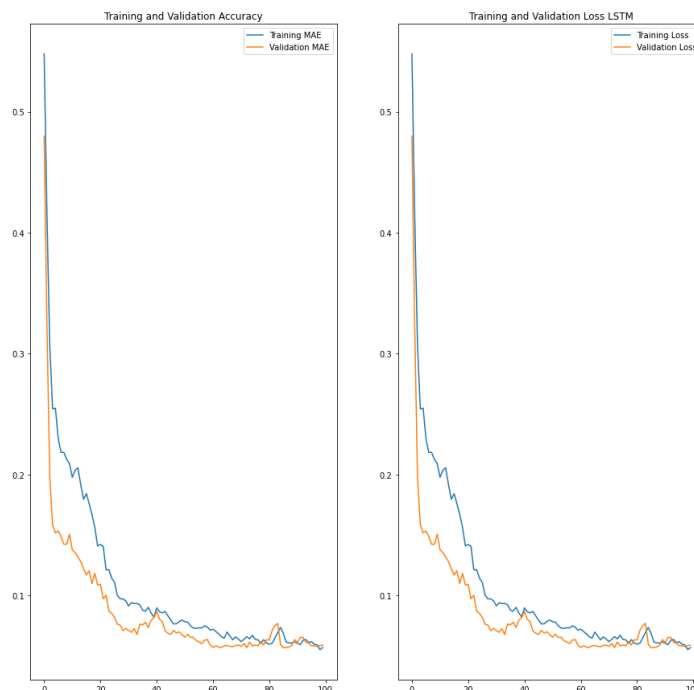
Εικόνα 36. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 37. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.2.1.4 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 128.

Δεν παρατηρούνται μεγάλες αλλαγές στη συμπεριφορά του δικτύου. Με τα μέχρι τώρα δεδομένα. Αυτό που προκύπτει είναι πως παρόλο που στις τελευταίες δύο υποενότητες χρησιμοποιούνται περισσότεροι παράμετροι εκπαίδευσης του αλγορίθμου (38.206 για το RNN και 139.750 για το LSTM), τα αποτελέσματα είναι χειρότερα σε σχέση με τις αρχικές υπερπαραμέτρους.



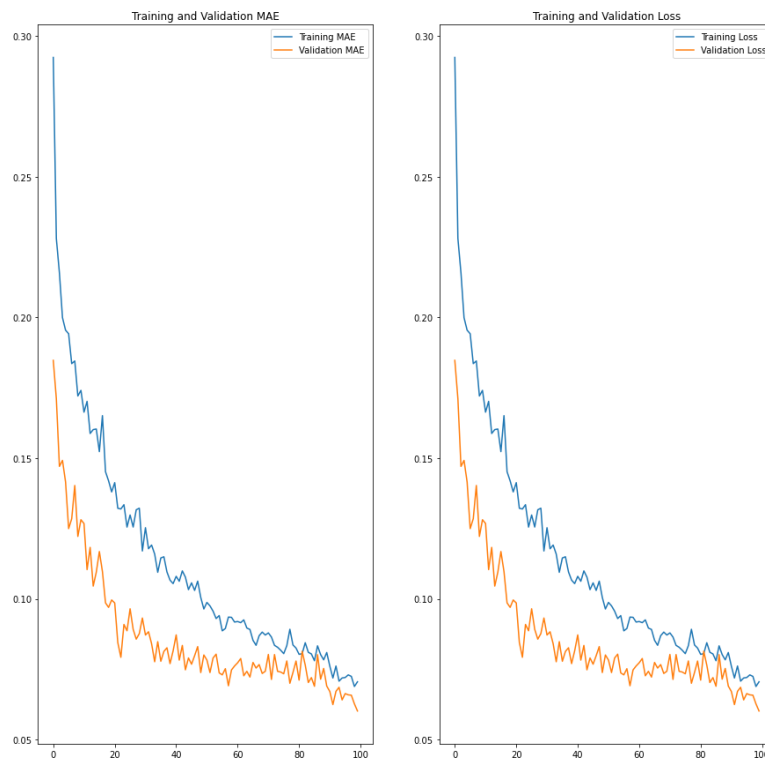
Εικόνα 38. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης



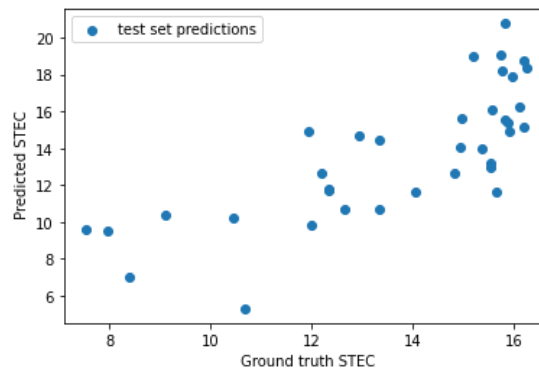
Εικόνα 39. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.2.1.5 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 256.

Όσο αυξάνεται ο αριθμός των παραμέτρων εκπαίδευσης του αλγορίθμου, τόσο μεγαλώνει το σφάλμα στο σετ δεδομένων (υπερπροσαρμογή δικτύου).



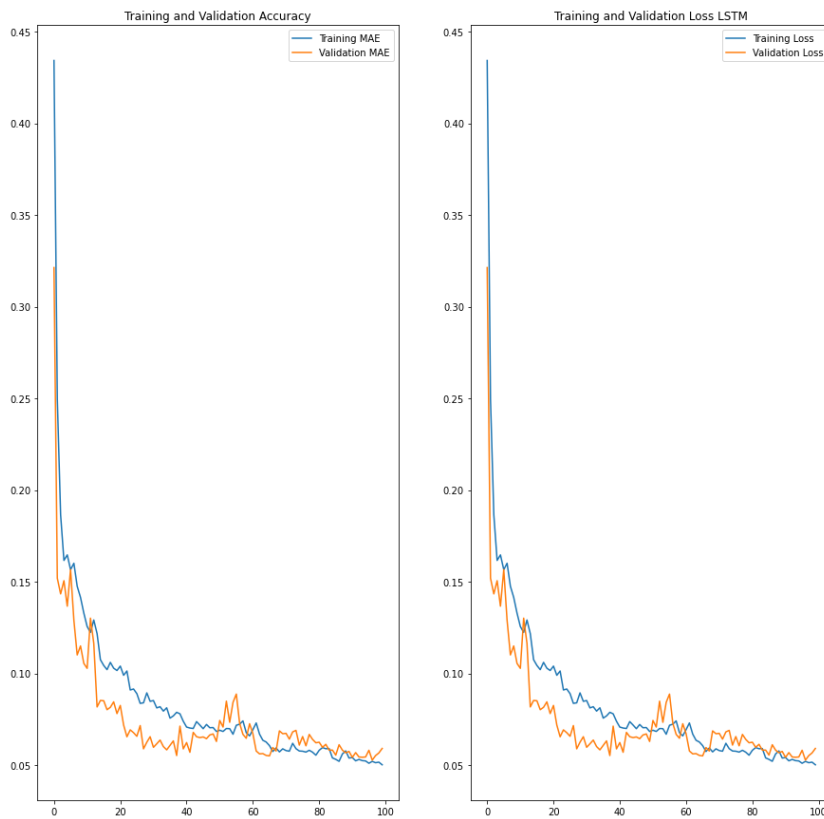
Εικόνα 40. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 41. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.2.1.6 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 256.

Όμοιες παρατηρήσεις με προηγούμενο υποκεφάλαιο



Εικόνα 42. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 43. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.2.1.7 Αξιολόγηση αποτελεσμάτων 1^{ου} σεναρίου για δεδομένα εξόδου STEC.

Με την περάτωση του 1^{ου} Σεναρίου, παρατηρήθηκαν τα κάτωθι:

- Η χρήση των δεδομένων από όλες τις παραμέτρους επιρροής τιμών TEC δεν αποδείχθηκε ικανοποιητική
- Το καλύτερο αποτέλεσμα προήλθε από την εκπαίδευση του LSTM δικτύου με αριθμό υπερπαραμέτρων 64. Αυτό υποδηλώνει πως ο μεγαλύτερος αριθμός των παραμέτρων εκπαίδευσης του αλγορίθμου, δεν αποτελεί κριτήριο ενισχυτικό για καλύτερα αποτελέσματα.
- Στο ακόλουθο γράφημα απεικονίζονται οι σχέσεις των τιμών MAE και MSE στις διάφορες υποκατηγορίες. Όσο πιο μικρός είναι ο αριθμός αυτών των δεικτών και όσο περισσότερο ταυτίζονται, τόσο καλύτερα προσδιορίζεται το μοντέλο. Φαίνεται και από το εν λόγω γράφημα πως το δίκτυο LSTM προσδιόρισε με μεγαλύτερη ακρίβεια το μοντέλο.



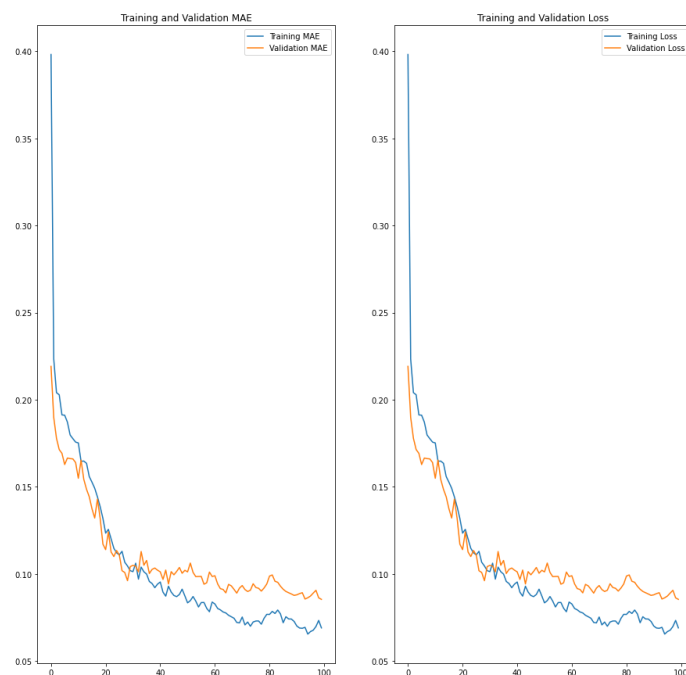
Εικόνα 44. Προσδιορισμός μοντέλου, μέσω των μετρητικών σχέσεων MSE-MAE

7.2.2 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου VTEC.


Στη συγκεκριμένη υποενότητα θα εξεταστεί ο βαθμός εκπαίδευσης των δικτύων RNN, LSTM, με διαφορετικό κάθε φορά αριθμό παραμέτρων εκπαίδευσης του αλγορίθμου. Μελετάται η ακρίβεια των δεδομένων εξόδου VTEC.

7.2.2.1 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 64.

Τα αποτελέσματα της συγκεκριμένης περίπτωσης αποτυπώνονται στα κάτωθι γραφήματα.



Εικόνα 45. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης



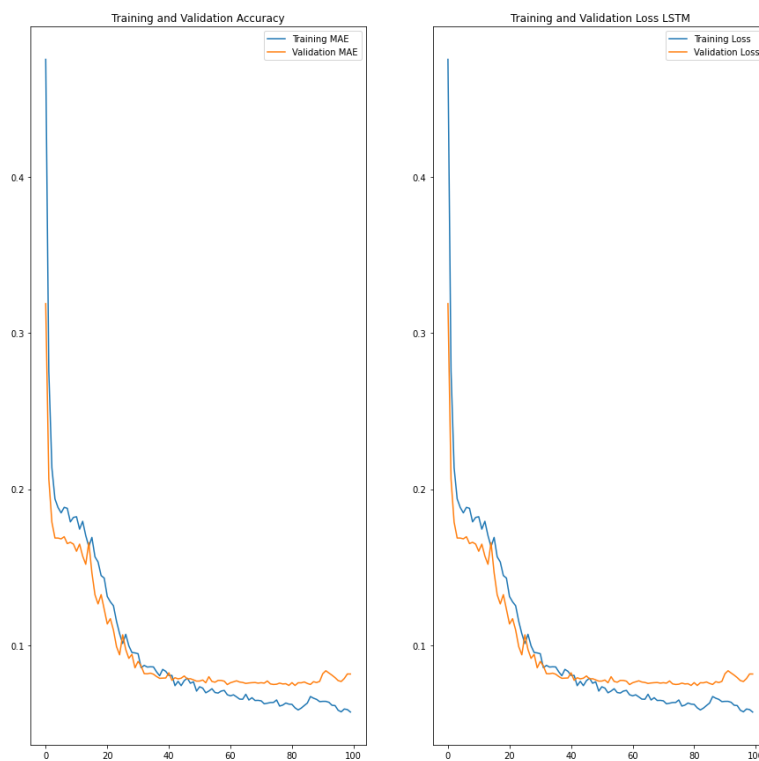
Εικόνα 46. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

Όπως φαίνεται λοιπόν στο γράφημα της Εικόνας 45, τα δεδομένα εκπαίδευσης δεν ταυτίζονται με τα δεδομένα αξιολόγησης, και αυτό μας οδηγεί στο συμπέρασμα ότι το νευρωνικό δίκτυο υπερπροσαρμόστηκε. Αυτό μπορεί να οφείλεται στο γεγονός, πως έχουν εισαχθεί τα δεδομένα όλων των παραμέτρων επιρροής τιμών TEC, κάποιες από τις οποίες δεν βοηθούν στην εξαγωγή σωστών συμπερασμάτων, δηλαδή δεν διαδραματίζουν τόσο σημαντικό ρόλο στην εκπαίδευση του μοντέλου.


Ομοίως για το γράφημα της Εικόνας 46, παρατηρείται μέσω της γραμμικής παλινδρόμησης ότι το σφάλμα πρόβλεψης δεν ελαχιστοποιείται καθώς παρατηρούνται αρκετά χωρικά ακρότατα.

7.2.2.2 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 64.

Όμοια αποτελέσματα όπως προηγουμένως.




Εικόνα 47. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 48. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.2.2.3 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 128.

Στη συγκεκριμένη περίπτωση παρατηρείται μία αλλαγή στην ελαχιστοποίηση του σφάλματος καθώς παρατηρούνται περισσότερα χωρικά ακρότατα. Το RNN δίκτυο δείχνει να μην ανταποκρίνεται καλά στα δεδομένα εισόδου.



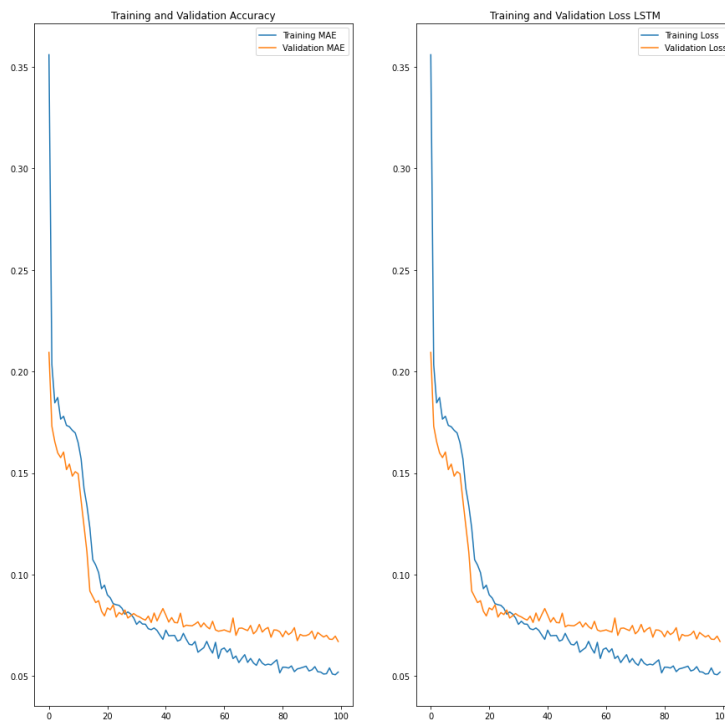
Εικόνα 49. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 50. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.2.2.4 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 128.

Παρατηρείται, πως όσο αυξάνεται ο αριθμός των παραμέτρων εκπαίδευσης του αλγορίθμου, τόσο μειώνεται το σφάλμα στο σετ δεδομένων, σε αντίθεση με την προσαρμοστικότητα των δικτύων για δεδομένα εξόδου STEC.



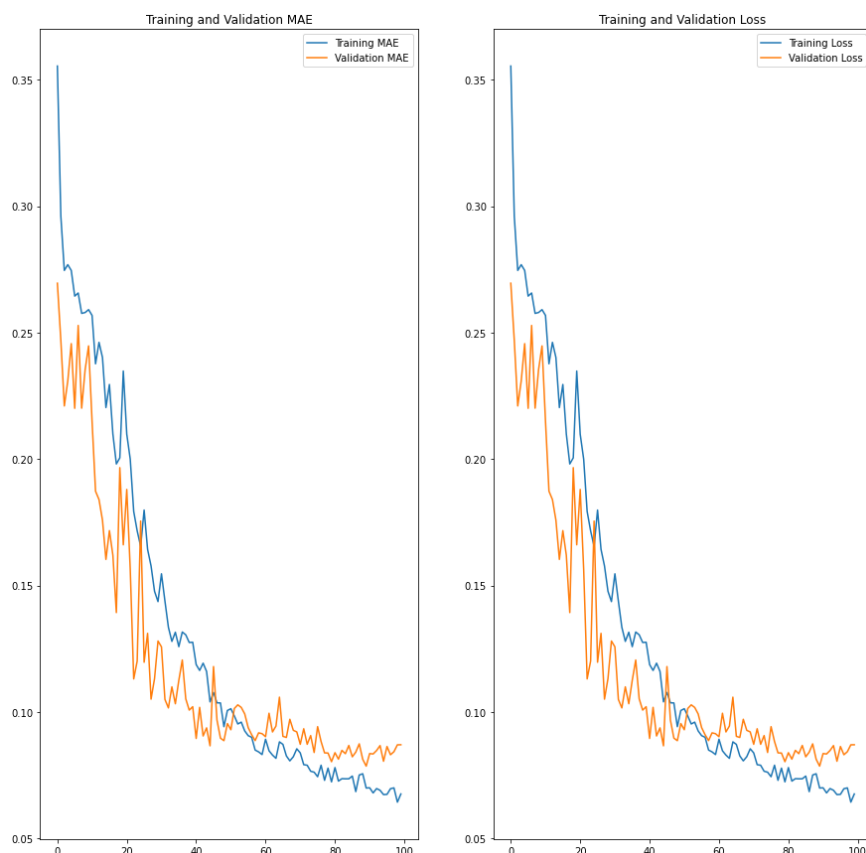
Εικόνα 51. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 52. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.2.2.5 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 256.

Στην εκπαίδευση του RNN δικτύου, παρόλο που όλα τα κριτήρια είναι ίδια όπως προηγουμένως, παρατηρείται καλύτερη προσαρμογή του σετ δεδομένων, καθώς τα δεδομένα εκπαίδευσης και αξιολόγησης τείνουν να ταυτιστούν (Εικόνα 53). Τα χωρικά ακρότατα δείχνουν να παραμένουν τα ίδια (Εικόνα 54).



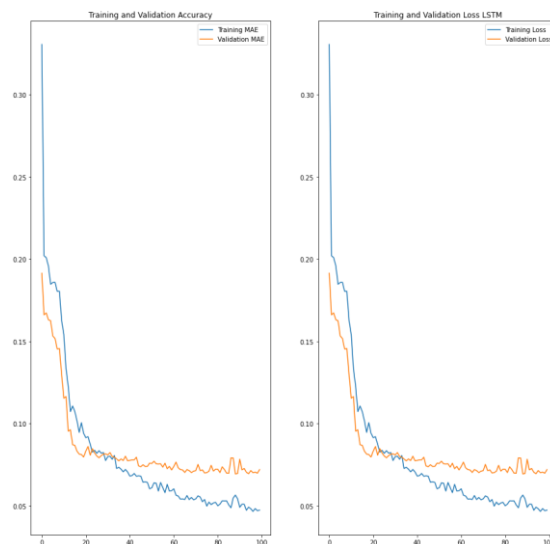
Εικόνα 53. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 54. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.2.2.6 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 256.

Όμοιες παρατηρήσεις με προηγούμενο υποκεφάλαιο



Εικόνα 55. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 56. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.2.2.7 Αξιολόγηση αποτελεσμάτων 1^{ου} σεναρίου για δεδομένα εξόδου VTEC.

Με την περάτωση του 1^{ου} Σεναρίου, παρατηρήθηκαν τα κάτωθι:

- Η χρήση των δεδομένων από όλες τις παραμέτρους επιρροής τιμών TEC δεν αποδείχθηκε ικανοποιητική
- Το καλύτερο αποτέλεσμα προήλθε από την εκπαίδευση του RNN δικτύου με αριθμό υπερπαραμέτρων 128, 256. Αυτό υποδηλώνει, σε αντίθεση με την προσαρμοστικότητα των δικτύων για output STEC, πως όσο μεγαλώνει ο αριθμός των παραμέτρων εκπαίδευσης του αλγορίθμου, τόσο έχουμε καλύτερα αποτελέσματα.
- Στο ακόλουθο γράφημα απεικονίζονται οι σχέσεις των τιμών MAE και MSE στις διάφορες υποκατηγορίες. Όσο πιο μικρός είναι ο αριθμός αυτών των δεικτών και όσο περισσότερο ταυτίζονται, τόσο καλύτερα προσδιορίζεται το μοντέλο. Φαίνεται και από το εν λόγω γράφημα πως το δίκτυο LSTM προσδιόρισε με μεγαλύτερη ακρίβεια το μοντέλο.
- Επιπλέον σε αντίθεση με το κεφάλαιο 7.1.1, οι τιμές MAE και MSE είναι αρκετά πιο μικρές αριθμητικά (μέγιστη τιμή mse για δεδομένα εξόδου VTEC είναι 0.78 ενώ η αντίστοιχη τιμή για δεδομένα εξόδου STEC ήταν 6.2). Οπότε συμπεραίνεται πως οι τιμές VTEC προσδιορίζονται πολύ καλύτερα από τις αντίστοιχες STEC, με δεδομένα εισόδου όλες τις παραμέτρους επιρροής TEC.



Εικόνα 57. Προσδιορισμός μοντέλου, μέσω των μετρητικών σχέσεων MSE-MAE

7.3 Σενάριο 2^ο (για τον μήνα Ιανουάριου 2018)

Κατά τη διεξαγωγή του δεύτερου σεναρίου, επιλέχθηκαν να εισαχθούν στο νευρωνικό δίκτυο, τα δεδομένα από τις Γεωμαγνητικές και τις Solar Radio Flux παραμέτρους επιρροής των τιμών TEC. Αναλυτικά ο τρόπος διεξαγωγής του Σεναρίου Νο2 στον Πίνακα 5.

Πίνακας 5. Δεύτερο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας


ΣΕΝΑΡΙΟ	ΠΑΡΑΜΕΤΡΟΙ	ΑΡΙΘΜΟΣ ΕΠΟΧΩΝ	ΠΡΟΣ ΕΚΠ/ΣΗ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ	ΑΡΙΘΜΟΣ ΦΙΛΤΡΩΝ ΓΙΑ ΔΕΔΟΜΕΝΑ ΕΙΣΟΔΟΥ	ΑΡΙΘΜΟΣ ΠΑΡΑΜΕΤΡΩΝ ΕΚ/ΣΗΣ ΑΛΓΟΡΙΘΜΟΥ	ΤΙΜΕΣ ΕΞΟΔΟΥ
2	Γεωμαγνητικές & Solar Radio Flux	100	RNN	64	10.942	STEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	
	Solar Radio Flux	100	RNN	64	10.942	VTEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	

7.3.1 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου STEC.


Στη συγκεκριμένη υποενότητα θα εξεταστεί ο βαθμός εκπαίδευσης των δικτύων RNN, LSTM, με διαφορετικό κάθε φορά αριθμό παραμέτρων εκπαίδευσης του αλγορίθμου. Μελετάται η ακρίβεια των δεδομένων εξόδου **STEC**.

7.3.1.1 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 64.

Τα αποτελέσματα της συγκεκριμένης περίπτωσης αποτυπώνονται στα κάτωθι γραφήματα.



Εικόνα 58. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης



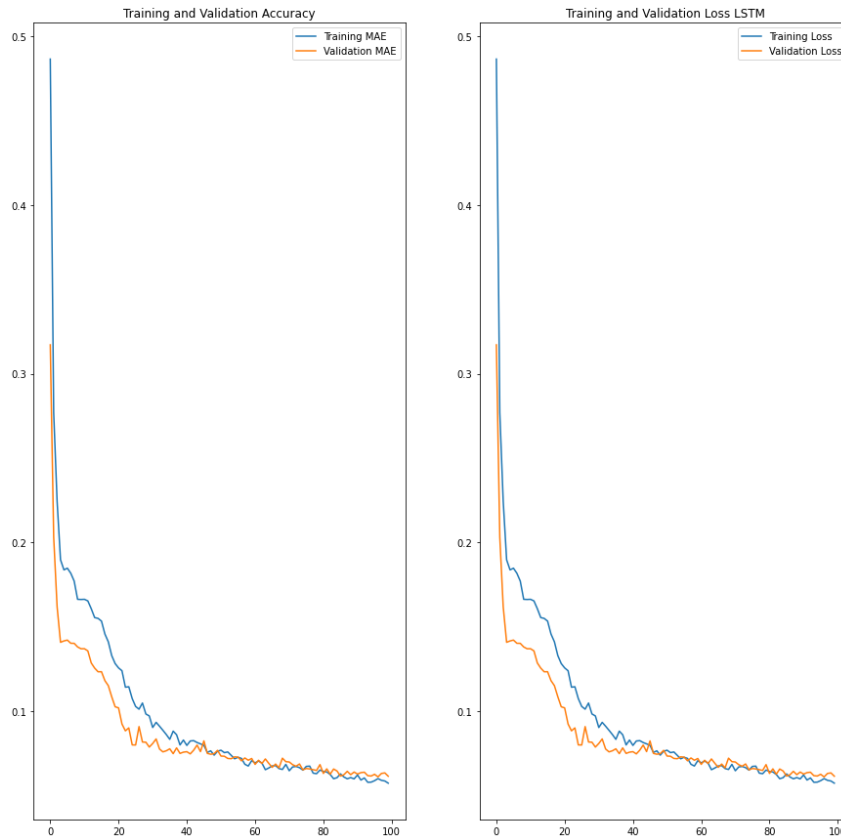
Εικόνα 59. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

Όπως φαίνεται λοιπόν στο γράφημα της Εικόνας 58 τα δεδομένα εκπαίδευσης ταυτίζονται με τα δεδομένα αξιολόγησης, και αυτό μας οδηγεί στο συμπέρασμα ότι το νευρωνικό δίκτυο έχει προσαρμοστεί κατάλληλα και εξάγει αξιόπιστα συμπεράσματα για τις τιμές εξόδου STEC. Αυτό μπορεί να οφείλεται στο γεγονός, πως έχουν προστεθεί δεδομένα μόνο δύο παραμέτρων επιρροής τιμών TEC και όχι πληθώρα παραμέτρων όπως στο Σενάριο 1. Συμπεραίνεται λοιπόν πως κάποιες από τις παραμέτρους του προηγούμενου σεναρίου ήταν περισσότερο «βάρος» για την εξαγωγή ορθών αποτελεσμάτων και όχι βοηθητικές.


Ομοίως για το γράφημα της Εικόνας 59, παρατηρείται μέσω της γραμμικής παλινδρόμησης ότι το σφάλμα πρόβλεψης ελαχιστοποιείται καθώς δεν παρατηρούνται αρκετά χωρικά ακρότατα.

7.3.1.2 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 64.

Όμοια αποτελέσματα και για την προσαρμοστικότητα του δικτύου LSTM.




Εικόνα 60. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 61. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.3.1.3 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 128.

Παρατηρείται πως όσο αυξάνεται ο αριθμός των υπερπαραμέτρων (128) τόσο το δίκτυο υπερπροσαρμόζεται, κάτι το οποίο δεν είναι επιθυμητό. Το σφάλμα πρόβλεψης παραμένει ικανοποιητικό.



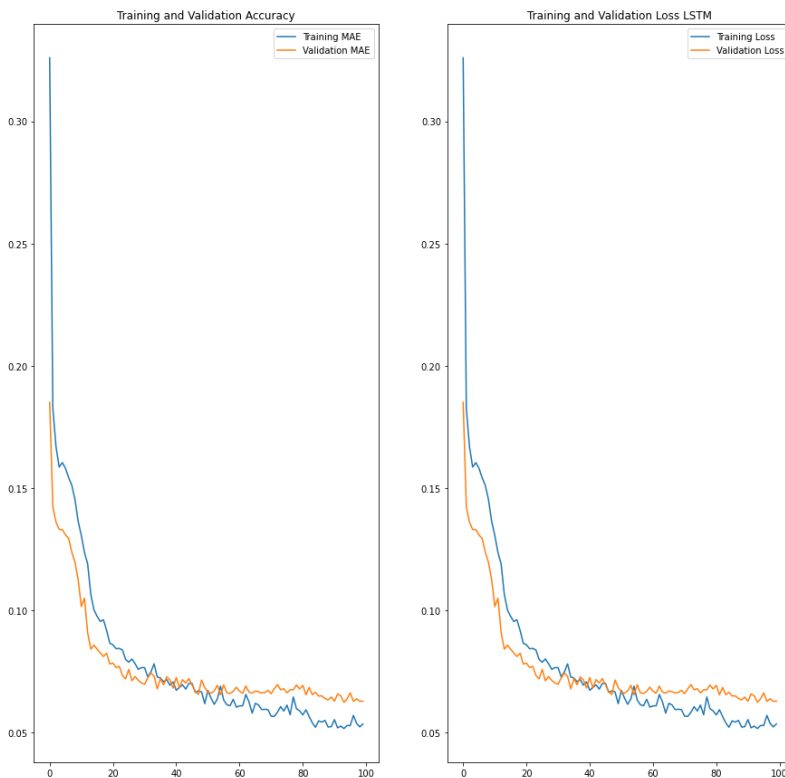
Εικόνα 62. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 63. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.3.1.4 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 128.

Παρόλο που ο αριθμός υπερπαραμέτρων παραμένει ο ίδιος με προηγούμενως, το σφάλμα στο σετ δεδομένων αξιολόγησης είναι πολύ καλύτερο στο LSTM, σε σχέση με το δίκτυο RNN.



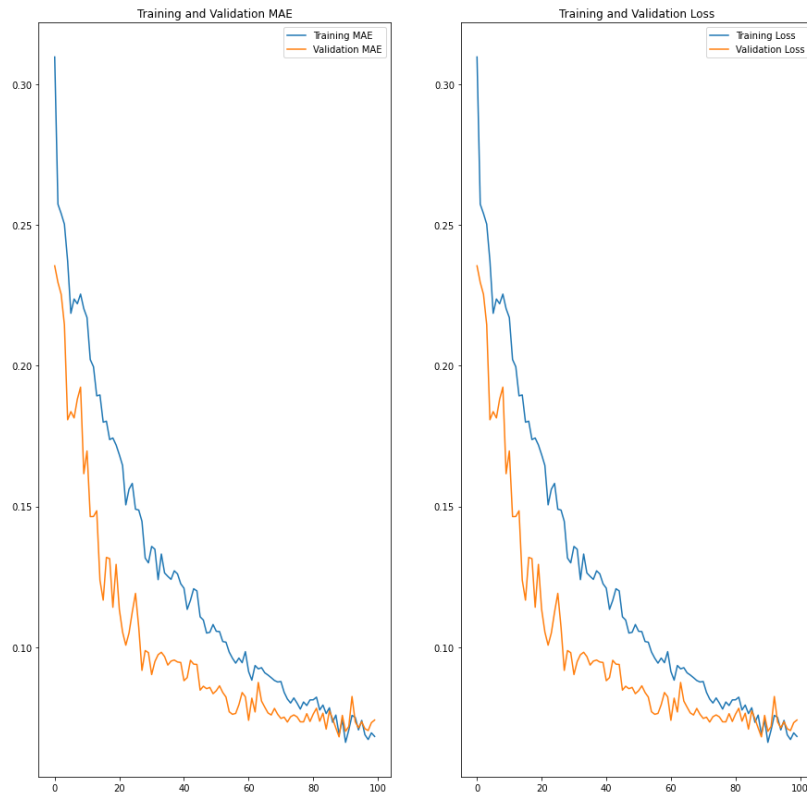
Εικόνα 64. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 65. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.3.1.5 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 256.

Όμοιες παρατηρήσεις με υποκεφάλαιο 7.2.1.3.




Εικόνα 66. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 67. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.3.1.6 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 256.

Όμοιες παρατηρήσεις με προηγούμενο υποκεφάλαιο



Εικόνα 68. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 69. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.3.1.7 Αξιολόγηση αποτελεσμάτων 1^{ου} σεναρίου για δεδομένα εξόδου STEC.

Με την περάτωση του 2^{ου} Σεναρίου, παρατηρήθηκαν τα κάτωθι:

- Η χρήση των δεδομένων από τις γεωμαγνητικές και solar radio flux παραμέτρους επιρροής τιμών TEC αποδείχθηκε εξαιρετικά ικανοποιητική
- Το καλύτερο αποτέλεσμα προήλθε από την εκπαίδευση του RNN δικτύου με αριθμό υπερπαραμέτρων 256. Αυτό υποδηλώνει πως ο μεγαλύτερος αριθμός των παραμέτρων εκπαίδευσης του αλγορίθμου, αποτελεί κριτήριο ενισχυτικό για καλύτερα αποτελέσματα.
- Στο ακόλουθο γράφημα απεικονίζονται οι σχέσεις των τιμών MAE και MSE στις διάφορες υποκατηγορίες. Όσο πιο μικρός είναι ο αριθμός αυτών των δεικτών και όσο περισσότερο ταυτίζονται, τόσο καλύτερα προσδιορίζεται το μοντέλο. Φαίνεται και από το εν λόγω γράφημα πως το δίκτυο RNN προσδιόρισε με μεγαλύτερη ακρίβεια το μοντέλο.
- Επιπλέον σε αντίθεση με το Σενάριο 1, οι τιμές MAE και MSE είναι αρκετά πιο μικρές αριθμητικά (μέγιστη τιμή mse για δεδομένα εξόδου STEC είναι 2.8 ενώ η αντίστοιχη τιμή για δεδομένα εξόδου STEC του 1^{ου} σεναρίου ήταν 6.2). Οπότε συμπεραίνεται πως η είσοδος μόνο των γεωμαγνητικών και solar radio flux παραμέτρων προσδιορίζουν πολύ καλύτερα το αποτέλεσμα σε σχέση με το 1^ο σενάριο. Αυτό μπορεί να οφείλεται τόσο στη μείωση του αριθμού των παραμέτρων, όσο και στα ποιοτικά καλύτερα δεδομένα των συγκεκριμένων δύο παραμέτρων.




Εικόνα 70. Προσδιορισμός μοντέλου, μέσω των μετρητικών σχέσεων MSE-MAE

7.3.2 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου VTEC.


Στη συγκεκριμένη υποενότητα θα εξεταστεί ο βαθμός εκπαίδευσης των δικτύων RNN, LSTM, με διαφορετικό κάθε φορά αριθμό παραμέτρων εκπαίδευσης του αλγορίθμου. Μελετάται η ακρίβεια των δεδομένων εξόδου **VTEC**.

7.3.2.1 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 64.

Τα αποτελέσματα της συγκεκριμένης περίπτωσης αποτυπώνονται στα κάτωθι γραφήματα.



Εικόνα 71. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης

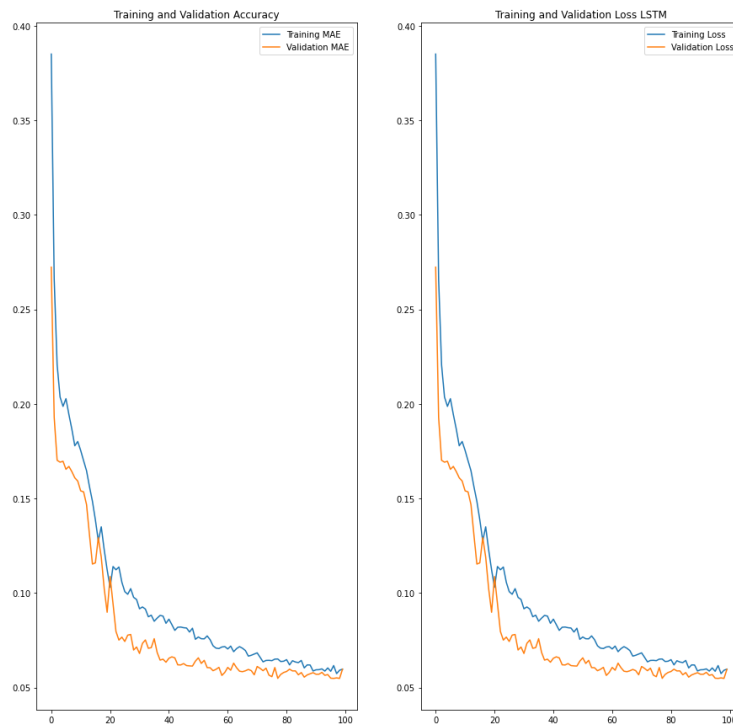


Εικόνα 72. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)


Όπως φαίνεται λοιπόν στην Εικόνα 71 τα δεδομένα εκπαίδευσης δεν ταυτίζονται με τα δεδομένα αξιολόγησης, και αυτό μας οδηγεί στο συμπέρασμα ότι το νευρωνικό δίκτυο υπερπροσαρμόστηκε. Ομοίως στην Εικόνα 72, παρατηρείται μέσω της γραμμικής παλινδρόμησης ότι το σφάλμα πρόβλεψης δεν ελαχιστοποιείται καθώς παρατηρούνται αρκετά χωρικά ακρότατα.

7.3.2.2 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 64.

Το δίκτυο LSTM φαίνεται να προσαρμόζεται καλύτερα στις τιμές εισόδου καθώς τα δεδομένα εκπαίδευσης με τα αντίστοιχα αξιολόγησης τείνουν να ταυτιστούν, και τα χωρικά ακρότατα αρχίζουν να εκλείπουν.



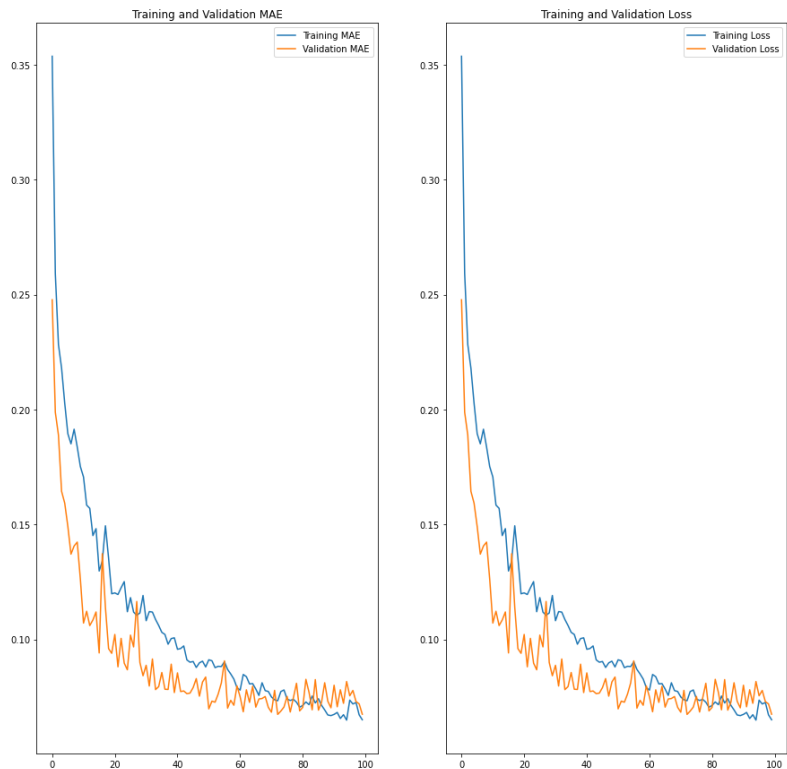
Εικόνα 73. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 74. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.3.2.3 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 128.

Παρατηρείται, πως όσο αυξάνεται ο αριθμός των παραμέτρων εκπαίδευσης του αλγορίθμου, τόσο αυξάνεται το σφάλμα στο σετ δεδομένων.



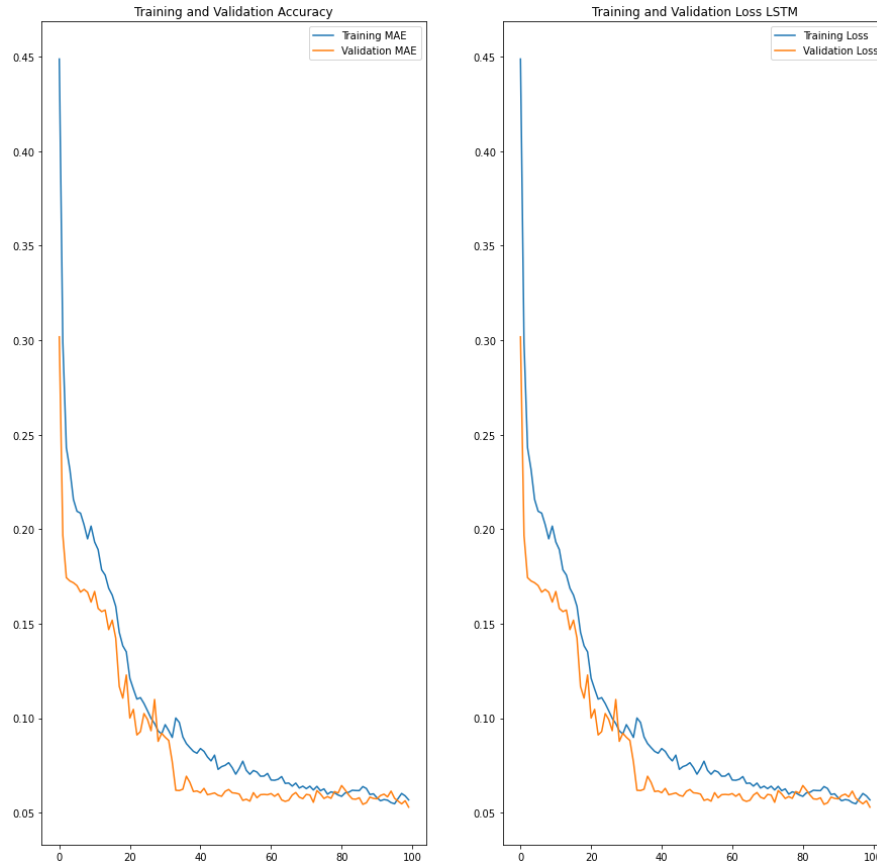
Εικόνα 75. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 76. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.3.2.4 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 128.

Ομοίως με προηγούμενο υποκεφάλαιο.




Εικόνα 77. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 78. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.3.2.5 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 256.

Στην εκπαίδευση του RNN δικτύου, παρόλο που όλα τα κριτήρια είναι ίδια όπως προηγουμένως, παρατηρείται ακόμα χειρότερη προσαρμογή του σετ δεδομένων, καθώς τα δεδομένα εκπαίδευσης και αξιολόγησης αποκλίνουν ακόμα περισσότερο (Εικόνα 79). Τα χωρικά ακρότατα δείχνουν να παραμένουν τα ίδια (Εικόνα 80).



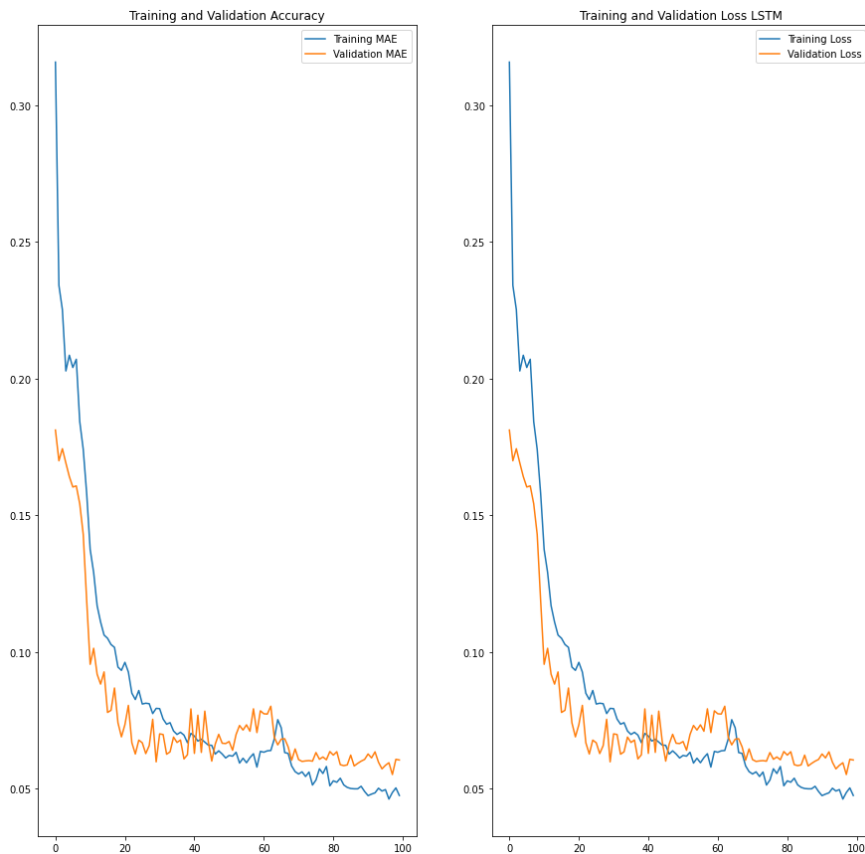
Εικόνα 79. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 80. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.3.2.6 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 256.

Αντίθετα με προηγουμένως το LSTM δίκτυο προσαρμόζεται καλύτερα σε σχέση με το RNN.



Εικόνα 81. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 82. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.3.2.7 Αξιολόγηση αποτελεσμάτων 2^{ου} σεναρίου για δεδομένα εξόδου VTEC.

Με την περάτωση του 2^{ου} Σεναρίου, παρατηρήθηκαν τα κάτωθι:

- Η χρήση των δεδομένων από όλες τις παραμέτρους επιρροής τιμών TEC δεν αποδείχθηκε ικανοποιητική
- Το καλύτερο αποτέλεσμα προήλθε από την εκπαίδευση του LSTM δικτύου με αριθμό υπερπαραμέτρων 64. Αυτό υποδηλώνει, σε αντίθεση με την προσαρμοστικότητα των δικτύων για output STEC, πως όσο μεγαλώνει ο αριθμός των παραμέτρων εκπαίδευσης του αλγορίθμου, τόσο έχουμε χειρότερα αποτελέσματα.
- Στο ακόλουθο γράφημα απεικονίζονται οι σχέσεις των τιμών MAE και MSE στις διάφορες υποκατηγορίες. Όσο πιο μικρός είναι ο αριθμός αυτών των δεικτών και όσο περισσότερο ταυτίζονται, τόσο καλύτερα προσδιορίζεται το μοντέλο. Φαίνεται και από το εν λόγω γράφημα πως το δίκτυο LSTM προσδιόρισε με μεγαλύτερη ακρίβεια το μοντέλο.
- Επιπλέον σε αντίθεση με το κεφάλαιο 7.1.2, οι τιμές MAE και MSE είναι αρκετά πιο μικρές αριθμητικά. Οπότε συμπεραίνεται πως οι τιμές VTEC προσδιορίζονται πολύ καλύτερα από τις αντίστοιχες STEC, με δεδομένα εισόδου όλες τις παραμέτρους επιρροής TEC.



Εικόνα 83. Προσδιορισμός μοντέλου, μέσω των μετρητικών σχέσεων MSE-MAE

7.4 Σενάριο 3^ο (για τον μήνα Ιανουάριου 2018)

Κατά τη διεξαγωγή του τρίτου σεναρίου, επιλέχθηκαν να εισαχθούν στο νευρωνικό δίκτυο, τα δεδομένα από τις Γεωμαγνητικές, τις Solar Radio Flux και τις Sunspot (3ωρες) παραμέτρους επιρροής των τιμών TEC. Αναλυτικά ο τρόπος διεξαγωγής του Σεναρίου Νο3 στον Πίνακα 6.

Πίνακας 6. Τρίτο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας

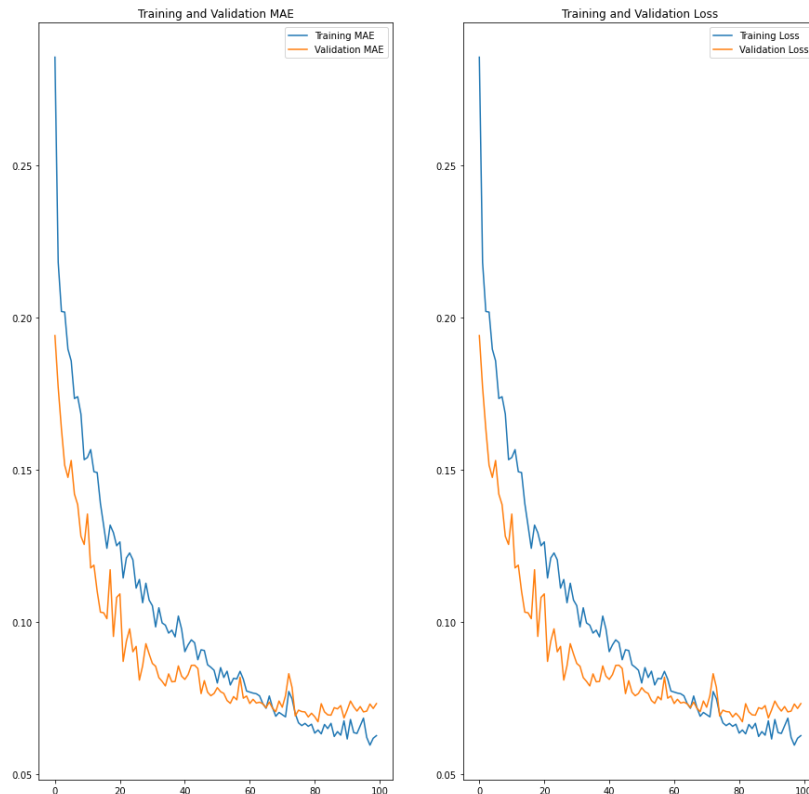
ΣΕΝΑΡΙΟ	ΠΑΡΑΜΕΤΡΟΙ	ΑΡΙΘΜΟΣ ΕΠΟΧΩΝ	ΠΡΟΣ ΕΚΠ/ΣΗ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ	ΑΡΙΘΜΟΣ ΦΙΛΤΡΩΝ ΓΙΑ ΔΕΔΟΜΕΝΑ ΕΙΣΟΔΟΥ	ΑΡΙΘΜΟΣ ΠΑΡΑΜΕΤΡΩΝ ΕΚ/ΣΗΣ ΑΛΓΟΡΙΘΜΟΥ	ΤΙΜΕΣ ΕΞΟΔΟΥ
3	Γεωμαγνητικές & Solar Radio Flux	100	RNN	64	10.942	STEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	
	& Sunspot	100	RNN	64	10.942	VTEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	

7.4.1 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου STEC.


Στη συγκεκριμένη υποενότητα θα εξεταστεί ο βαθμός εκπαίδευσης των δικτύων RNN, LSTM, με διαφορετικό κάθε φορά αριθμό παραμέτρων εκπαίδευσης του αλγορίθμου. Μελετάται η ακρίβεια των δεδομένων εξόδου STEC.

7.4.1.1 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 64.

Τα αποτελέσματα της συγκεκριμένης περίπτωσης αποτυπώνονται στα κάτωθι γραφήματα.



Εικόνα 84. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης



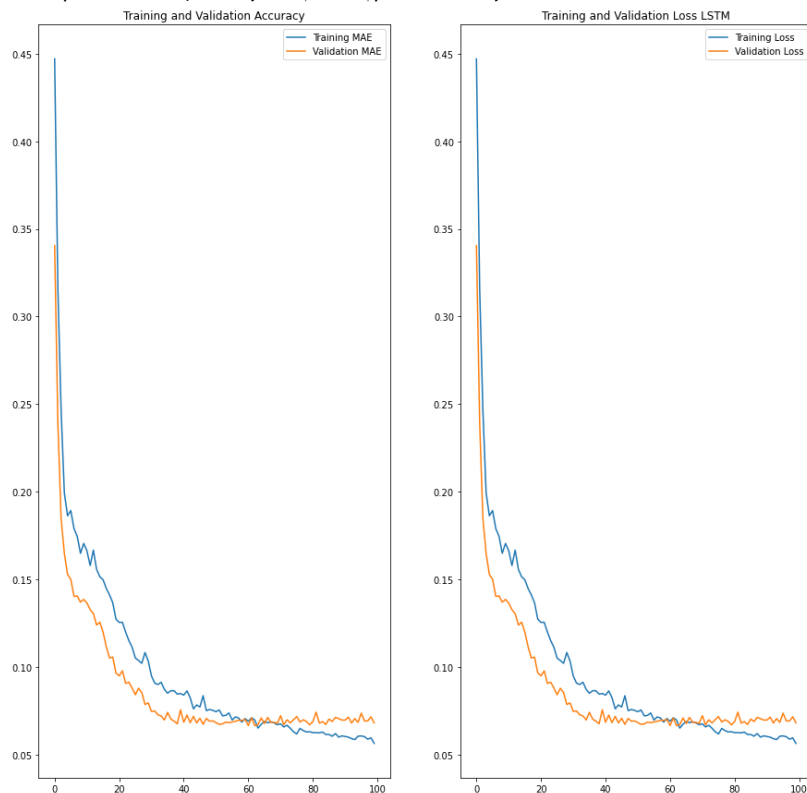
Εικόνα 85. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

Όπως φαίνεται λοιπόν στην Εικόνα 84, τα δεδομένα εκπαίδευσης ταυτίζονται με τα δεδομένα αξιολόγησης, και αυτό μας οδηγεί στο συμπέρασμα ότι το νευρωνικό δίκτυο έχει προσαρμοστεί κατάλληλα και εξάγει αξιόπιστα συμπεράσματα για τις τιμές εξόδου STEC. Βέβαια αξίζει να σημειωθεί πως ο βαθμός ταύτισης δεν είναι τόσο μεγάλος όσο στο Σενάριο 2. Το αποτέλεσμα είναι καλύτερο σε σχέση με το Σενάριο 1, αλλά όχι τόσο αξιόπιστο με το Σενάριο 2.


Ομοίως για το γράφημα της Εικόνας 85, παρατηρείται μέσω της γραμμικής παλινδρόμησης ότι το σφάλμα πρόβλεψης ελαχιστοποιείται καθώς δεν παρατηρούνται αρκετά χωρικά ακρότατα.

7.4.1.2 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 64.

Όμοια αποτελέσματα και για την προσαρμοστικότητα του δικτύου LSTM.



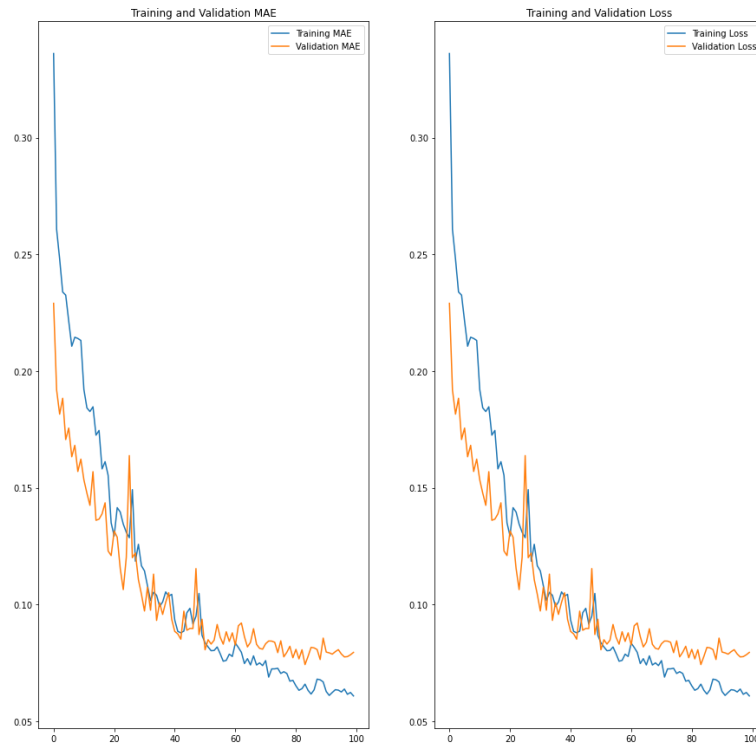
Εικόνα 86. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 87. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.4.1.3 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 128.

Παρατηρείται πως όσο αυξάνεται ο αριθμός των υπερπαραμέτρων (128) τόσο το δίκτυο υπερπροσαρμόζεται, κάτι το οποίο δεν είναι επιθυμητό. Το σφάλμα πρόβλεψης παραμένει ικανοποιητικό.



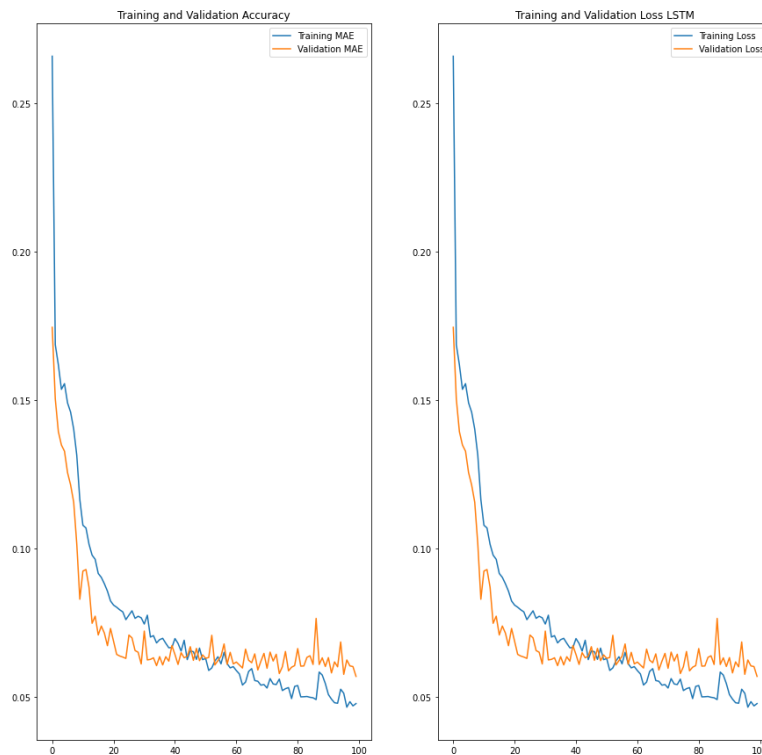
Εικόνα 88. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 89. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.4.1.4 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 128.

Όμοιες παρατηρήσεις με υποκεφάλαιο 7.3.1.3.




Εικόνα 90. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 91. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.4.1.5 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 256.

Όμοιες παρατηρήσεις με προηγούμενο υποκεφάλαιο




Εικόνα 92. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 93. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.4.1.6 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 256.

Όμοιες παρατηρήσεις με προηγούμενο υποκεφάλαιο



Εικόνα 94. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 95. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.4.1.7 Αξιολόγηση αποτελεσμάτων 1^{ου} σεναρίου για δεδομένα εξόδου STEC.

Με την περάτωση του 3^{ου} Σεναρίου, παρατηρήθηκαν τα κάτωθι:

- Η χρήση των δεδομένων από τις γεωμαγνητικές, solar radio flux και sunspot παραμέτρους επιρροής τιμών TEC αποδείχθηκε αρκετά ικανοποιητική.
- Το καλύτερο αποτέλεσμα προήλθε από την εκπαίδευση του RNN δικτύου με αριθμό υπερπαραμέτρων 64. Αξιοσημείωτο είναι πως το αποτέλεσμα είναι καλύτερο σε σχέση με το Σενάριο 1, αλλά όχι τόσο αξιόπιστο με το Σενάριο 2.

- Στο ακόλουθο γράφημα απεικονίζονται οι σχέσεις των τιμών MAE και MSE στις διάφορες υποκατηγορίες. Όσο πιο μικρός είναι ο αριθμός αυτών των δεικτών και όσο περισσότερο ταυτίζονται, τόσο καλύτερα προσδιορίζεται το μοντέλο. Φαίνεται και από το εν λόγω γράφημα πως το δίκτυο RNN προσδιόρισε με μεγαλύτερη ακρίβεια το μοντέλο.
- Επιπλέον σε αντίθεση με το Σενάριο 2, οι τιμές MAE και MSE είναι αρκετά πιο μεγάλες αριθμητικά, όπως στο Σενάριο 1. Οπότε συμπεραίνεται πως η είσοδος μόνο των γεωμαγνητικών, solar radio flux και sunspot παραμέτρων προσδιορίζουν πολύ καλύτερα το αποτέλεσμα σε σχέση με το 1^ο Σενάριο, αλλά όχι τόσο αξιόπιστα όπως το Σενάριο 2. Αυτό μπορεί να οφείλεται στην ποιότητα των δεδομένων της παραμέτρου sunspot.



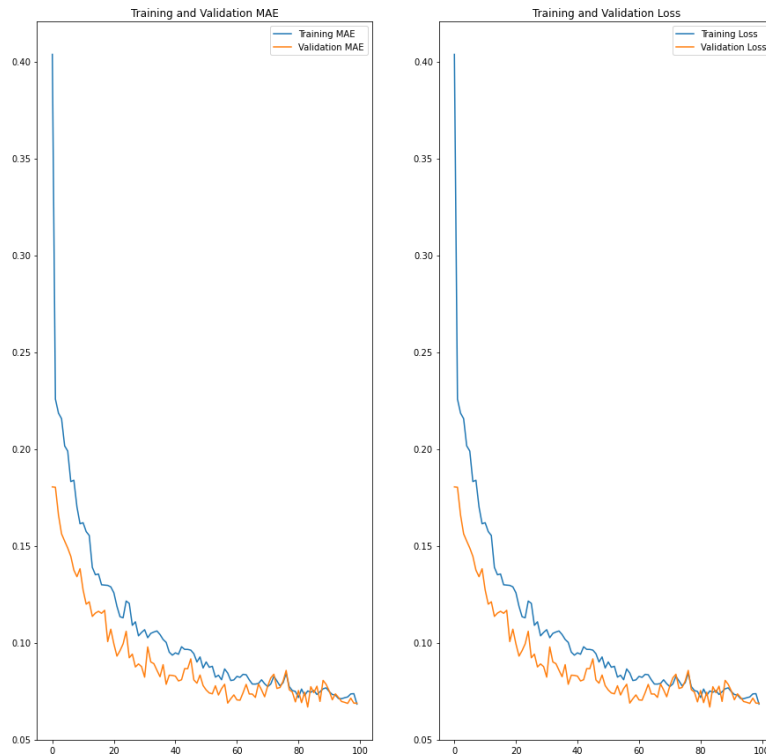
Εικόνα 96. Προσδιορισμός μοντέλου, μέσω των μετρητικών σχέσεων MSE-MAE

7.4.2 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου VTEC.


Στη συγκεκριμένη υποενότητα θα εξεταστεί ο βαθμός εκπαίδευσης των δικτύων RNN, LSTM, με διαφορετικό κάθε φορά αριθμό παραμέτρων εκπαίδευσης του αλγορίθμου. Μελετάται η ακρίβεια των δεδομένων εξόδου **VTEC**.

7.4.2.1 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 64.

Τα αποτελέσματα της συγκεκριμένης περίπτωσης αποτυπώνονται στα κάτωθι γραφήματα.



Εικόνα 97. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης

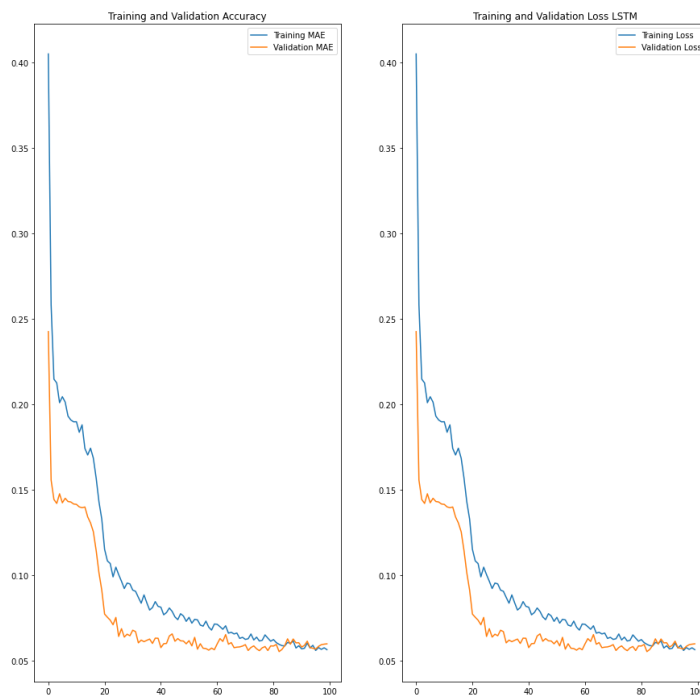


Εικόνα 98. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)


Όπως φαίνεται λοιπόν στην Εικόνα 97, τα δεδομένα εκπαίδευσης ταυτίζονται με τα δεδομένα αξιολόγησης. Ομοίως για το γράφημα της Εικόνας 98, παρατηρείται μέσω της γραμμικής παλινδρόμησης ότι το σφάλμα πρόβλεψης ελαχιστοποιείται καθώς δεν παρατηρούνται αρκετά χωρικά ακρότατα.

7.4.2.2 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 64.

Το δίκτυο LSTM φαίνεται να προσαρμόζεται ακόμη καλύτερα στις τιμές εισόδου καθώς τα δεδομένα εκπαίδευσης με τα αντίστοιχα αξιολόγησης τείνουν να ταυτιστούν, οι προβλέψεις των τιμών VTEC βρίσκονται όλες γύρω από την γραμμή παλινδρόμησης, χωρίς σχεδόν καθόλου χωρικά ακρότατα.



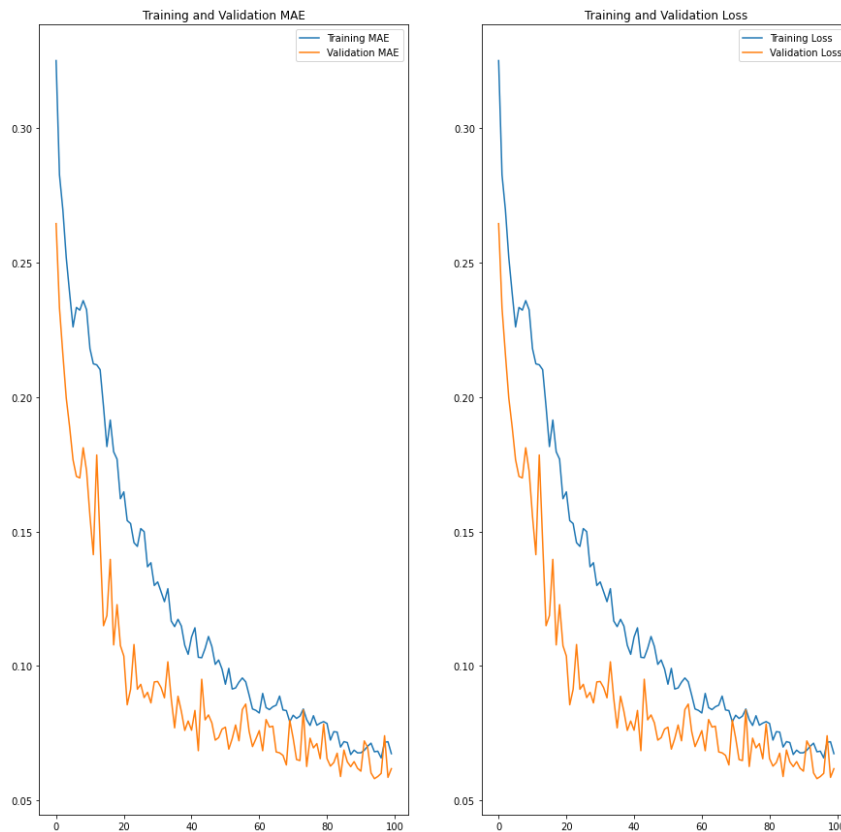
Εικόνα 99. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 100. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.4.2.3 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 128.

Παρατηρείται, πως όσο αυξάνεται ο αριθμός των παραμέτρων εκπαίδευσης του αλγορίθμου, τόσο αυξάνεται το σφάλμα στο σετ δεδομένων.



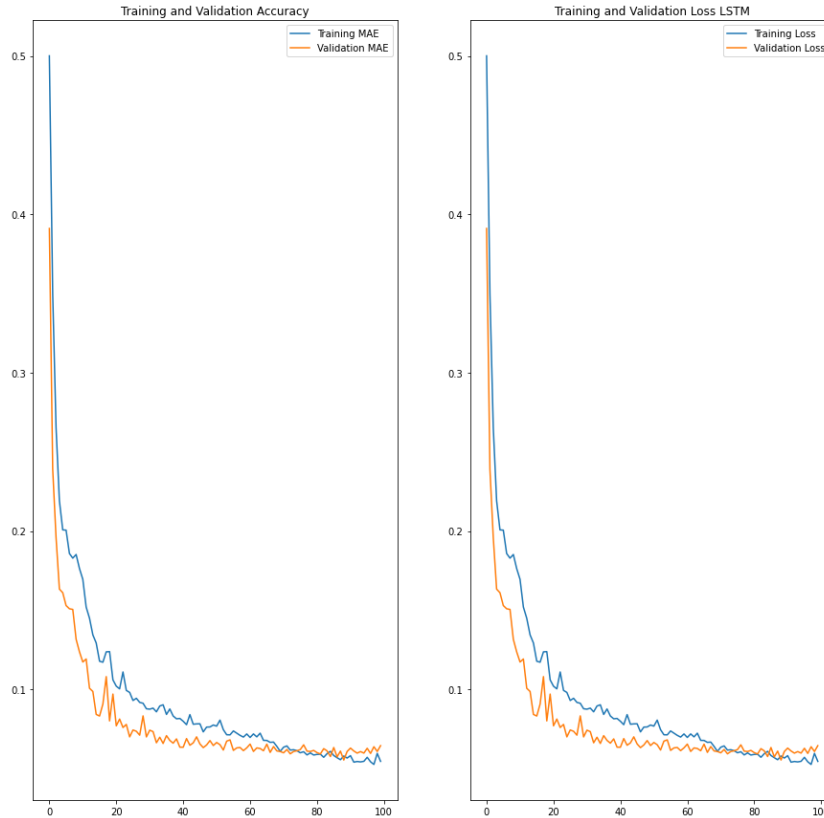
Εικόνα 101. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 102. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.4.2.4 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 128.

Ομοίως με προηγούμενο υποκεφάλαιο.




Εικόνα 103. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 104. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.4.2.5 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 256.

Στην εκπαίδευση του RNN δικτύου, παρόλο που όλα τα κριτήρια είναι ίδια όπως προηγουμένως, παρατηρείται ακόμα χειρότερη προσαρμογή του σετ δεδομένων, καθώς τα δεδομένα εκπαίδευσης και αξιολόγησης αποκλίνουν ακόμα περισσότερο (Εικόνα 105). Τα χωρικά ακρότατα δείχνουν να παραμένουν τα ίδια (Εικόνα 106).



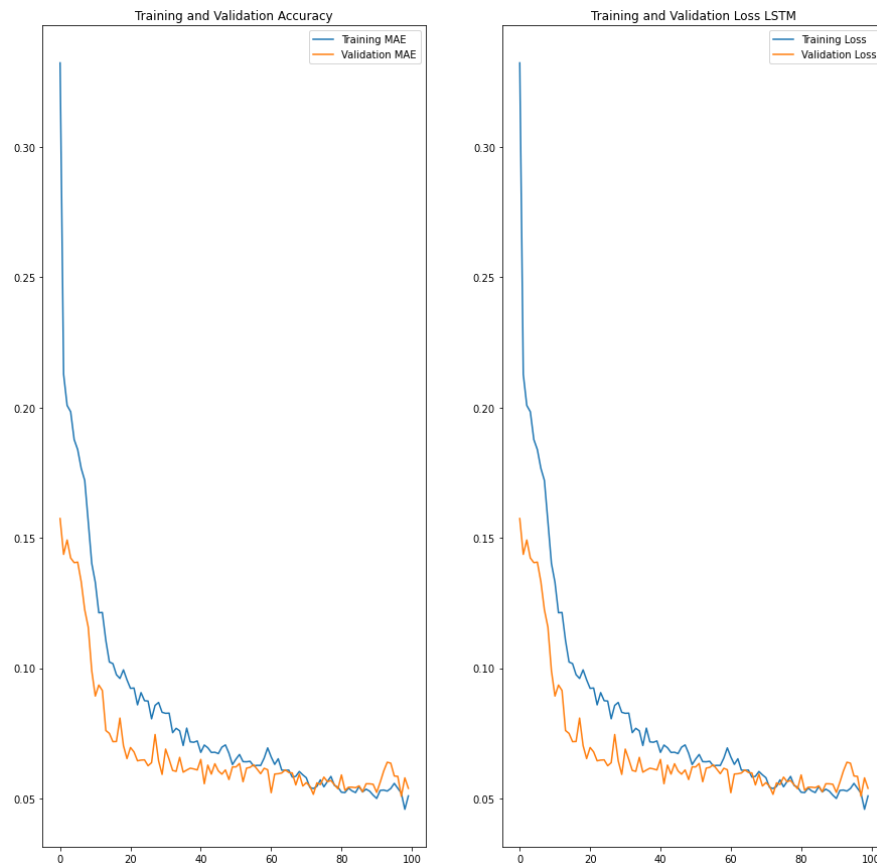
Εικόνα 105. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 106. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.4.2.6 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 256.

Αντίθετα με προηγουμένως το LSTM δίκτυο προσαρμόζεται καλύτερα σε σχέση με το RNN.



Εικόνα 107. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 108. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.4.2.7 Αξιολόγηση αποτελεσμάτων 3^{ου} σεναρίου για δεδομένα εξόδου VTEC.

Με την περάτωση του 3^{ου} Σεναρίου, παρατηρήθηκαν τα κάτωθι:

- Η χρήση των δεδομένων από τις γεωμαγνητικές, solar radio flux και sunspot παραμέτρους επιρροής τιμών TEC αποδείχθηκε αρκετά ικανοποιητική.
- Το καλύτερο αποτέλεσμα προήλθε από την εκπαίδευση του RNN και LSTM δικτύου με αριθμό υπερπαραμέτρων 64. Αξιοσημείωτο είναι πως το αποτέλεσμα είναι καλύτερο τόσο σε σχέση με το Σενάριο 1όσο και με το Σενάριο 2.
- Στο ακόλουθο γράφημα απεικονίζονται οι σχέσεις των τιμών MAE και MSE στις διάφορες υποκατηγορίες. Όσο πιο μικρός είναι ο αριθμός αυτών των δεικτών και όσο περισσότερο ταυτίζονται, τόσο καλύτερα προσδιορίζεται το μοντέλο. Φαίνεται και από το εν λόγω γράφημα πως το δίκτυο RNN προσδιόρισε με μεγαλύτερη ακρίβεια το μοντέλο.
- Επιπλέον όπως και στο Σενάριο 2, οι τιμές MAE και MSE είναι αρκετά μικρές αριθμητικά και ταυτίζονται ιδιαίτερα στην εκπαίδευση των νευρωνικών δικτύων με τις λιγότερες παραμέτρους εκπαίδευσης.. Οπότε συμπεραίνεται πως η είσοδος μόνο των γεωμαγνητικών, solar radio flux και sunspot παραμέτρων για προσδιορισμό ακρίβειας τιμών εξόδου VTEC, προσδιορίζουν πολύ καλύτερα το αποτέλεσμα σε σχέση με τα προηγούμενα σενάρια.



Εικόνα 109. Προσδιορισμός μοντέλου, μέσω των μετρητικών σχέσεων MSE-MAE

7.5 Σενάριο 4^ο (για τον μήνα Ιανουάριου 2018)

Κατά τη διεξαγωγή του τέταρτου σεναρίου, επιλέχθηκαν να εισαχθούν στο νευρωνικό δίκτυο, τα δεδομένα από τις Γεωμαγνητικές και τις Coronal Mass Ejections παραμέτρους επιρροής των τιμών TEC. Αναλυτικά ο τρόπος διεξαγωγής του Σεναρίου Νο4 στον Πίνακα 7.

Πίνακας 7. Τέταρτο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας


ΣΕΝΑΡΙΟ	ΠΑΡΑΜΕΤΡΟΙ	ΑΡΙΘΜΟΣ ΕΠΟΧΩΝ	ΠΡΟΣ ΕΚΠ/ΣΗ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ	ΑΡΙΘΜΟΣ ΦΙΛΤΡΩΝ ΓΙΑ ΔΕΔΟΜΕΝΑ ΕΙΣΟΔΟΥ	ΑΡΙΘΜΟΣ ΠΑΡΑΜΕΤΡΩΝ ΕΚ/ΣΗΣ ΑΛΓΟΡΙΘΜΟΥ	ΤΙΜΕΣ ΕΞΟΔΟΥ
4	Γεωμαγνητικές & Coronal Mass Ejections	100	RNN	64	10.942	STEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	
			RNN	64	10.942	VTEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	

7.5.1 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου STEC.


Στη συγκεκριμένη υποενότητα θα εξεταστεί ο βαθμός εκπαίδευσης των δικτύων RNN, LSTM, με διαφορετικό κάθε φορά αριθμό παραμέτρων εκπαίδευσης του αλγορίθμου. Μελετάται η ακρίβεια των δεδομένων εξόδου **STEC**.

7.5.1.1 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 64.

Τα αποτελέσματα της συγκεκριμένης περίπτωσης αποτυπώνονται στα κάτωθι γραφήματα.



Εικόνα 110. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 111. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)


Όπως φαίνεται λοιπόν στην Εικόνα 110 τα δεδομένα εκπαίδευσης δεν ταυτίζονται σε καμία περίπτωση με τα δεδομένα αξιολόγησης, και αυτό μας οδηγεί στο συμπέρασμα ότι το νευρωνικό δίκτυο δεν έχει προσαρμοστεί κατάλληλα. Ομοίως για το γράφημα της Εικόνας 111, παρατηρείται μέσω της γραμμικής παλινδρόμησης ότι το σφάλμα πρόβλεψης είναι το μέγιστο από τα μέχρι τώρα σενάρια καθώς υπάρχουν μόνο χωρικά ακρότατα.

7.5.1.2 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 64.

Όμοια αποτελέσματα και για την προσαρμοστικότητα του δικτύου LSTM.




Εικόνα 112. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 113. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.5.1.3 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 128.

Όμοιες παρατηρήσεις με υποκεφάλαιο 7.4.1.2.



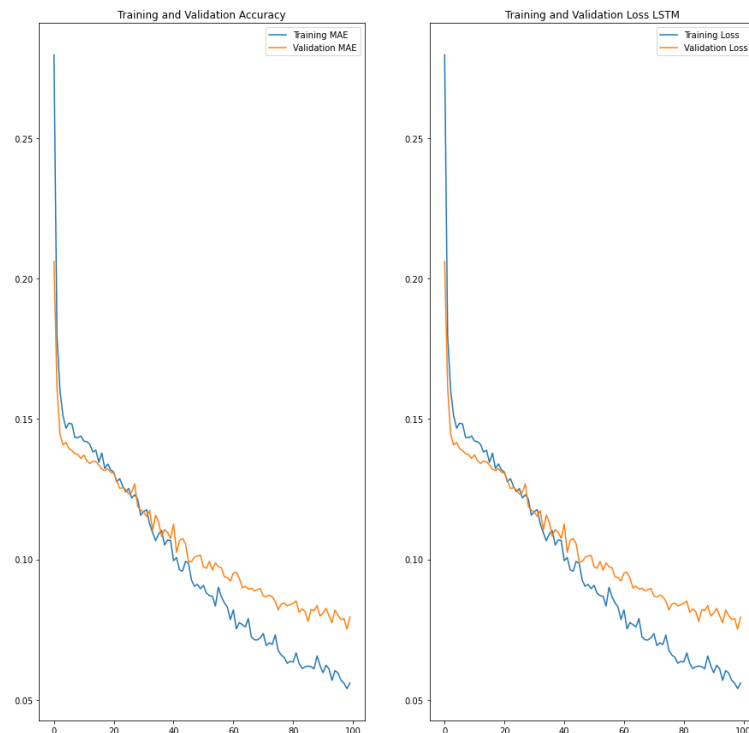
Εικόνα 114. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 115. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.5.1.4 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 128.

Όμοιες παρατηρήσεις με υποκεφάλαιο 7.4.1.2.




Εικόνα 116. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 117. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.5.1.5 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 256.

Όμοιες παρατηρήσεις με προηγούμενο υποκεφάλαιο



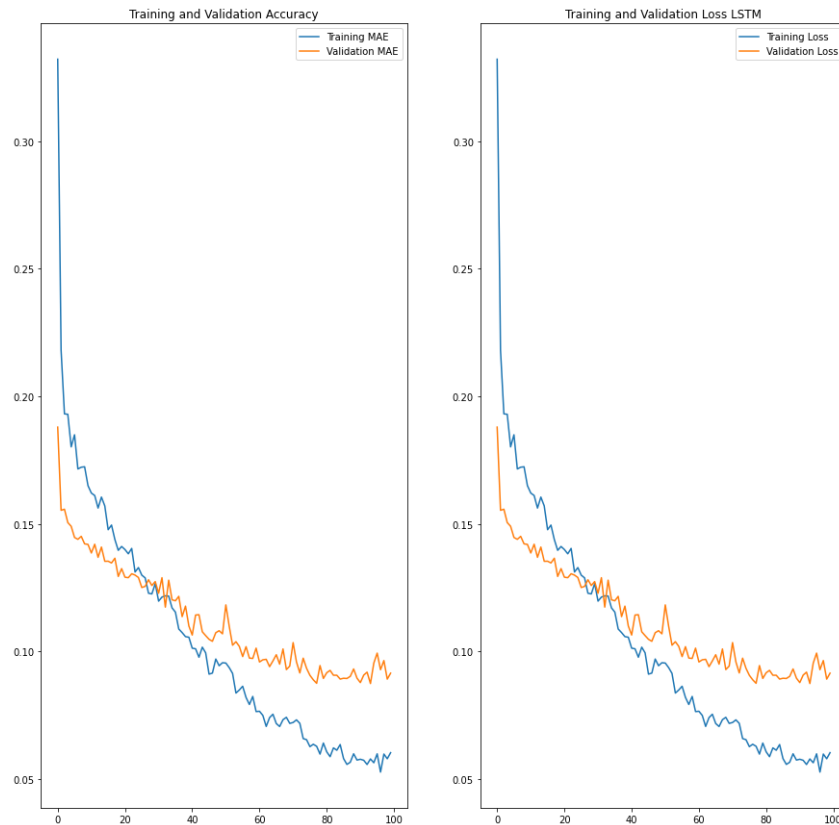
Εικόνα 118. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 119. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.5.1.6 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 256.

Όμοιες παρατηρήσεις με προηγούμενο υποκεφάλαιο



Εικόνα 120. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης



Εικόνα 121. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)


7.5.1.7 Αξιολόγηση αποτελεσμάτων 1^{ου} σεναρίου για δεδομένα εξόδου STEC.

Με την περάτωση του 4^{ου} Σεναρίου, παρατηρήθηκαν τα κάτωθι:

- Η χρήση των δεδομένων από τις γεωμαγνητικές, και coronal mass ejections παραμέτρους επιρροής τιμών TEC αποδείχθηκε χείριστη. Αυτό μπορεί να οφείλεται στο γεγονός των δεδομένων της παραμέτρου Coronal Mass Ejection ή

κατά κύριο λόγο στην έλλειψη της παραμέτρου Solar Radio Flux από τις παραμέτρους εισόδου στο νευρωνικό δίκτυο.

- Στο ακόλουθο γράφημα απεικονίζονται οι σχέσεις των τιμών MAE και MSE στις διάφορες υποκατηγορίες. Όσο πιο μικρός είναι ο αριθμός αυτών των δεικτών και όσο περισσότερο ταυτίζονται, τόσο καλύτερα προσδιορίζεται το μοντέλο. Φαίνεται και από το εν λόγω γράφημα πως το δίκτυο RNN προσδιόρισε με μεγαλύτερη ακρίβεια το μοντέλο.
- Επιπλέον σε αντίθεση με τα προηγούμενα σενάρια, οι τιμές MAE και MSE είναι αρκετά μεγάλες και σε καμία περίπτωση δεν συμβαδίζουν μεταξύ τους. Οπότε συμπεραίνεται πως η παράμετρος Solar Radio Flux είναι υψίστης σημασίας για την ομαλή έκβαση των αποτελεσμάτων




Εικόνα 122. Προσδιορισμός μοντέλου, μέσω των μετρητικών σχέσεων MSE-MAE

7.5.2 Αποτελέσματα εκπαίδευσης δικτύων RNN και LSTM για δεδομένα εξόδου VTEC.


Στη συγκεκριμένη υποενότητα θα εξεταστεί ο βαθμός εκπαίδευσης των δικτύων RNN, LSTM, με διαφορετικό κάθε φορά αριθμό παραμέτρων εκπαίδευσης του αλγορίθμου. Μελετάται η ακρίβεια των δεδομένων εξόδου **VTEC**.

7.5.2.1 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 64.

Τα αποτελέσματα της συγκεκριμένης περίπτωσης αποτυπώνονται στα κάτωθι γραφήματα.



Εικόνα 123. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης

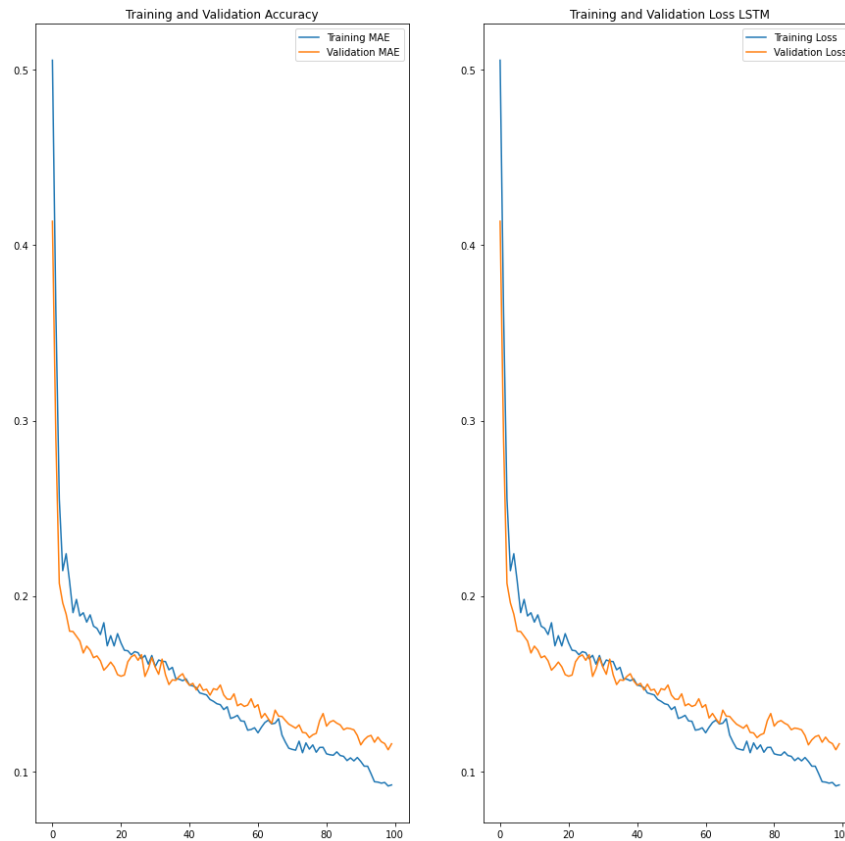


Εικόνα 124. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)


Όπως φαίνεται λοιπόν στα γραφήματα, τα αποτελέσματα είναι ίδια με αυτά του υποκεφαλαίου 7.4.1

7.5.2.2 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 64.

Ομοίως με προηγούμενο υποκεφάλαιο.




Εικόνα 125. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 126. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.5.2.3 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 128.

Ομοίως με προηγούμενο υποκεφάλαιο.



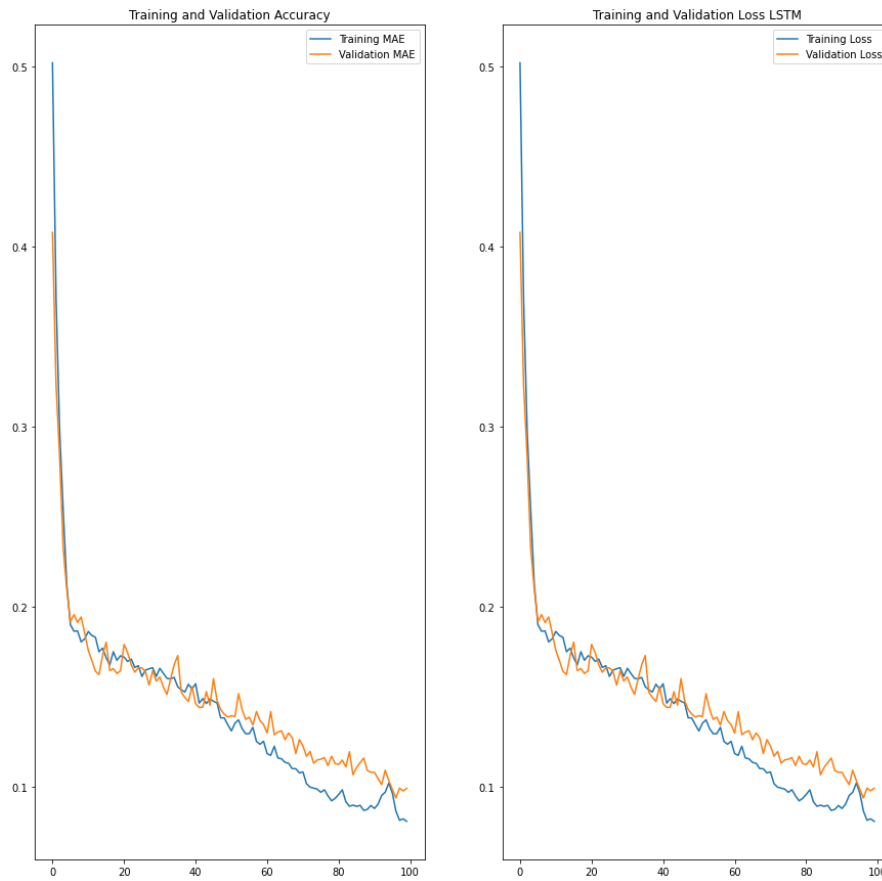
Εικόνα 127. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 128. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.5.2.4 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 128.

Ομοίως με προηγούμενο υποκεφάλαιο.




Εικόνα 129. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 130. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.5.2.5 Αποτελέσματα εκπαίδευσης δικτύου RNN, με αριθμό υπερπαραμέτρων 256.

Ομοίως με προηγούμενο υποκεφάλαιο.




Εικόνα 131. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης




Εικόνα 132. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.5.2.6 Αποτελέσματα εκπαίδευσης δικτύου LSTM, με αριθμό υπερπαραμέτρων 256.

Ομοίως με προηγούμενο υποκεφάλαιο.




Εικόνα 133. Ποιότητα σφάλματος στα σετ δεδομένων αξιολόγησης και εκπαίδευσης



Εικόνα 134. Σφάλμα πρόβλεψης των δεδομένων (γραμμική παλινδρόμηση)

7.5.2.7 Αξιολόγηση αποτελεσμάτων 4^{ου} σεναρίου για δεδομένα εξόδου VTEC.

Με την περάτωση του 4^{ου} Σεναρίου, παρατηρήθηκε ότι είναι το σενάριο με τα χειρότερα αποτελέσματα τόσο για δεδομένα εξόδου STEC όσο και για VTEC



Εικόνα 135. Προσδιορισμός μοντέλου, μέσω των μετρητικών σχέσεων MSE-MAE

Σε αυτό το σημείο, θεωρήθηκε σκόπιμο να μην παρατεθούν και τα διαγραμματικά αποτελέσματα των υπόλοιπων σεναρίων στο κύριο σώμα της Διπλωματικής εργασίας, καθόσον από τα προαναφερθέντα σενάρια, εντοπίστηκαν οι παράμετροι επιρροής των τιμών TEC με το μεγαλύτερο βάρος-αξία για την παραγωγή ορθών και ακριβή αποτελεσμάτων. Παρατίθενται επιγραμματικά ο αριθμός του σεναρίου και οι παράμετροι επιρροής tec που συνδυάστηκαν σε καθ' ένα από αυτά. Τα διαγραμματικά αποτελέσματα των υπόλοιπων σεναρίων για τον μήνα Ιανουάριο 2018, όσο και για τους μήνες Φεβρουάριο και Μάρτιο, τοποθετηθήκαν στο Παράρτημα Β της παρούσας διπλωματικής εργασίας.

7.6 Σενάριο 5^ο (για τον μήνα Ιανουάριου 2018)

Κατά τη διεξαγωγή του πέμπτου σεναρίου, επιλέχθηκαν να εισαχθούν στο νευρωνικό δίκτυο, τα δεδομένα από τις Γεωμαγνητικές, solar radio flux, solar flares και Coronal Mass Ejections παραμέτρους επιρροής των τιμών TEC. Αναλυτικά ο τρόπος διεξαγωγής του Σεναρίου Νο5 στον Πίνακα 8.

Πίνακας 8. Πέμπτο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας

ΣΕΝΑΡΙΟ	ΠΑΡΑΜΕΤΡΟΙ	ΑΡΙΘΜΟΣ ΕΠΟΧΩΝ	ΠΡΟΣ ΕΚΠ/ΣΗ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ	ΑΡΙΘΜΟΣ ΦΙΛΤΡΩΝ ΓΙΑ ΔΕΔΟΜΕΝΑ ΕΙΣΟΔΟΥ	ΑΡΙΘΜΟΣ ΠΑΡΑΜΕΤΡΩΝ ΕΚ/ΣΗΣ ΑΛΓΟΡΙΘΜΟΥ	ΤΙΜΕΣ ΕΞΟΔΟΥ
5	Γεωμαγνητικές & Solar Radio Flux & Solar flares & Coronal Mass Ejections	100	RNN	64	10.942	STEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	
			RNN	64	10.942	VTEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	

7.7 Σενάριο 6^ο (για τον μήνα Ιανουάριου 2018)

Κατά τη διεξαγωγή του έκτου σεναρίου, επιλέχθηκαν να εισαχθούν στο νευρωνικό δίκτυο, τα δεδομένα από τις Γεωμαγνητικές, solar radio flux και Coronal Mass Ejections παραμέτρους επιρροής των τιμών TEC. Αναλυτικά ο τρόπος διεξαγωγής του Σεναρίου Νο6 στον Πίνακα 9.

Πίνακας 9. Έκτο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας

ΣΕΝΑΡΙΟ	ΠΑΡΑΜΕΤΡΟΙ	ΑΡΙΘΜΟΣ ΕΠΟΧΩΝ	ΠΡΟΣ ΕΚΠ/ΣΗ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ	ΑΡΙΘΜΟΣ ΦΙΛΤΡΩΝ ΓΙΑ ΔΕΔΟΜΕΝΑ ΕΙΣΟΔΟΥ	ΑΡΙΘΜΟΣ ΠΑΡΑΜΕΤΡΩΝ ΕΚ/ΣΗΣ ΑΛΓΟΡΙΘΜΟΥ	ΤΙΜΕΣ ΕΞΟΔΟΥ
6	Γεωμαγνητικές & Solar Radio Flux & Coronal Mass Ejections	100	RNN	64	10.942	STEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	
			RNN	64	10.942	VTEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	

7.8 Σενάριο 7^ο (για τον μήνα Ιανουάριου 2018)

Κατά τη διεξαγωγή του έβδομου σεναρίου, επιλέχθηκαν να εισαχθούν στο νευρωνικό δίκτυο, τα δεδομένα από τις solar radio flux Sunspot Number και Energetic Particle Flux παραμέτρους επιρροής των τιμών TEC. Αναλυτικά ο τρόπος διεξαγωγής του Σεναρίου No7 στον Πίνακα 10.

Πίνακας 10. Έβδομο σενάριο συνδυασμού παραμέτρων αξιολόγησης ιονόσφαιρας

ΣΕΝΑΡΙΟ	ΠΑΡΑΜΕΤΡΟΙ	ΑΡΙΘΜΟΣ ΕΠΟΧΩΝ	ΠΡΟΣ ΕΚΠ/ΣΗ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ	ΑΡΙΘΜΟΣ ΦΙΛΤΡΩΝ ΓΙΑ ΔΕΔΟΜΕΝΑ ΕΙΣΟΔΟΥ	ΑΡΙΘΜΟΣ ΠΑΡΑΜΕΤΡΩΝ ΕΚ/ΣΗΣ ΑΛΓΟΡΙΘΜΟΥ	ΤΙΜΕΣ ΕΞΟΔΟΥ
7	Solar Radio Flux & Sunspot Number & Energetic Particle Flux	100	RNN	64	10.942	STEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	
			RNN	64	10.942	VTEC
				128	38.206	
				256	141.886	
			LSTM	64	37.222	
				128	139.750	
				256	541.414	

7.9 Συγκρίσεις πειραματικών δεδομένων – Σεναρίων

Αφού λοιπόν παρατέθηκαν τα αποτελέσματα και των επτά (7) σεναρίων, οδηγηθήκαμε στα κάτωθι συμπεράσματα:

- Το νευρωνικό δίκτυο LSTM, με μικρό αριθμό υπερπαραμέτρων (64) έδειξε να προσαρμόζεται καταλληλότερα στα δεδομένα εισόδου των παραμέτρων, καθώς εξήγαγε πιο ακριβής τιμές σε σχέση με το νευρωνικό δίκτυο RNN
- Ο βέλτιστος συνδυασμός παραμέτρων επιρροής των τιμών TEC, που εισήχθησαν ως δεδομένα εισόδου, για την αξιολόγηση και ακρίβεια των δεδομένων εξόδου STEC ήταν αυτός του Σεναρίου 2. Πιο αναλυτικά αποδείχθηκε πως οι γεωμαγνητικές και οι Solar Radio Flux παράμετροι έχουν το σημαντικότερο βάρος για την ορθή και αξιόπιστη εκπαίδευση των νευρωνικών δικτύων, και ταυτόχρονα η έλλειψη μίας εκ των δύο αυτών παραμέτρων από τα δεδομένα εισόδου του δικτύου, οδηγεί σε αναξιόπιστα αποτελέσματα.

- Αντίστοιχα για τα δεδομένα εξόδου τιμών VTEC, ο συνδυασμός των παραπάνω παραμέτρων μαζί με την παράμετρο Sunspot (Σενάριο 3), υπήρξε ο βέλτιστος.
- Και στις δύο περιπτώσεις οι τιμές MAE και MSE ήταν πολύ μικρές αριθμητικά και σχεδόν ταυτίζονταν. Έτσι λοιπόν προσδιορίζονταν σε μεγάλο βαθμό ικανοποιητικά οι τιμές εξόδου.
- Τα σετ δεδομένων αξιολόγησης και εκπαίδευσης των νευρωνικών δικτύων συμβάδιζαν, δεν υπήρχαν μεγάλες αποκλίσεις κάτι το οποίο αποδείκνυε πως το δίκτυο δεν υπερπροσαρμοζόταν δηλαδή οι παράμετροι εισαγωγής ήταν ικανοποιητικοί τόσο σε αριθμό όσο και σε ποιότητα δεδομένων.

Κεφάλαιο 8^ο Συμπεράσματα

Στην ακόλουθη διπλωματική εργασία αντιμετωπίστηκε το πρόβλημα του αυτόματου προσδιορισμού του ιονοσφαιρικού σφάλματος. Η παραπάνω διπλωματική εργασία απέδειξε πως είναι εφικτό για έναν αλγόριθμο να αξιολογεί «έξυπνα» διάφορες παραμέτρους, με την βοήθεια της βαθιάς μάθησης και συγκεκριμένα των πλήρως επαναλαμβανόμενων νευρωνικών δικτύων.

Οι αλγόριθμοι που χρησιμοποιήθηκαν (RNN και το LSTM) ήταν νέοι και καινοτόμοι αλγόριθμοι και είχαν ως στόχο την επιλογή του βέλτιστου συνδυασμού παραμέτρων επιρροής της ιονόσφαιρας για τον βέλτιστο προσδιορισμό τιμών STEC και VTEC .

Παράλληλα η συγκεκριμένη διπλωματική εργασία, απέδειξε πως μια τόσο δύσκολη και επίπονη διαδικασία, μπορεί να γίνει με ελάχιστη προεπεξεργασία, με μία απλή λήψη αρχικών δεδομένων από το διαδίκτυο, σε μια χαμηλού κόστους υπολογιστική μονάδα.

Το γεγονός πως η γλώσσα προγραμματισμού είναι η python, προσφέρει δύο μεγάλα πλεονέκτημα στην αντιμετώπιση του παραπάνω προβλήματος. Το πρώτο πλεονέκτημα είναι η φύση της γλώσσας, δηλαδή είναι ένα ανοιχτού κώδικα εργαλείο με τρομερές δυνατότητες προσφέροντας με μηδενικό κόστος εργαλεία και βιβλιοθήκες για επεξεργασία. Το δεύτερο πλεονέκτημα αφορά τα αναφερόμενα εργαλεία και οι βιβλιοθήκες, το Tensorflow και το Keras, προσφέρουν συναρτήσεις που κάνουν ειδικά τον προγραμματισμό νευρωνικών δεικτών εφικτό σε επαγγελματίες χρήστες και μη.

Σε μελλοντικά σχέδια κρίνεται απαραίτητη η μελέτη ακόμα περισσότερων δεδομένων, πολύ περισσότερων ετών για την εξαγωγή αξιόπιστων αποτελεσμάτων ακόμα και σε ακραία φαινόμενα και τη ενδελεχή μελέτη της απόκρισης της ιονόσφαιρας σε αυτά.

Αναφορές

[1] Siyu Tang, Zhi Huang, and Hong Yuan. Improving regional ionospheric tec mapping based on rbf interpolation. *Advances in Space Research*, 67(2):722–730, 2021.

[2] GPS και Γεωδαιτικές Εφαρμογές, Αριστείδης Ι. Φωτίου, Χρήστος Κ. Πικριδάς

[3] Performance evaluation of neural network TEC forecasting models over equatorial low-latitude Indian GNSS station. Sivavaraprasad*, V.S. Deepika, D. SreenivasaRao, M. Ravi Kumar, M. Sridhar

[4] *Research Article* Prediction of Ionospheric TEC Based on the NARX Neural Network
Liu Guoyan,¹ Gao Wang,² Zhang Zhengxie,² and Zhao Qing²
Nanjing Vocational University of Industry Technology, Nanjing 210000, China
South and East University, Nanjing 210000, China
Correspondence should be addressed to Liu Guoyan; 2296813027@qq.com
Received 27 August 2021; Revised 1 October 2021; Accepted 15 October 2021; Published 31 October 2021

[5] Predicting the Effects of Solar Storms on the Ionosphere Based on a Comparison of Real-Time Solar Wind Data with the Best-Fitting Historical Storm Event Erik Schmölder * and Jens Berdermann

[6] Statistical analysis of an ionospheric parameter as a base for earthquake prediction
Mei Li^{1,2,3} and Michel Parrot¹ Received 4 October 2012; revised 23 March 2013; accepted 3 May 2013; published 19 June 2013.

[7] Pedro Lara-Benitez, Manuel Carranza-Garcva, and Josu Riquelme. An experimental review on deep learning architectures for time series forecasting. *International Journal of Neural Systems*, 31, 11 2020.

[8] Deep Learning, Ian Goodfellow, Yoshua Bengio, Aaron Courville

[9] Jeffrey M Forbes, Scott E Palo, and Xiaoli Zhang. Variability of the ionosphere. *Journal of Atmospheric and Solar-Terrestrial Physics*, 62(8):685–693, 2000.

[10] Hu Jiang, Jingbin Liu, Zemin Wang, Jiachun An, Jikun Ou, Shulun Liu, and Ningbo Wang. Assessment of spatial and temporal tec variations derived from ionospheric models over the polar regions. *Journal of Geodesy*, 93(4):455–471, 2019.

[11] Siyu Tang, Zhi Huang, and Hong Yuan. Improving regional ionospheric tec mapping based on rbf interpolation. *Advances in Space Research*, 67(2):722–730, 2021.

[12] John A Klobuchar. Ionospheric time-delay algorithm for single-frequency gps users. *IEEE Transactions on aerospace and electronic systems*, (3):325–331, 1987.

[13] Manuel Hernandez-Pajares, J. Miguel Juan, Jaume Sanz, ñngela Aragón-ñngel, Alberto Garcva-Rigo, Dagoberto Salazar, and Miquel Escudero. The ionosphere: effects, GPS modeling and the benefits for space geodetic techniques. *Journal of Geodesy*, 85(12):887–907, December 2011.

- [14] S. Wang, L. Liu, Liangke Huang, Y. Yang, and H. Peng. Performance evaluation of ionospheric tec forecasting models using gps observations at different latitudes. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII- 3/W10:1175–1182, 02 2020.
- [15] M. Kaselimi, N. Doulamis, A. Voulodimos, E. Protopapadakis, and A. Doulamis. Context aware energy disaggregation using adaptive bidirectional lstm models. *IEEE Transactions on Smart Grid*, 11(4):3054–3067, 2020.
- [16] J. Space Weather Space Clim. 2 (2012) A22 Monitoring, tracking and forecasting ionospheric perturbations using GNSS techniques
- [17] Forecasting Global Ionospheric TEC Using Deep Learning Approach, [Lei Liu](#),[Shasha Zou](#),[Yibin Yao](#),[Zihan Wang](#)
- [18] Forecasting the occurrence of ionospheric scintillation activity in the equatorial ionosphere on a day-to-day basis Author links open overlay panelDavid N.Anderson^aBodoReinisch^bCesarValladares^cJorgeChau^dOscarVeliz^d
- [19] Forecasting of ionospheric TEC for different latitudes, seasons and solar activity conditions based on OKSMR. Mukesh, V. Karthikeyan, P. Soma & P. Sindhu *Astrophysics and Space Science* volume 365, Article number: 13 (2020)
- 20] Ionospheric specification and forecasting based on observations from European ionosondes participating in DIAS project Anna BELEHAKI1 , Ljiljana CANDER2 , Bruno ZOLESI3 , Juergen BREMER4 , Christer JUREN5 , Iwona STANISŁAWSKA6 , Dimitris DIALETIS7 and Michael HATZOPOULOS7
- [21] Forecasting the ionospheric f_oF_2 parameter one hour ahead using a support vector machine technique Author links open overlay panelChunChen^{ab}ZhensenWu^aShujiSun^bPanpanBan^bZhonghuaDing^bZhengwenXu^b
- [22] A Causal Long Short-Term Memory Sequence to Sequence Model for TEC Prediction Using GNSS Observations Maria Kaselimi 1,* , Athanasios Voulodimos 2 , Nikolaos Doulamis 1 , Anastasios Doulamis 1 and Demitris Delikaraoglou 1
- [23] S. Haykin, *Neural networks and learning machines*, 3/E. Pearson Education India, 2010.
- [24] “Deep learning,” *Wikipedia*. Sep. 20, 2021. Accessed: Oct. 03, 2021. [Online]. Available: https://en.wikipedia.org/w/index.php?title=Deep_learning&oldid=1045496580
- [25] W. J. Zhang, G. Yang, Y. Lin, C. Ji, and M. M. Gupta, “On Definition of Deep Learning,” in *2018 World Automation Congress (WAC)*, Jun. 2018, pp. 1–5. doi: 10.23919/WAC.2018.8430387.
- [26] Jeffrey M Forbes, Scott E Palo, and Xiaoli Zhang. Variability of the ionosphere. *Journal of Atmospheric and Solar-Terrestrial Physics*, 62(8):685–693, 2000.
- [27] Hochreiter, S.; Jürgen, S. Long Short-Term Memory. *Neural Comput.* 1997, 8, 1735–1780.

[28] Gers, F.A.; Schmidhuber, J.; Cummins, F. Learning to Forget: Continual Prediction with LSTM. In 1999 Ninth International Conference on Artificial Neural Networks ICANN; IET: London, UK, 1999.

[29] GPS-TEC analysis application *Developed by Dr. Gopi Krishna Seemala Indian Institute of Geomagnetism (IIG), Navi Mumbai, India Previous affiliations: Research Institute for Sustainable Humanosphere (RISH), Kyoto University, Kyoto, Japan Institute for Scientific Research, Boston College, Boston, U.S.A.*

[30] Randa Natras, Michael Schmidt. Machine Learning Model Development for Space Weather Forecasting in the Ionosphere. 2021

[31] Changqing Cheng, Akkarapol Sa-Ngasoongsong, Omer Beyca, Trung Le, Hui Yang, Zhenyu Kong, and Satish Bukkapatnam. Time series forecasting for nonlinear and nonstationary processes: A review and comparative study. IIE Transactions, 01 2015.

[32] George C Tiao and George EP Box. Modeling multiple time series with applications. journal of the American Statistical Association, 76(376):802–816, 1981.

[33] J. Lawrence C Hamilton, Cliff Brown, and Barry D Keim. Ski areas, weather and climate: time series models for new england case studies. International Journal of Climatology: A Journal of the Royal Meteorological Society, 27(15):2113–2124, 2007.

[34] Giovanni Sparacino, Francesca Zanderigo, Stefano Corazza, Alberto Maran, Andrea Facchinetti, and Claudio Cobelli. Glucose concentration can be predicted ahead in time from continuous glucose monitoring sensor time-series. IEEE Transactions on biomedical engineering, 54(5):931–937, 2007.

[35] Nikolay Laptev, Saeed Amizadeh, and Ian Flint. Generic and scalable framework for automated time-series anomaly detection. In Proceedings of the 21th ACM SIGKDD international conference on knowledge discovery and data mining, pages 1939–1947, 2015.

[36] Ke Su, Shuanggen Jin, and M. M. Hoque. Evaluation of ionospheric delay effects on multi-gnss positioning performance. Remote Sensing, 11(2), 2019.

[37] Rongxin Tang, Fantao Zeng, Zhou Chen, Jing-Song Wang, Chun-Ming Huang, and Zhiping Wu. The comparison of predicting storm-time ionospheric tec by three methods: Arima, lstm, and seq2seq. Atmosphere, 11(4):316, 2020.

[38] P. T. Newell, J. W. Gjerloev. Evaluation of SuperMAG auroral electrojet indices as indicators of substorms and auroral power. 2011

[39] Schmölder E., Berdermann J. Predicting the Effects of Solar Storms on the Ionosphere Based on a Comparison of Real-Time Solar Wind Data with the Best-Fitting. 2021

[40] Milan, S.E.; Clausen, L.B.N.; Coxon, J.C.; Carter, J.A.; Walach, M.T.; Laundal, K.; Østgaard, N.; Tenfjord, P.; Reistad, J.; Snekvik, K.; et al. Overview of Solar Wind-Magnetosphere-Ionosphere-Atmosphere Coupling and the Generation of Magnetospheric Currents. *Space Sci. Rev.* 2017, 206, 547–573.

- [41] Borovsky, J.E.; Denton, M.H. Differences between CME-driven storms and CIR-driven storms. *J. Geophys. Res.* 2006, *111*.
- [42] Yang, N.; Le, H.; Liu, L. Statistical analysis of the mid-latitude trough position during different categories of magnetic storms and different storm intensities. *Earth Planets Space* 2016, *68*, 171–181.
- [43] Dugassa, T.; Habarulema, J.B.; Nigussie, M. Equatorial and low-latitude ionospheric TEC response to CIR-driven geomagnetic storms at different longitude sectors. *Adv. Space Res.* 2020, *66*, 1947–1966.
- [44] Baker, D.N.; Daly, E.; Daglis, I.; Kappenman, J.G.; Panasyuk, M. Effects of Space Weather on Technology Infrastructure. *Space Weather* 2004
- [45] Balan, N.; Skoug, R.; Ram, S.T.; Rajesh, P.K.; Shiokawa, K.; Otsuka, Y.; Batista, I.S.; Ebihara, Y.; Nakamura, T. CME front and severe space weather. *J. Geophys. Res. Space Phys.* 2014, *119*, 10041–10058.
- [46] Berdermann, J.; Borries, C.; Hoque, M.M.; Jakowski, N. Forecast of Total Electron Content over Europe for Disturbed Ionospheric Conditions. 2021
- [47] Borries, C.; Berdermann, J.; Jakowski, N.; Hoque, M.; Bothmer, V. Preparation of an advanced TEC forecast based on the statistical analysis of historical ionospheric storms. In Proceedings of the 4th International Galileo Science Colloquium, Prague, Czech Republic, 4–6 December 2013
- [48] Schrijver, C.J.; Kauristie, K.; Aylward, A.D.; Denardini, C.M.; Gibson, S.E.; Glover, A.; Gopalswamy, N.; Grande, M.; Hapgood, M.; Heynderickx, D.; et al. Understanding space weather to shield society: A global road map for 2015–2025 commissioned by COSPAR and ILWS. *Adv. Space Res.* 2015
- [49] Tsagouri, I.; Belehaki, A. Ionospheric forecasts for the European region for space weather applications. *J. Space Weather Space Clim.* 201
- [50] Mallika, I. Lakshmi, Devanaboyina Venkata Ratnam, Yuichi Ostuka, Gampala Sivavaraprasad and Saravanan Raman. “Implementation of Hybrid Ionospheric TEC Forecasting Algorithm Using PCA-NN Method.” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 12 (2019): 371-381.
- [51] Nicola Linty, Alex Minetto, Fabio Dovis, Luca Spogli. Effects of Phase Scintillation on the GNSS Positioning Error During the September 2017 Storm at Svalbard. 2018
- [52] Anna Krypiak-Gregorczyk. Ionosphere response to three extreme events occurring near spring equinox in 2012, 2013 and 2015, observed by regional GNSS-TEC model. 2018
- [53] Schmölter, E.; Berdermann, J. Predicting the Effects of Solar Storms on the Ionosphere Based on a Comparison of Real-Time Solar Wind Data with the Best-Fitting Hist. 2018
- [54] G. Van Rossum, “Python Programming Language,,” in USENIX annual technical conference, 2007, vol. 41, p. 36.

- [55] D. Kuhlman, A python book: Beginning python, advanced python, and python exercises. 2009.
- [56] T. E. Oliphant, A guide to NumPy, vol. 1. 2006.
- [57] G. Hackeling, Mastering Machine Learning with scikit-learn. 2017
- [58] Seemala, Gopi. (2012). GPS-TEC analysis software.
- [59] “4 Reasons Why You Should Use Google Colab for Your Next Project | by Orhan G. Yalçın | Towards Data Science.” <https://towardsdatascience.com/4-reasons-why-you-should-use-google-colab-for-your-next-project-b0c4aad39ed> (accessed Oct. 04, 2021).
- [60] M. Abadi *et al.*, “TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems,” *ArXiv160304467 Cs*, Mar. 2016, Accessed: Oct. 04, 2021. [Online]. Available: <http://arxiv.org/abs/1603.04467>
- [61] M. Abadi *et al.*, *TensorFlow, Large-scale machine learning on heterogeneous systems*. 2015. doi: 10.5281/zenodo.4724125.
- [62] K. Team, “Keras documentation: Keras API reference.” <https://keras.io/api/> (accessed Oct. 04, 2021).
- [63] K. Team, “Keras documentation: Core layers.” https://keras.io/api/layers/core_layers/ (accessed Oct. 04, 2021).
- [64] G. Hackeling, Mastering machine learning with scikit-learn: apply effective learning algorithms to real-world problems using scikit-learn. Birmingham: Packt Publ, 2014.
- [65] A. F. Agarap, “Deep Learning using Rectified Linear Units (ReLU),” *ArXiv180308375 Cs Stat*, Feb. 2019, Accessed: Oct. 03, 2021. [Online]. Available: <http://arxiv.org/abs/1803.08375>

Παράρτημα Α

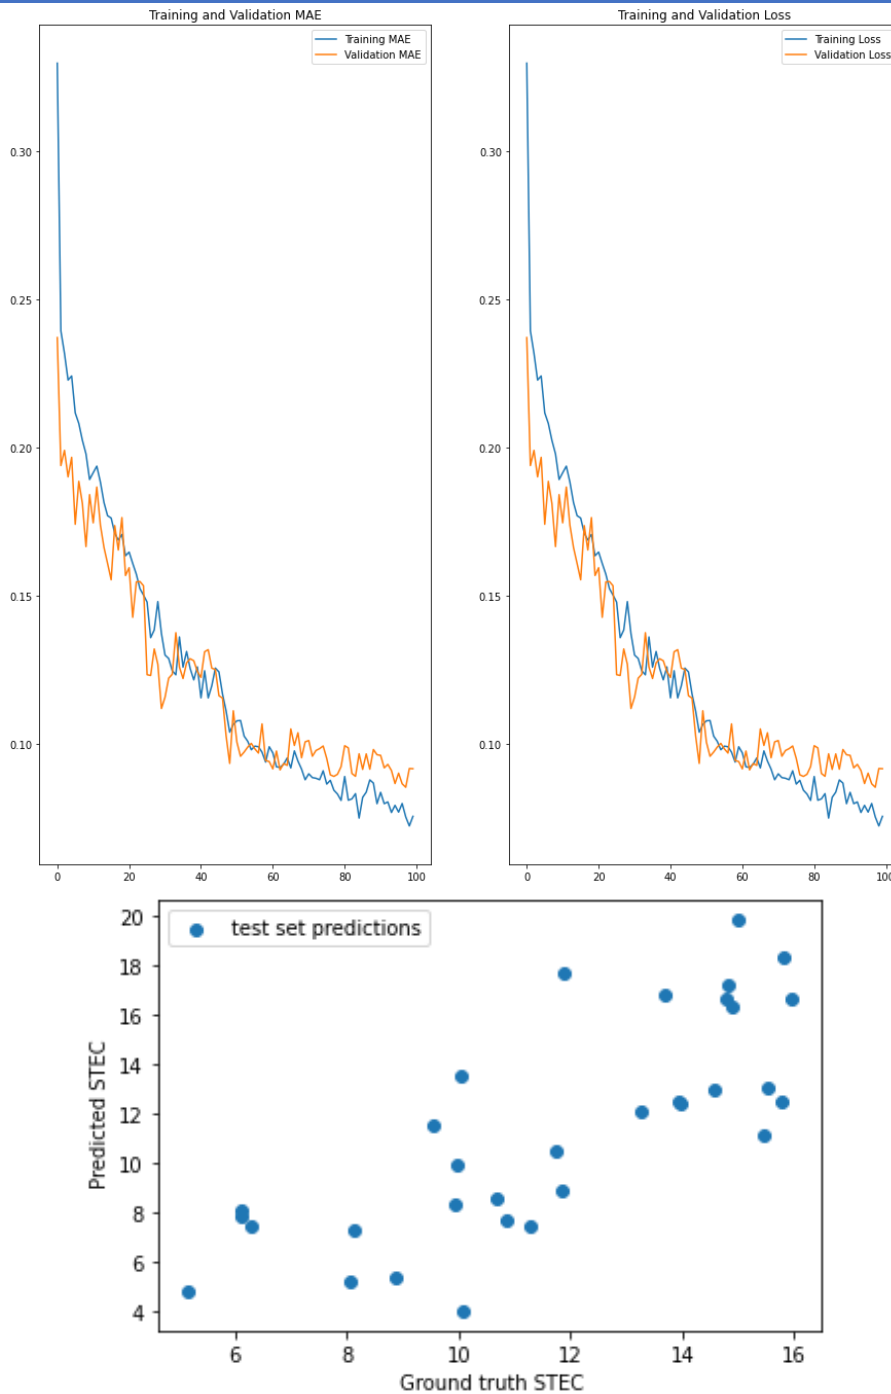
Πίνακας δεδομένων ανά μήνα




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




Παράρτημα Β

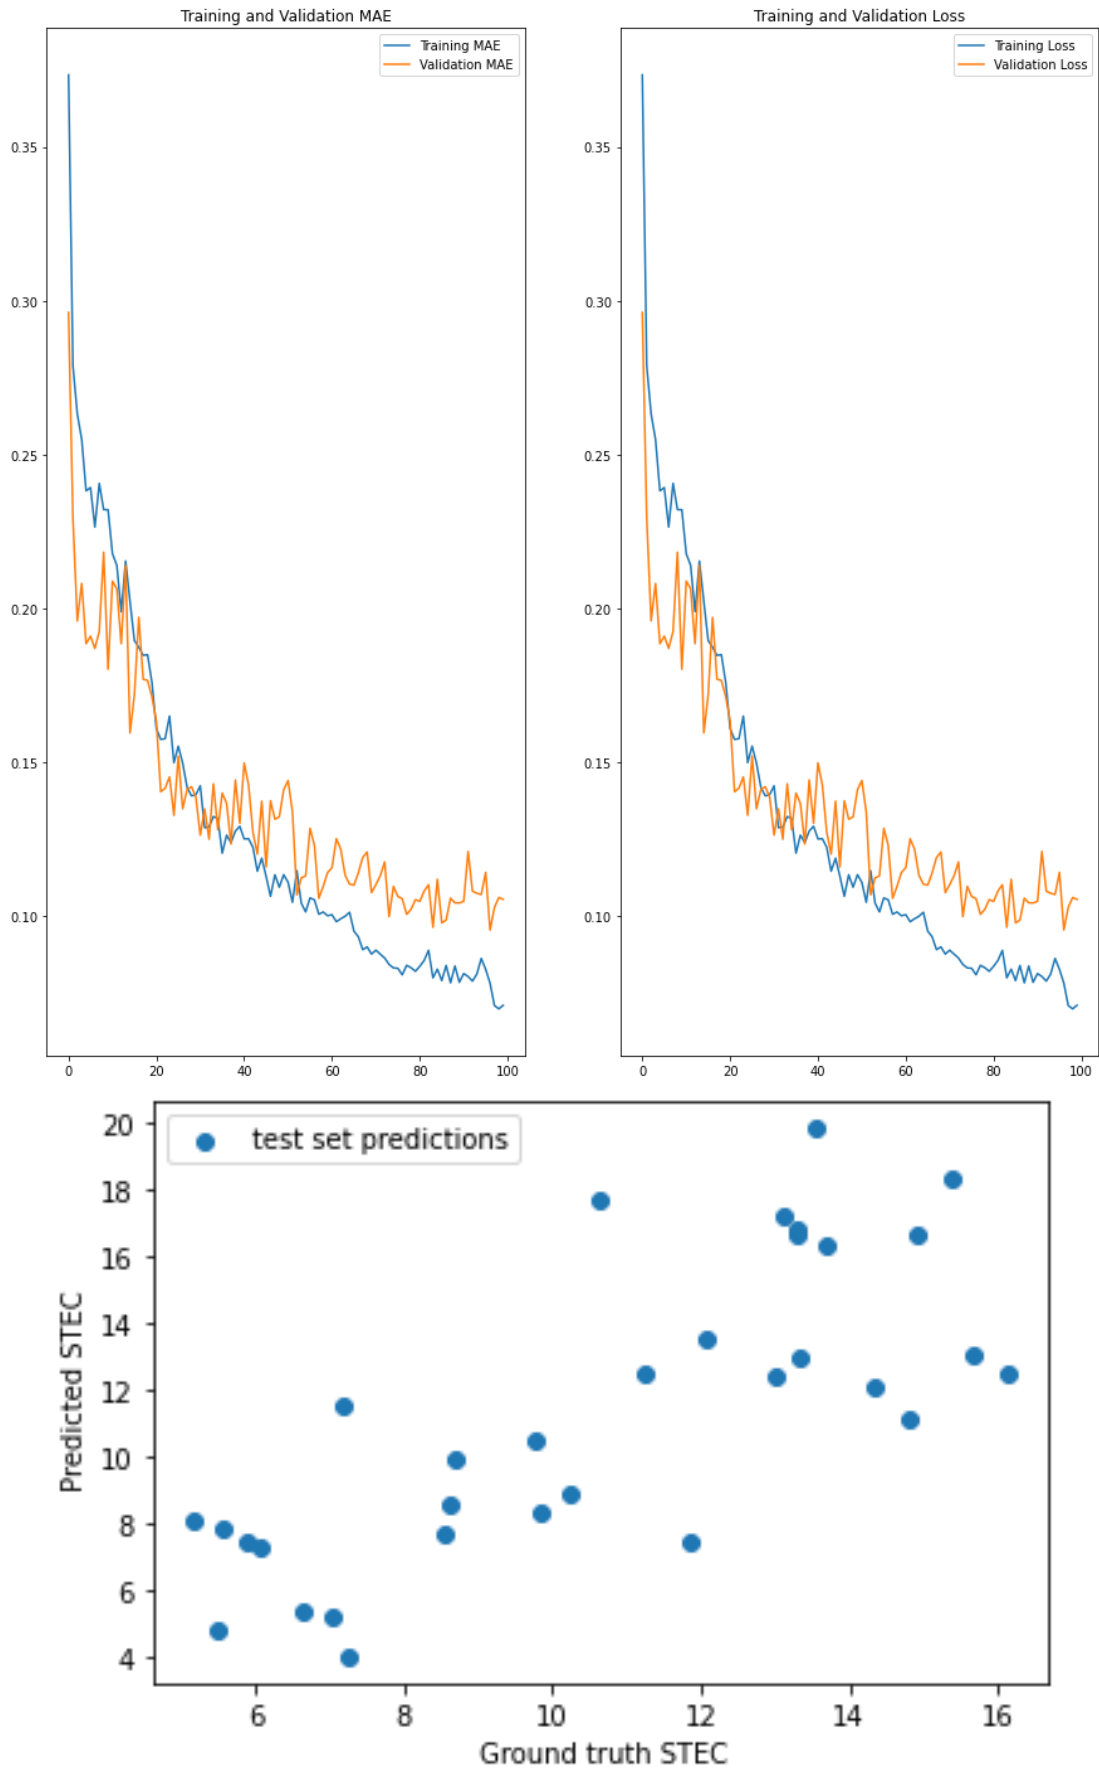
Αποτελέσματα Σεναρίου Νο 1,2,3,4 για τους μήνες Φεβρουάριο και Μάρτιο 2018




STEC ΦΕΒΡΟΥΑΡΙΟΥ


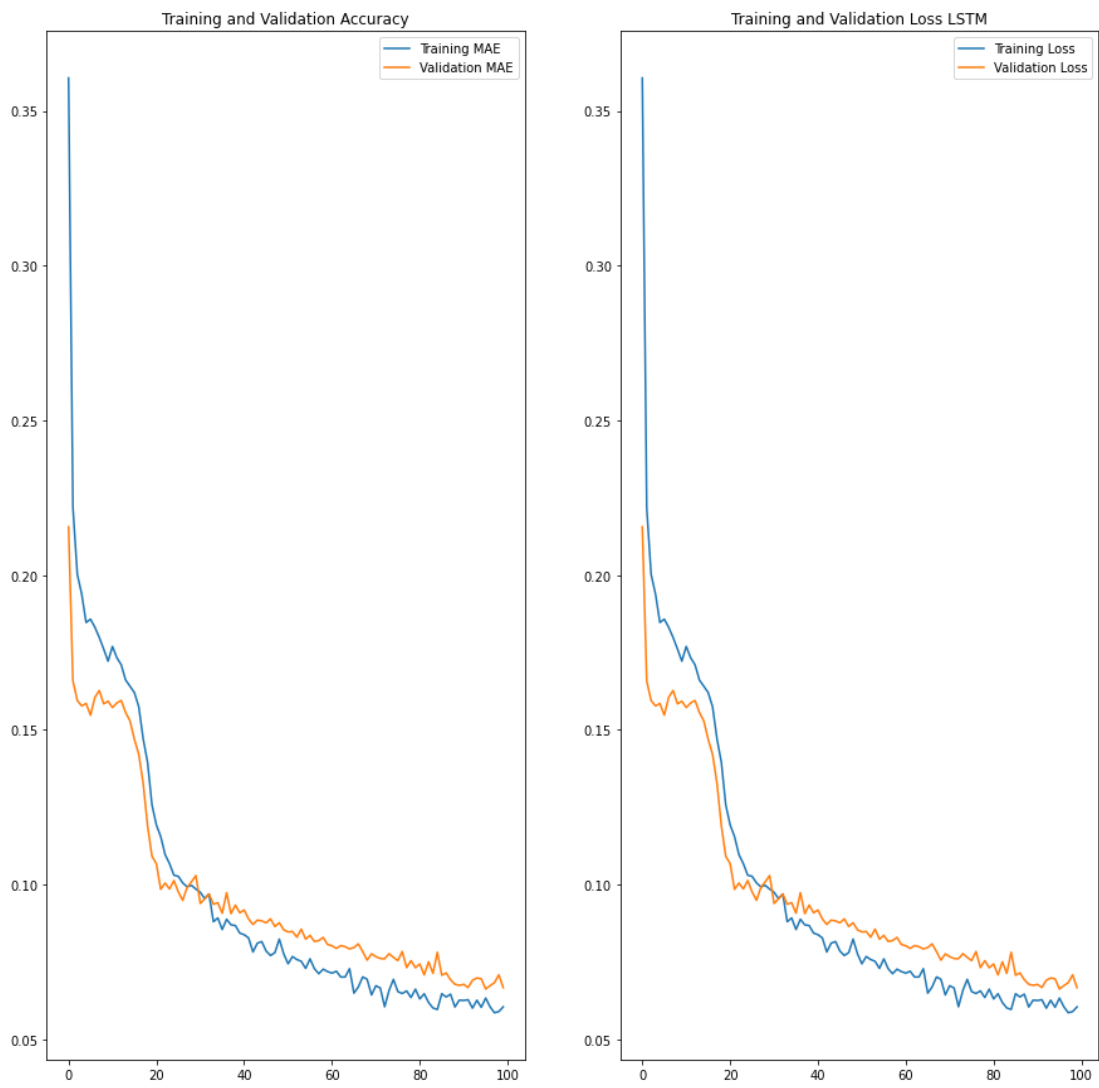




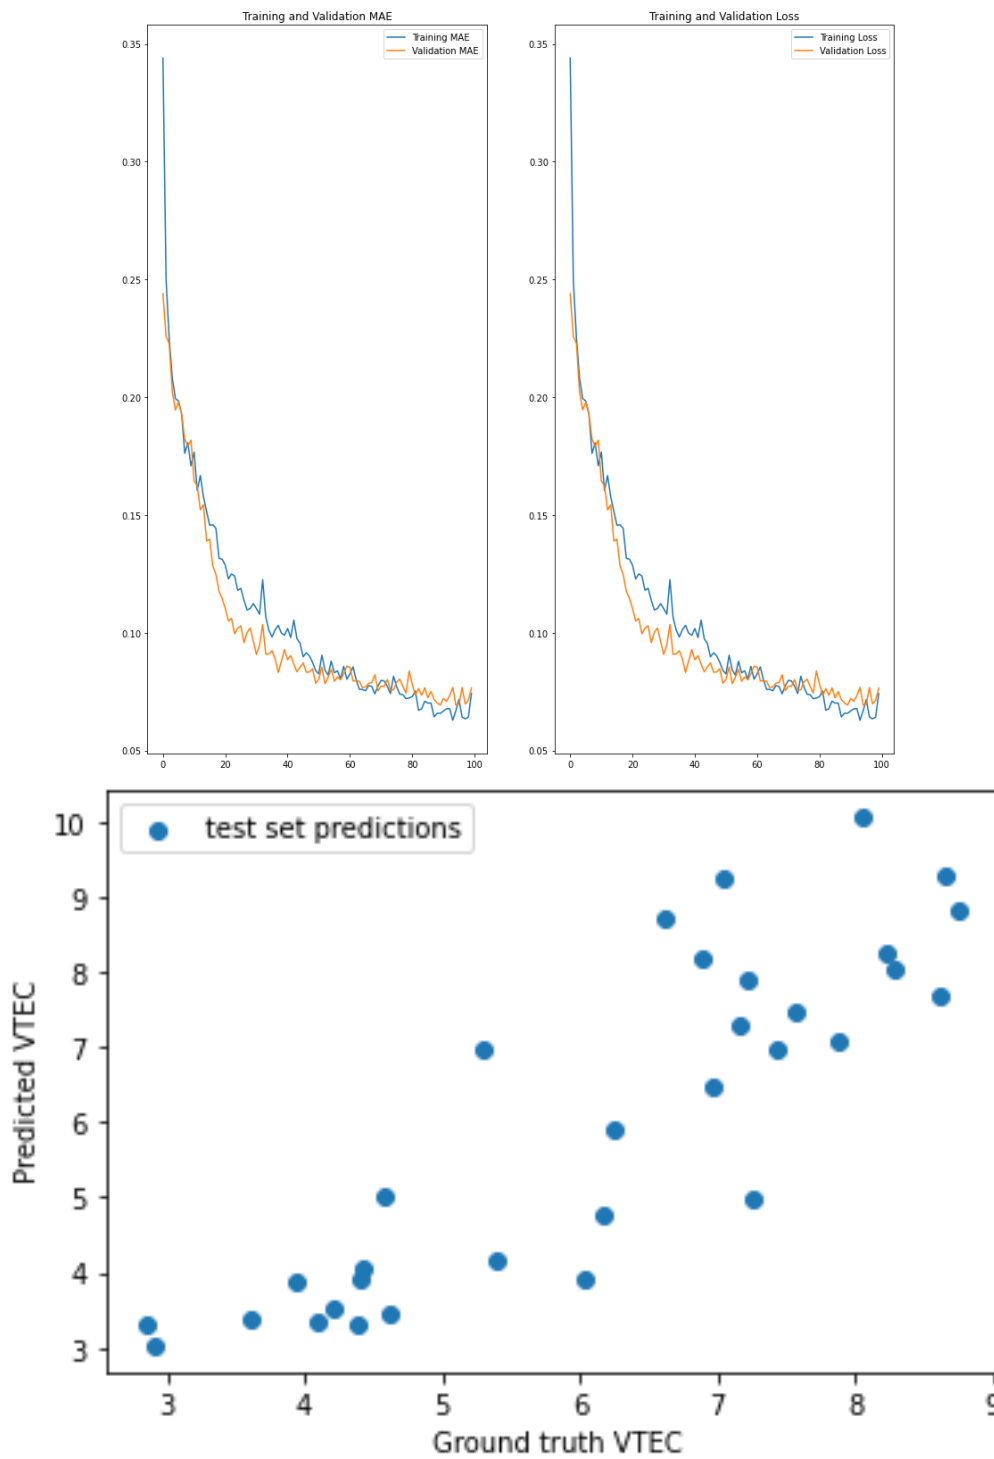


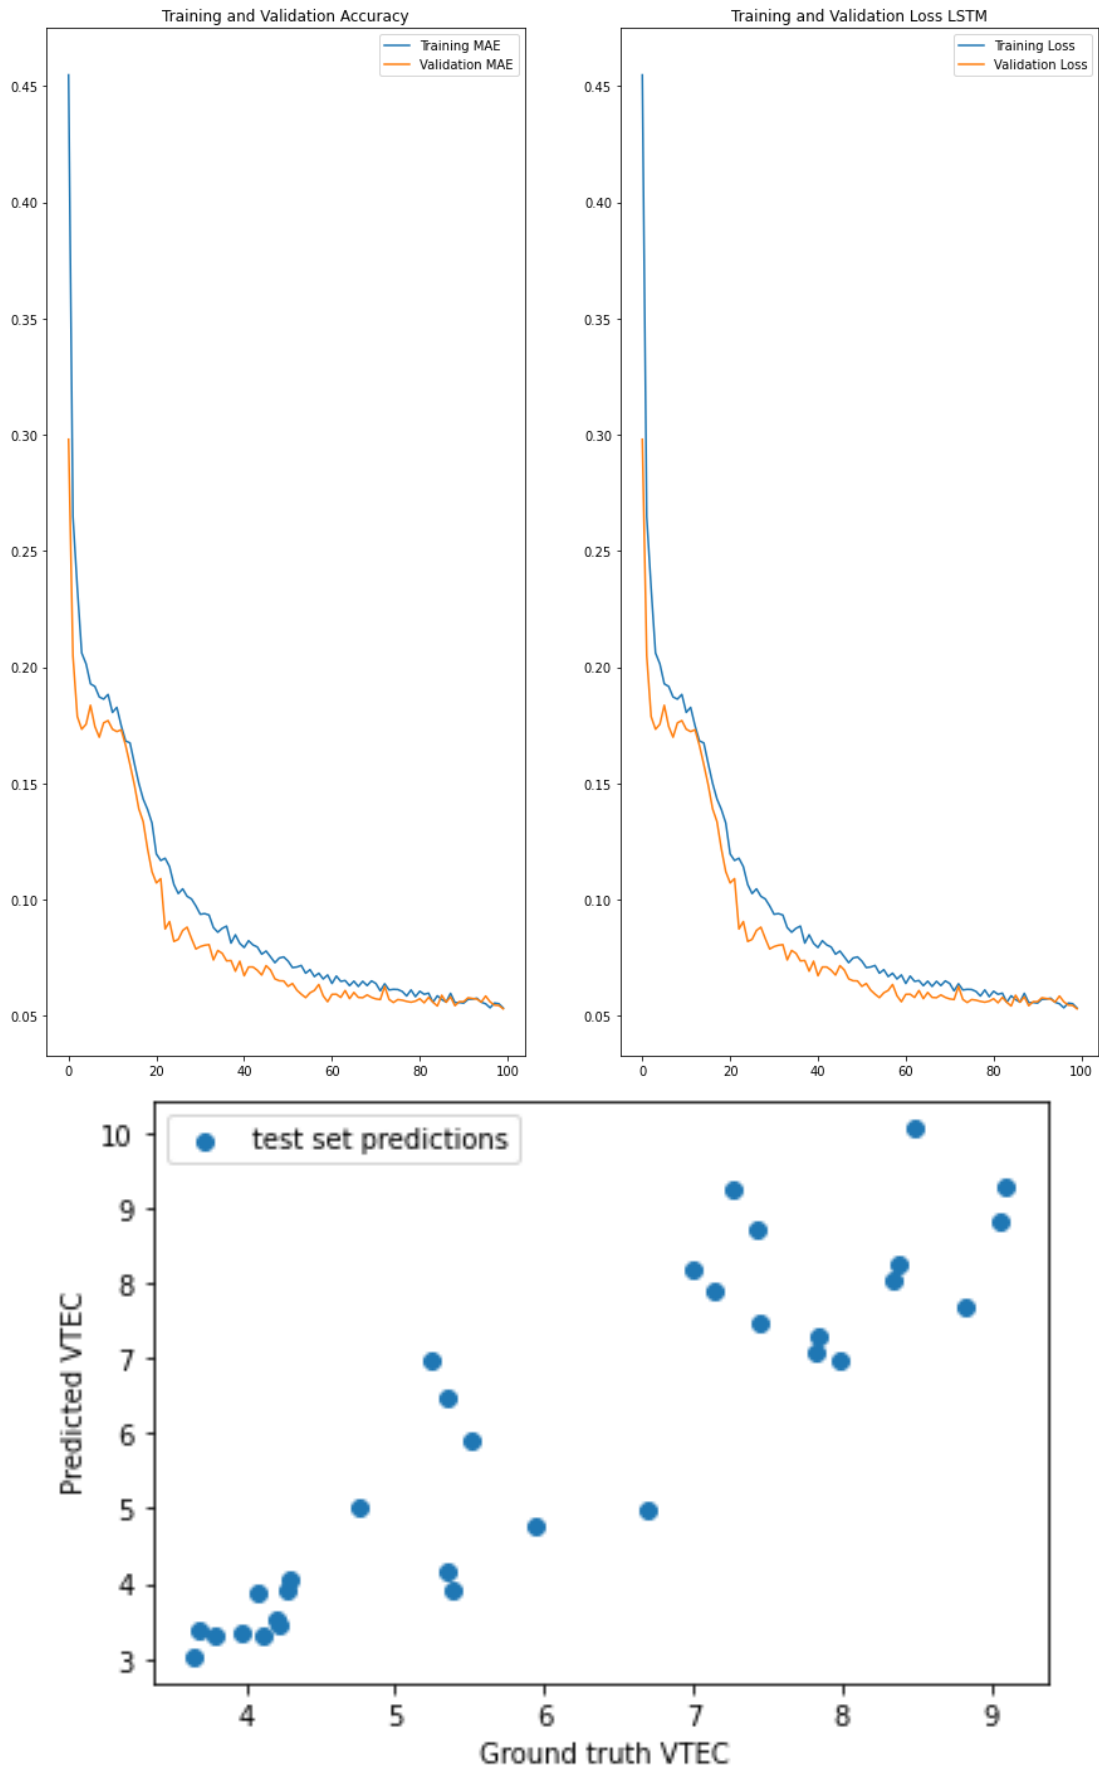


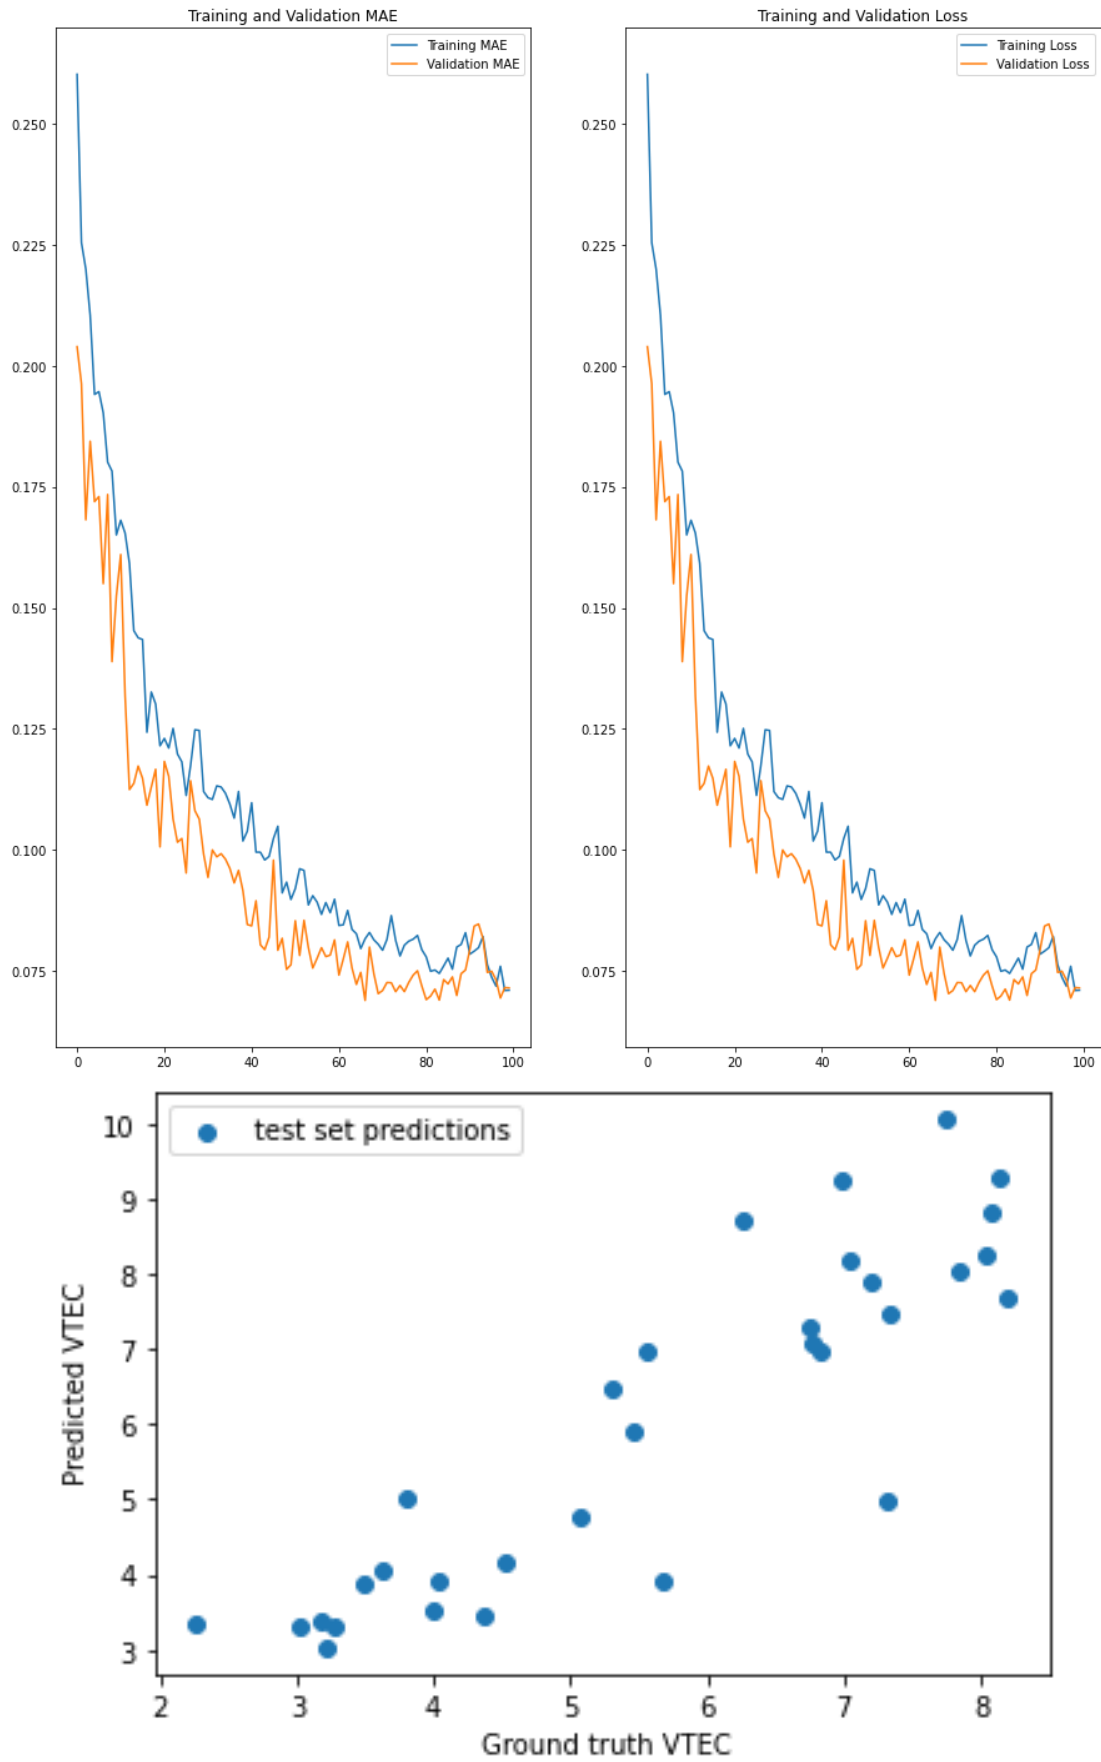







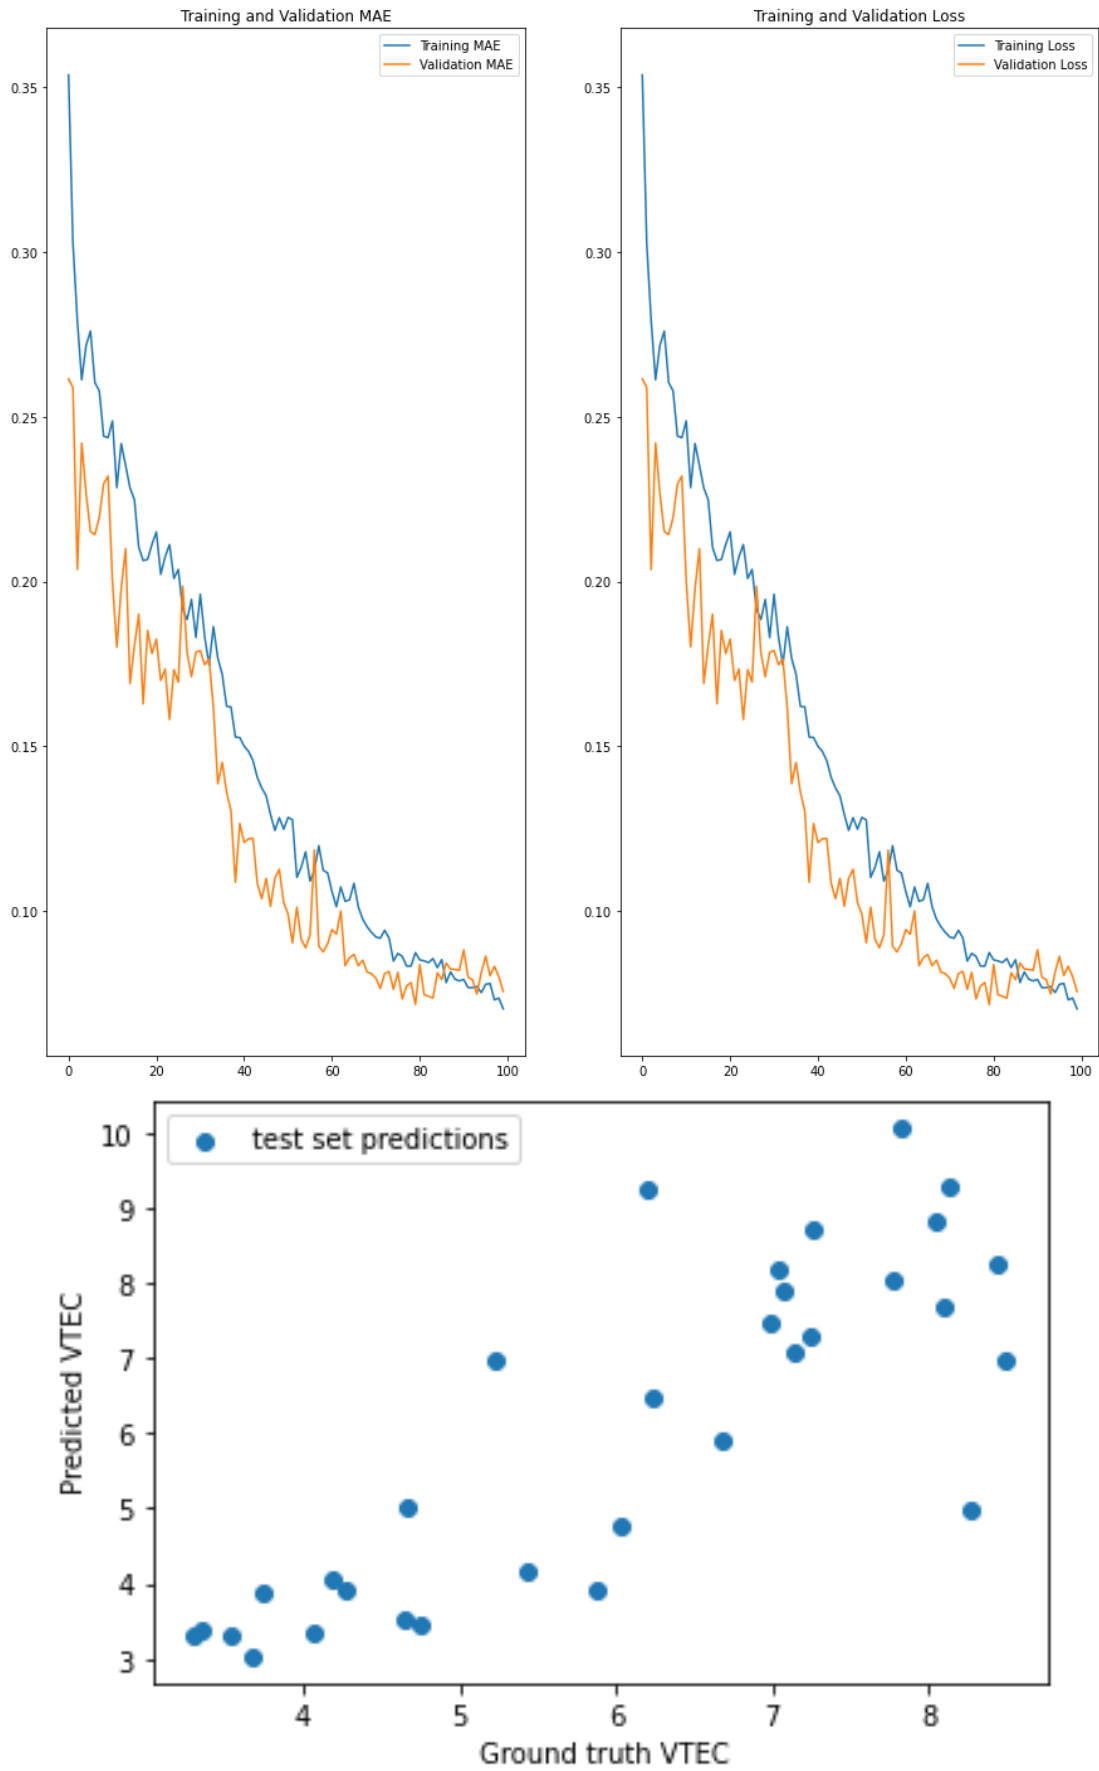
ΥΤΕC ΦΕΒΡΟΥΑΡΙΟΥ








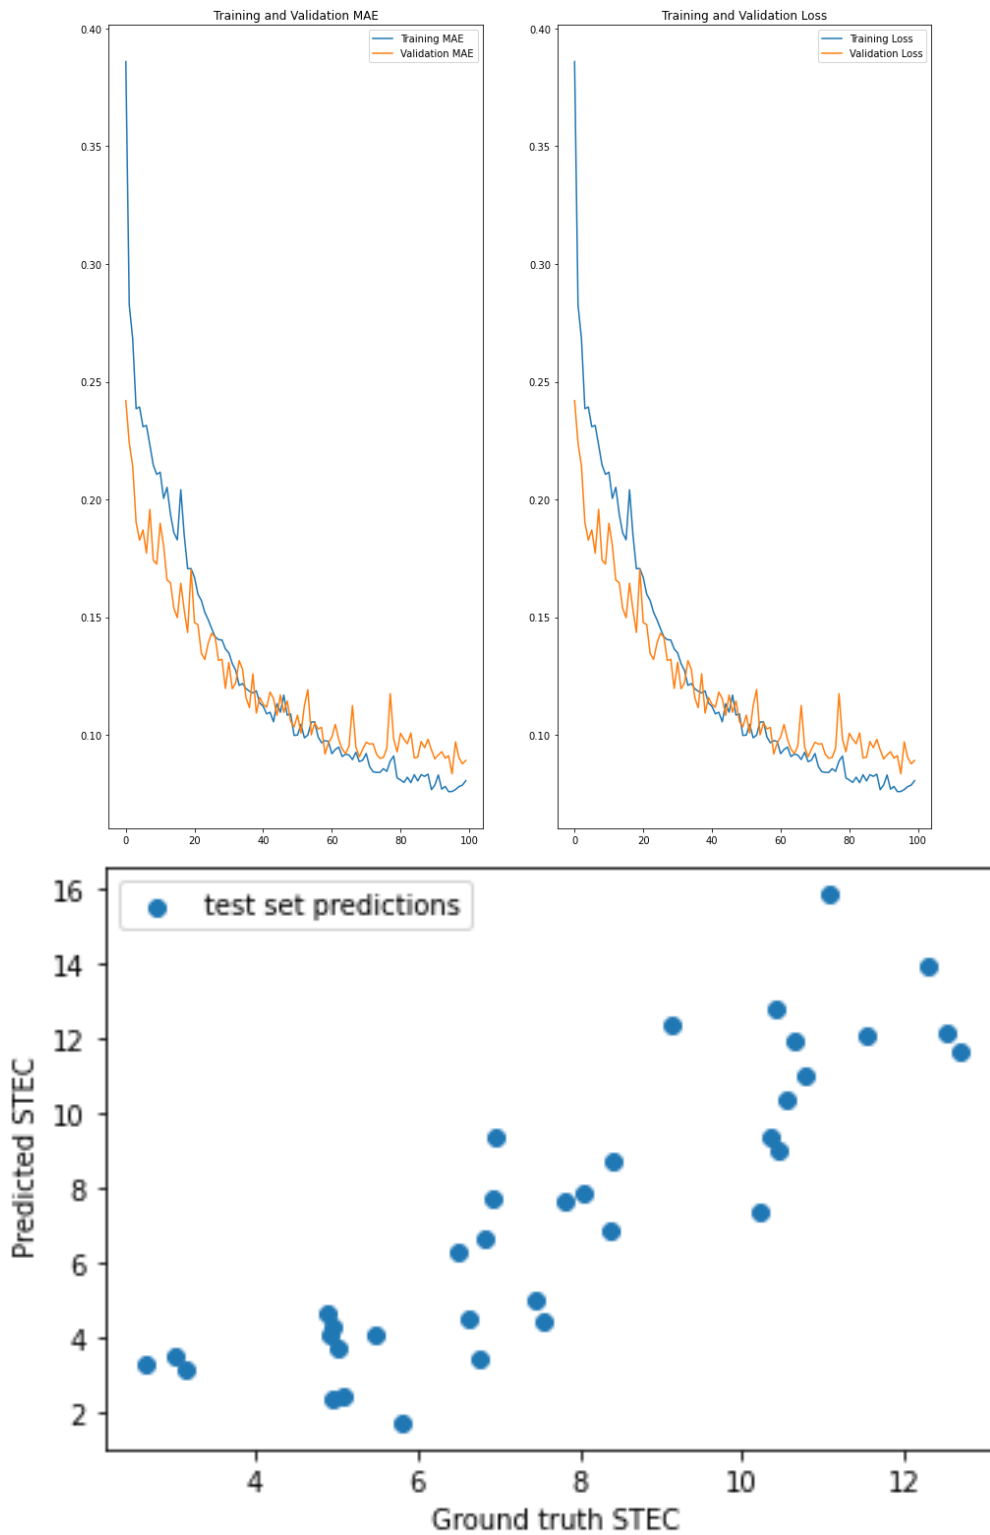



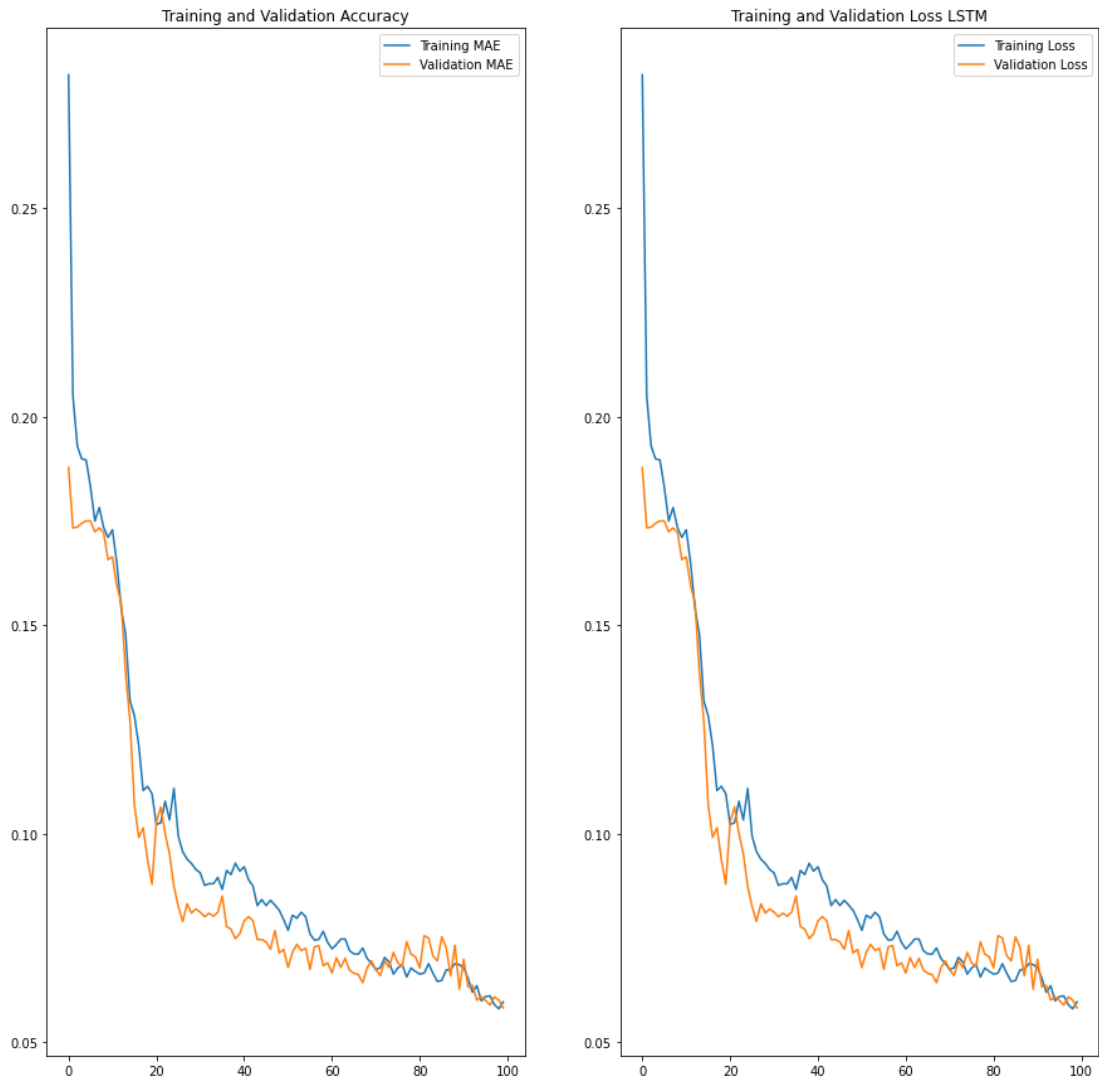



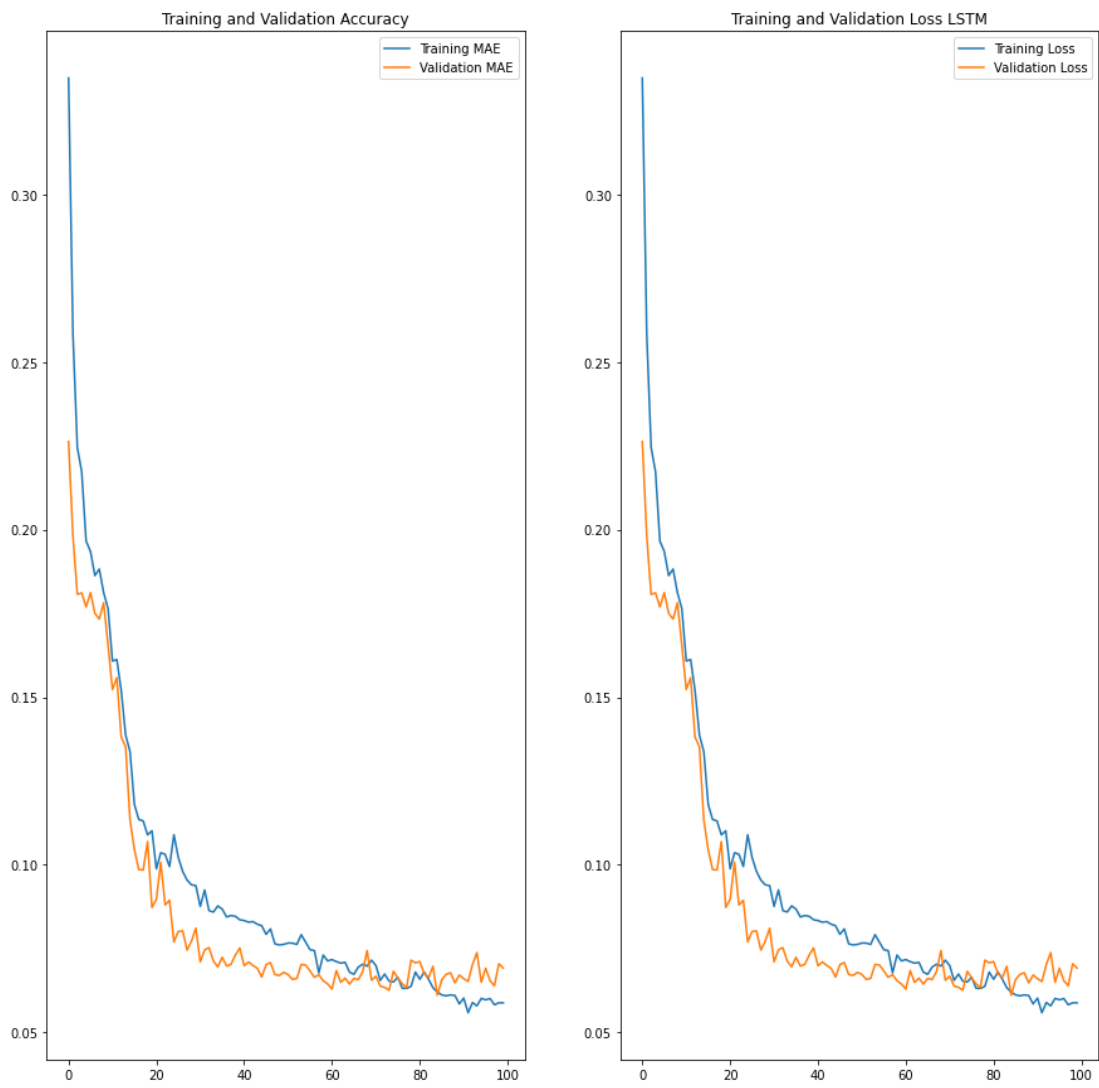


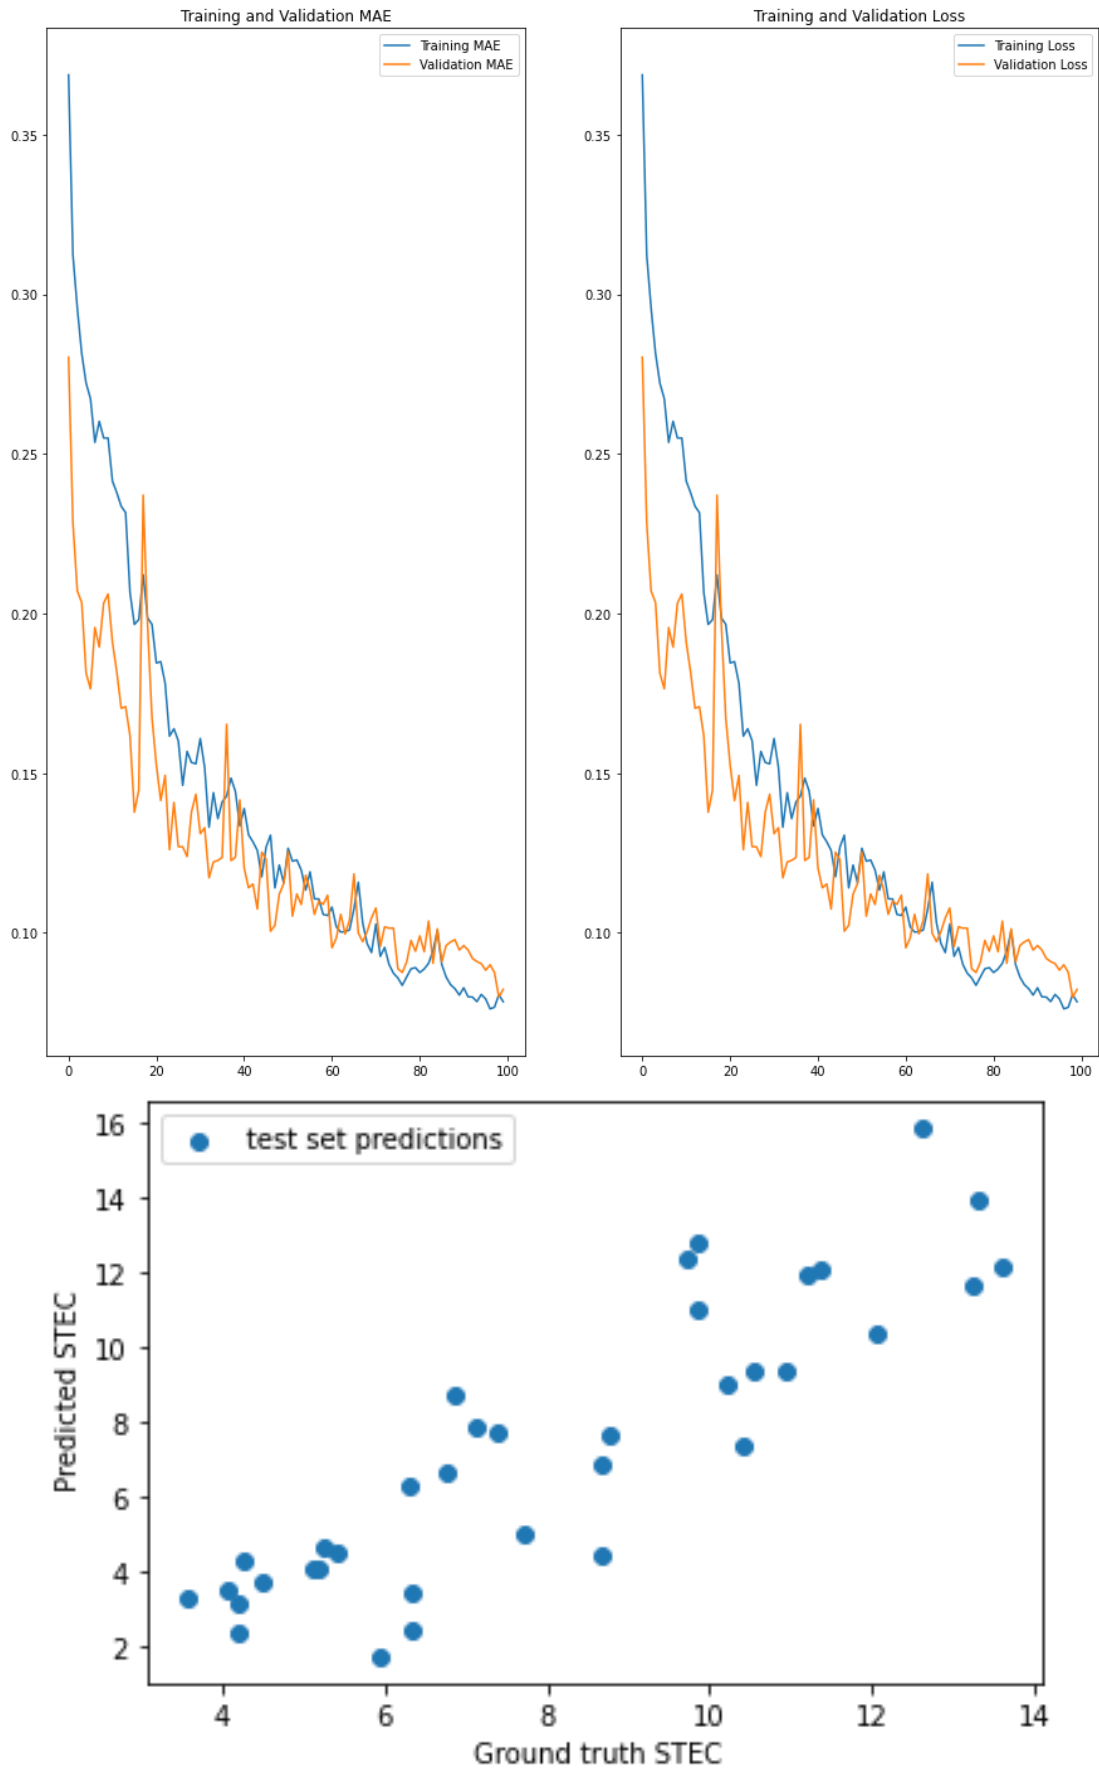


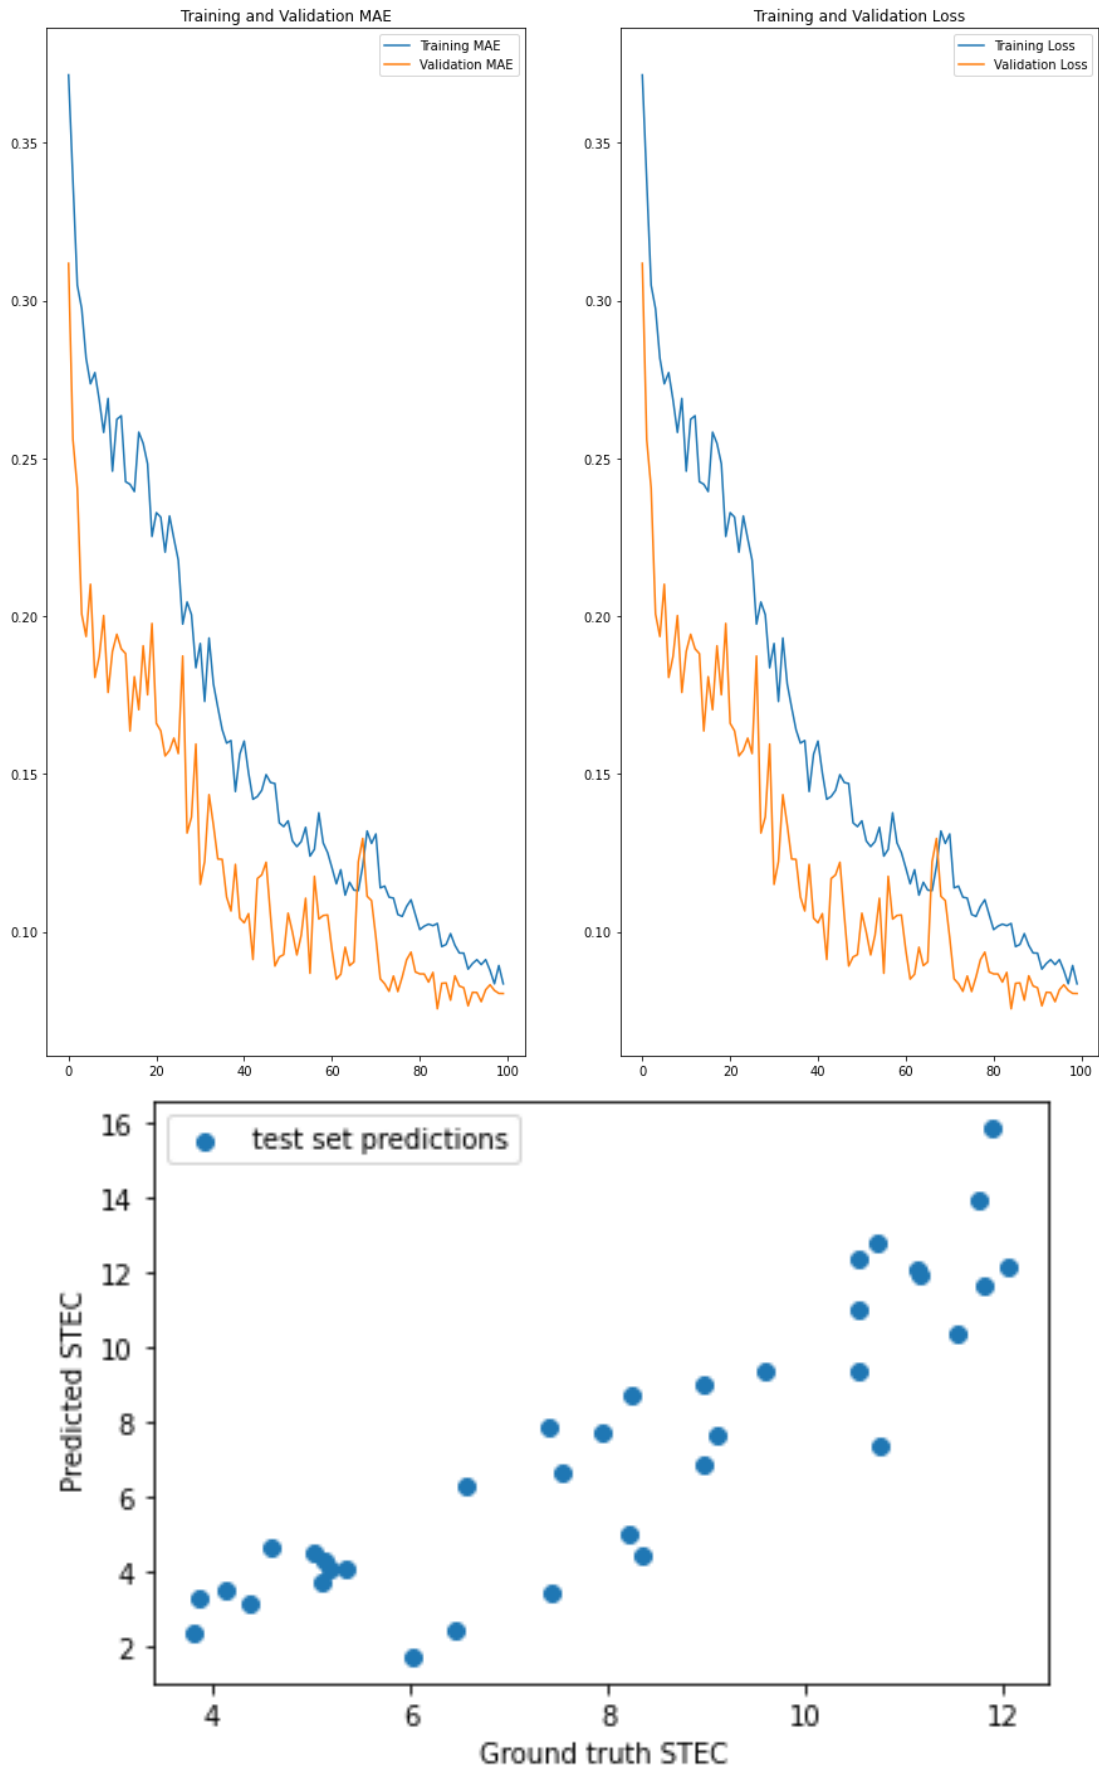
STEC ΜΑΡΤΙΟΥ








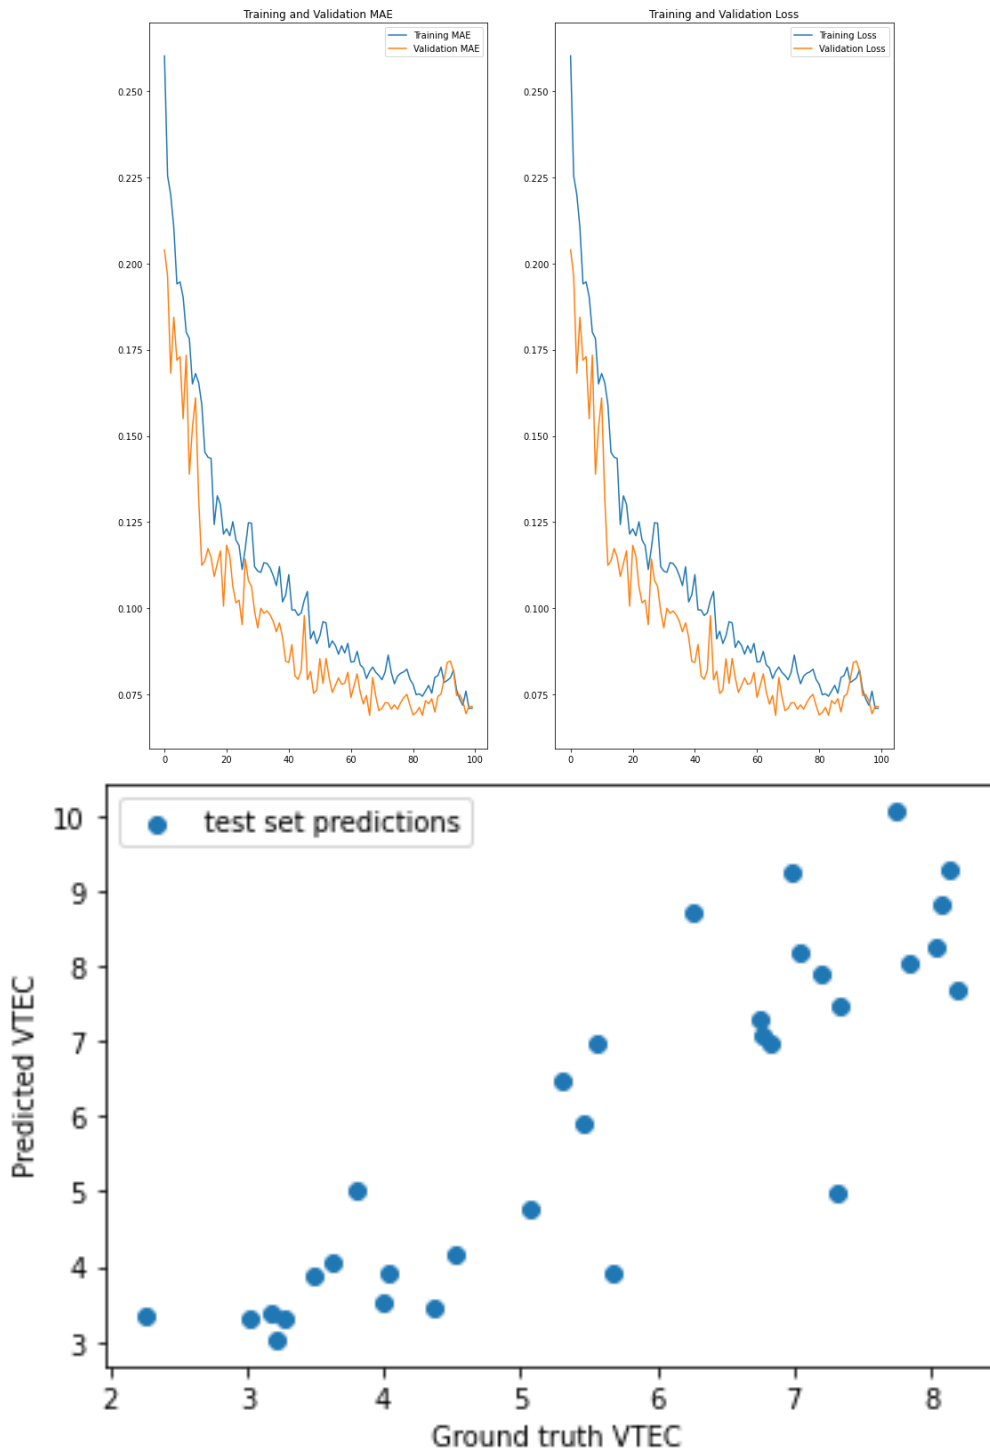

















VTEC ΜΑΡΤΙΟΥ



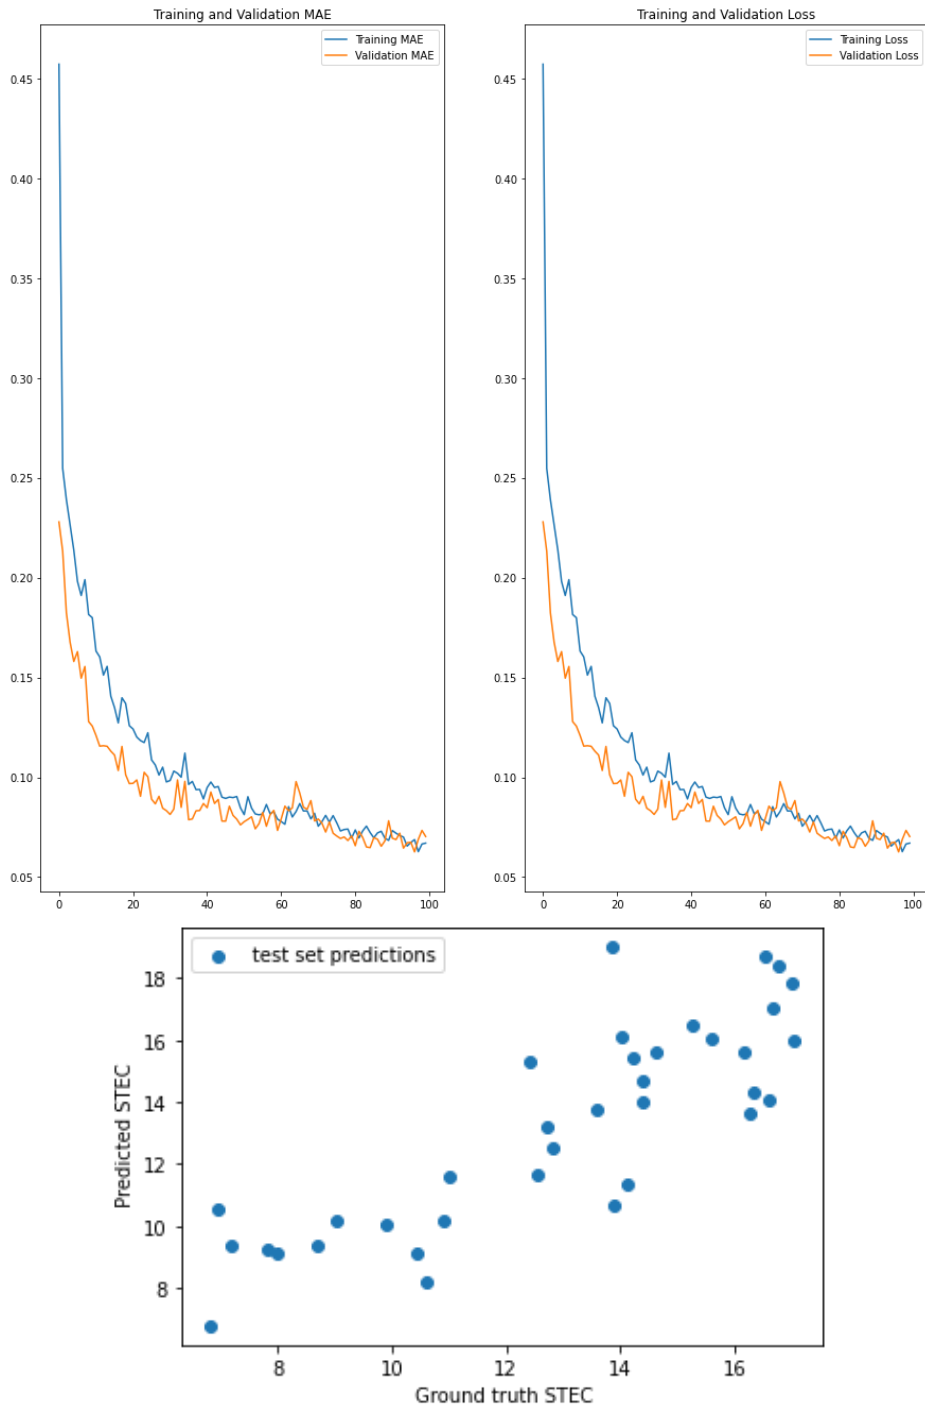







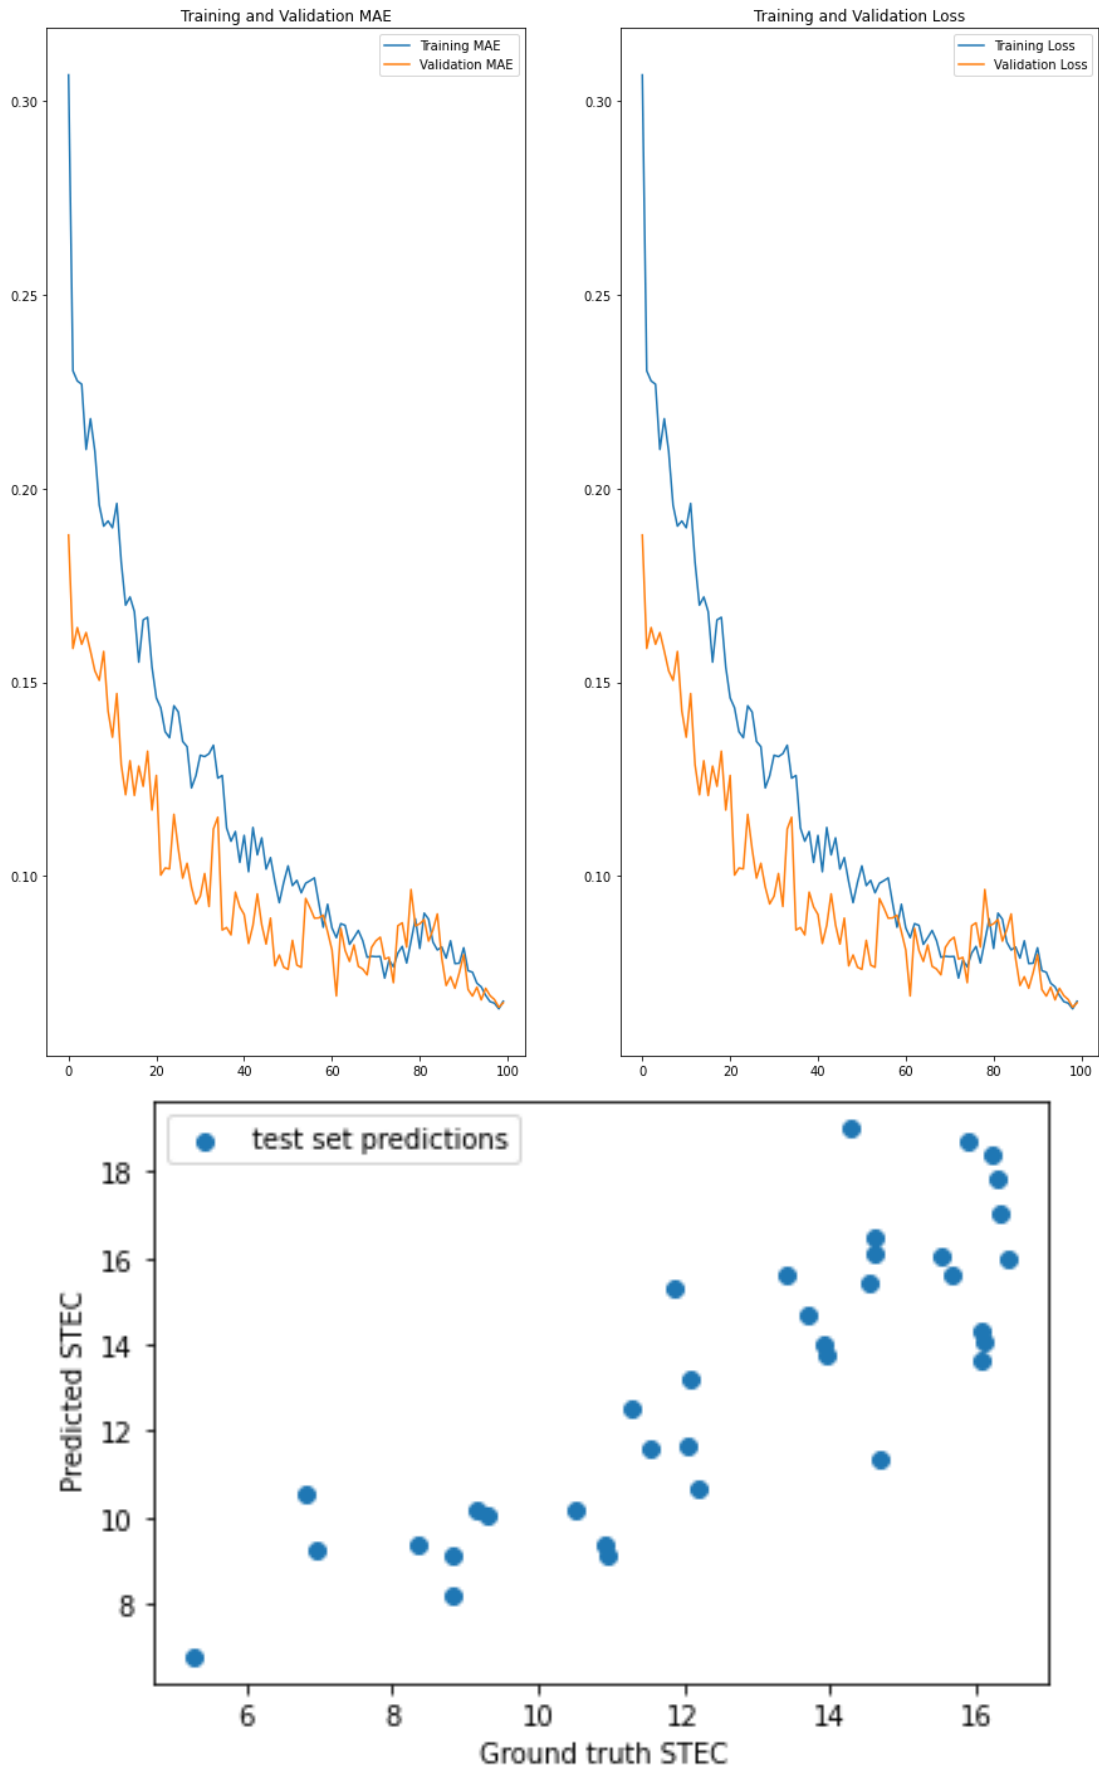


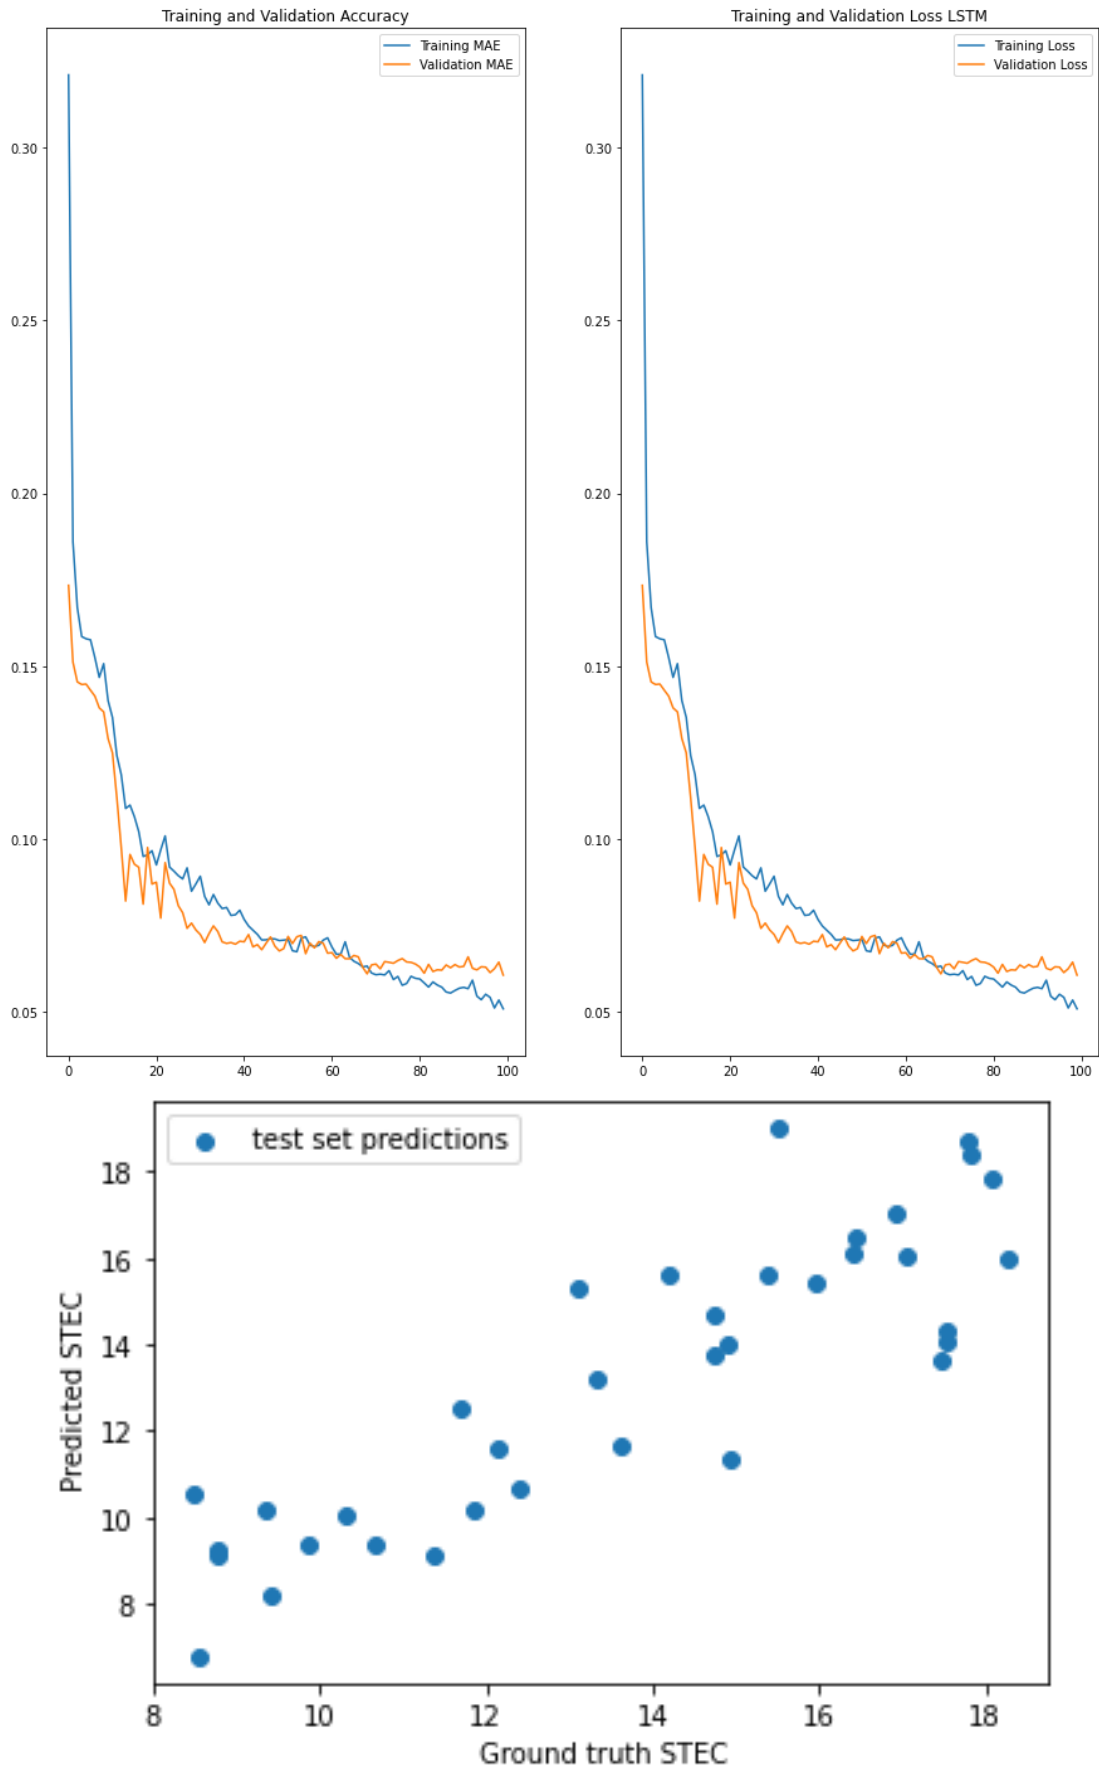
Αποτελέσματα Σεναρίου Νο 5 για τους μήνες Ιανουάριο, Φεβρουάριο και Μάρτιο 2018

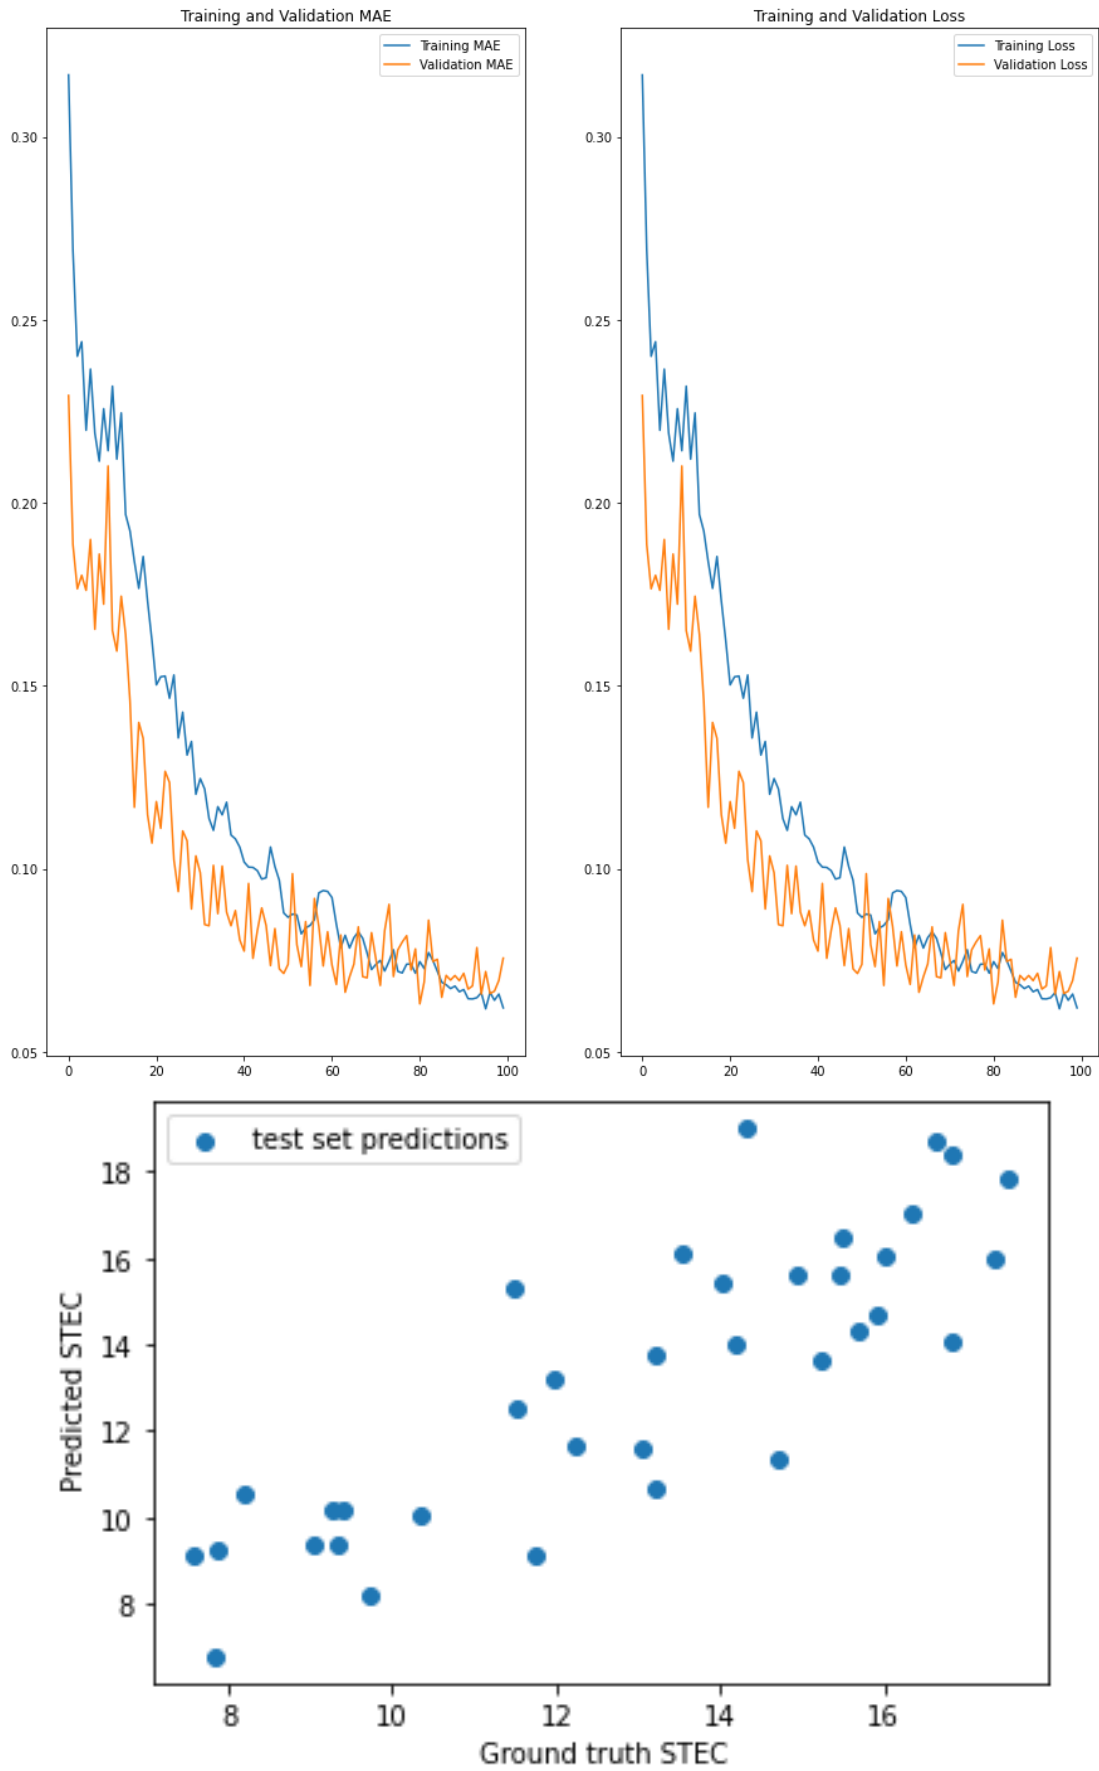
STEC ΙΑΝΟΥΑΡΙΟΥ








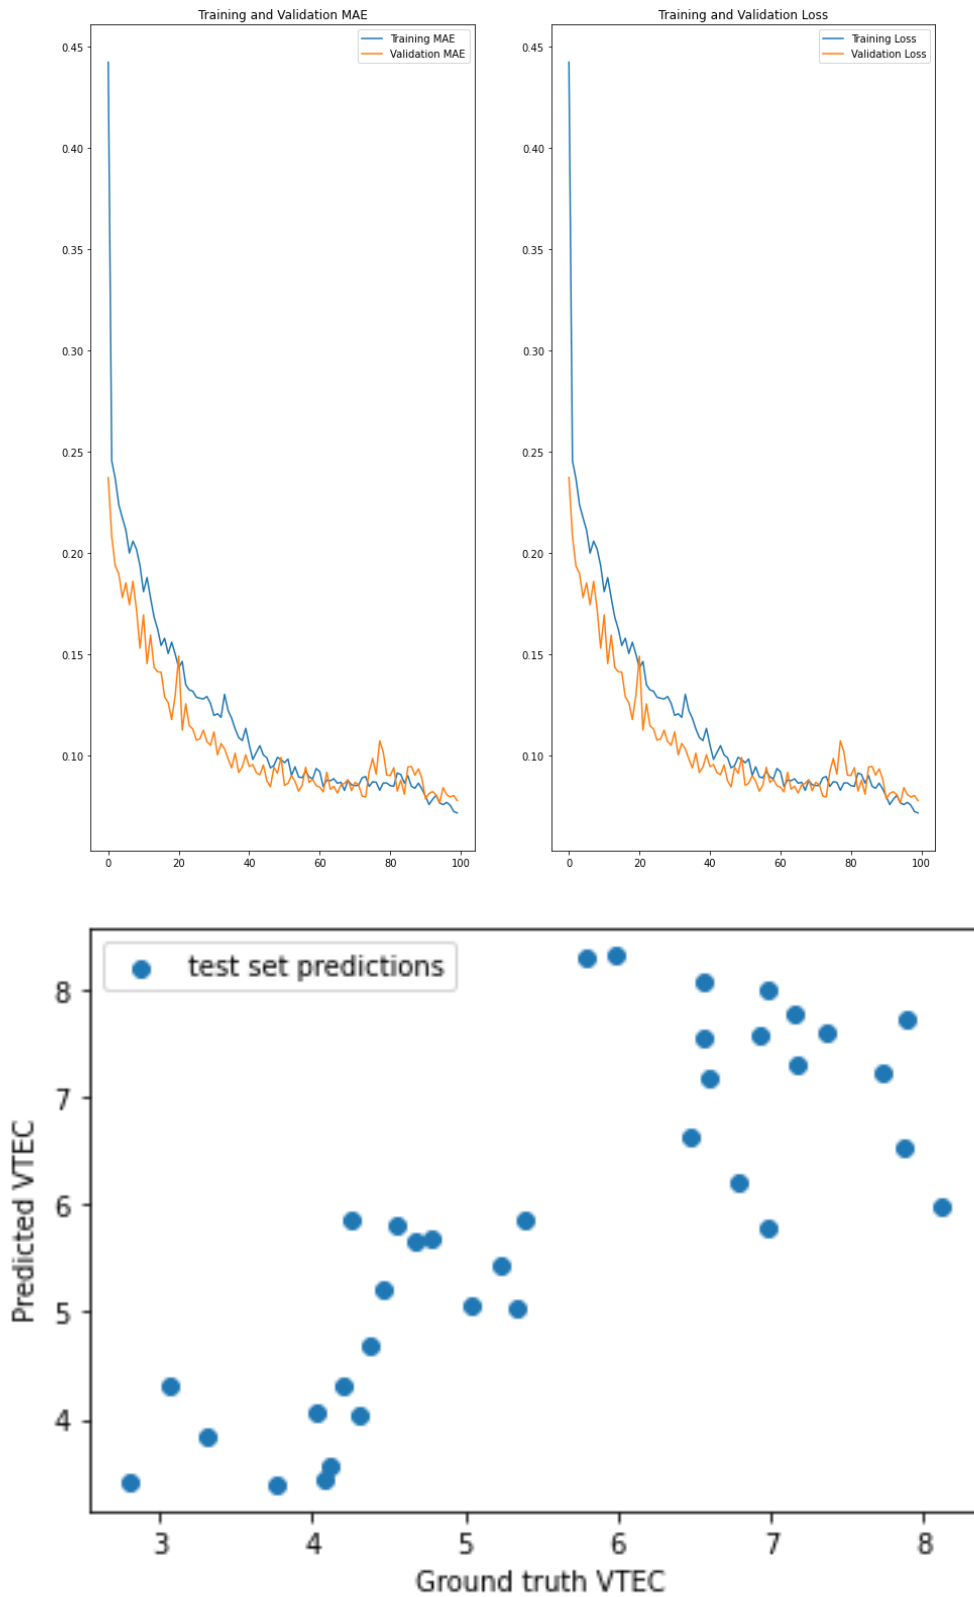


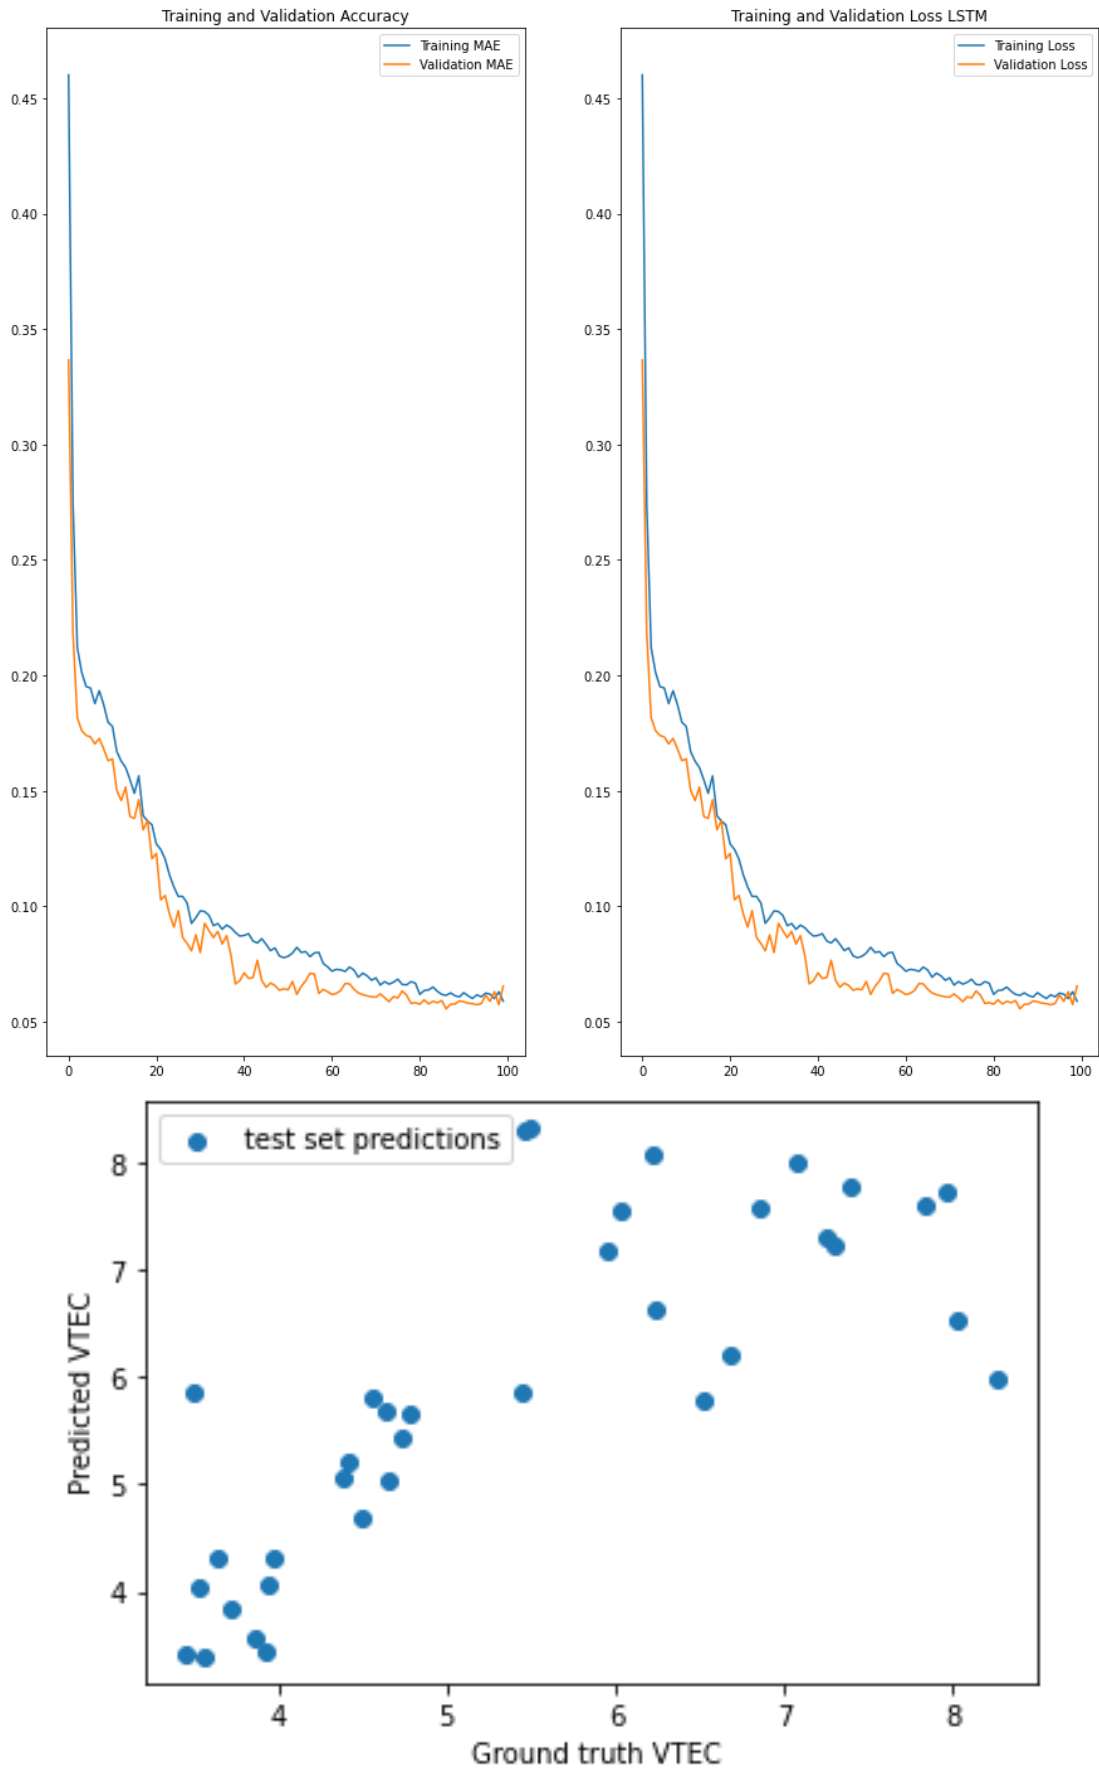







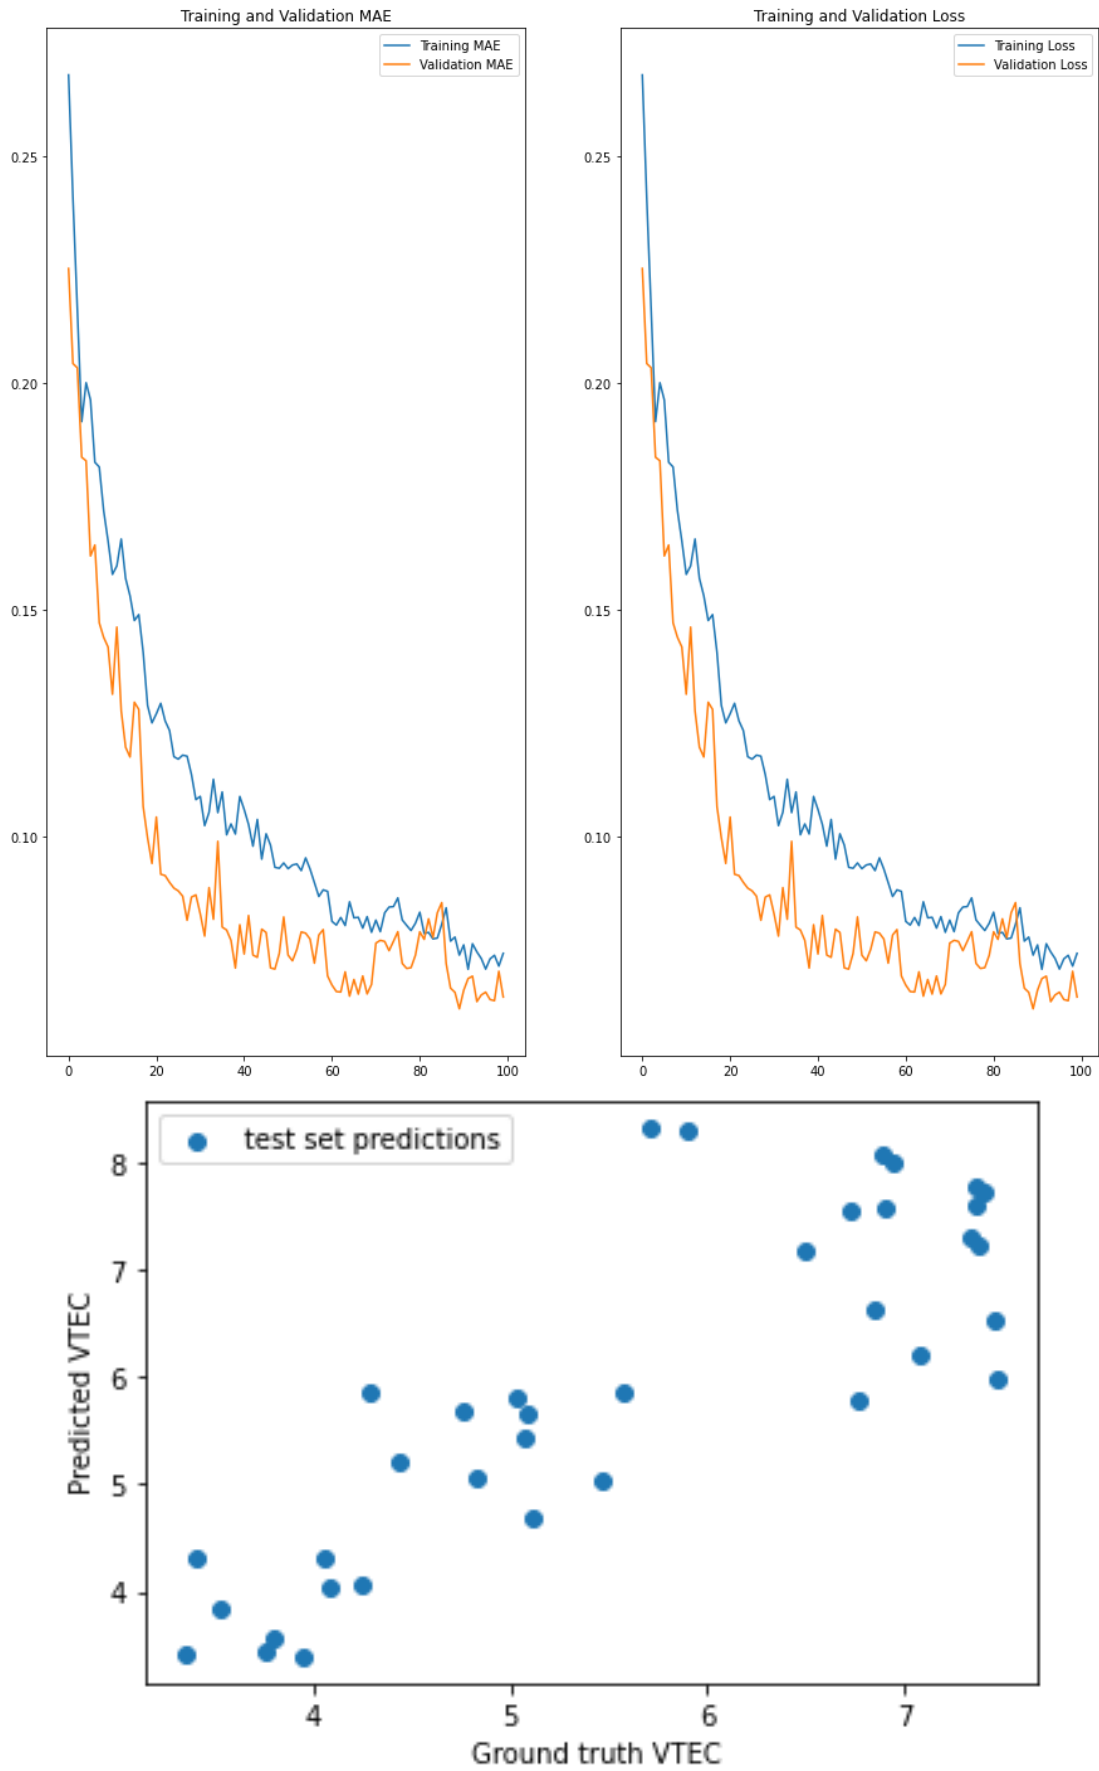


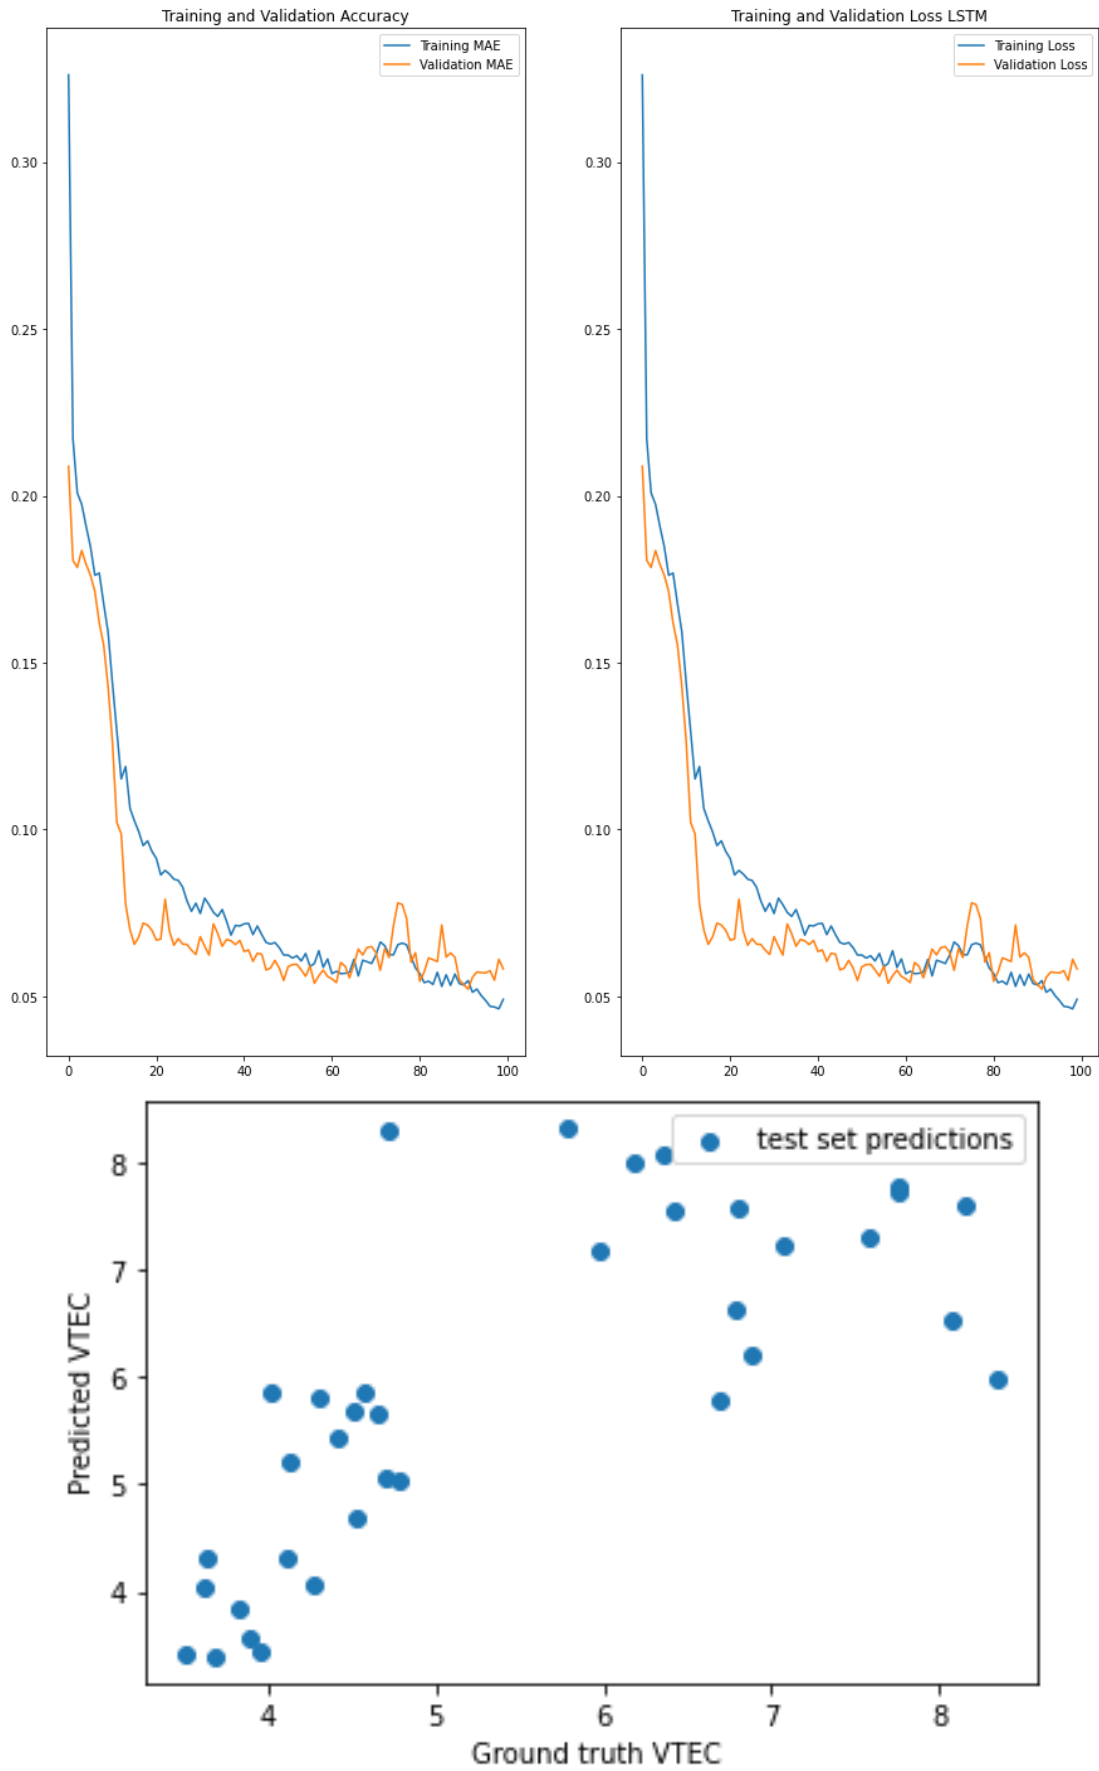
VTEC ΙΑΝΟΥΑΡΙΟΥ



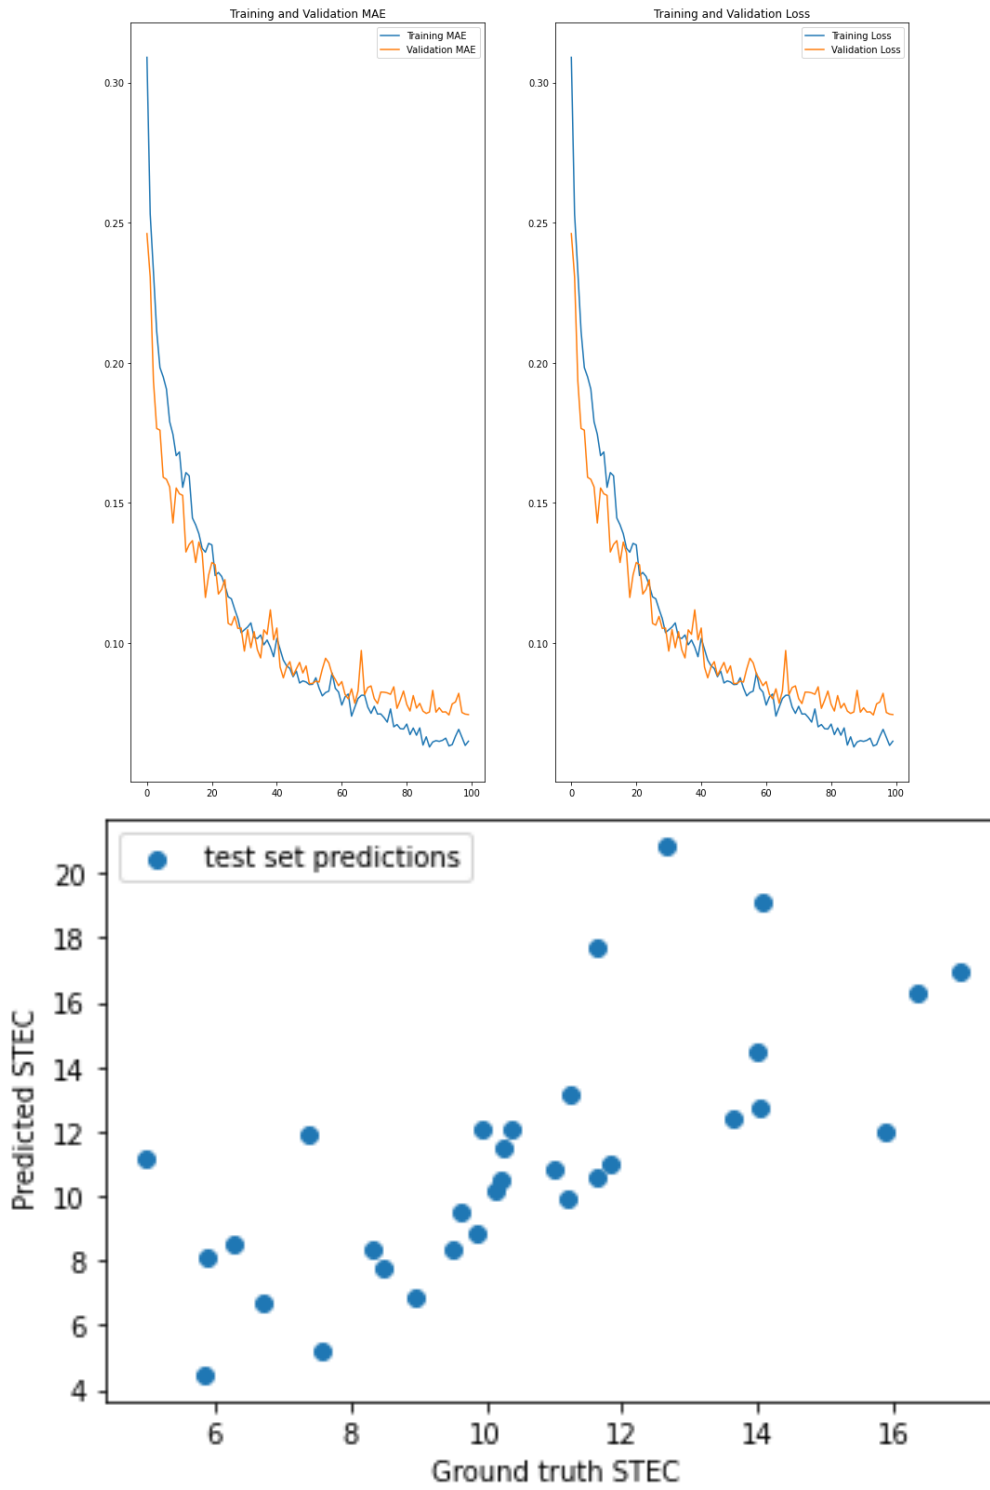














STEC ΦΕΒΡΟΥΑΡΙΟΥ

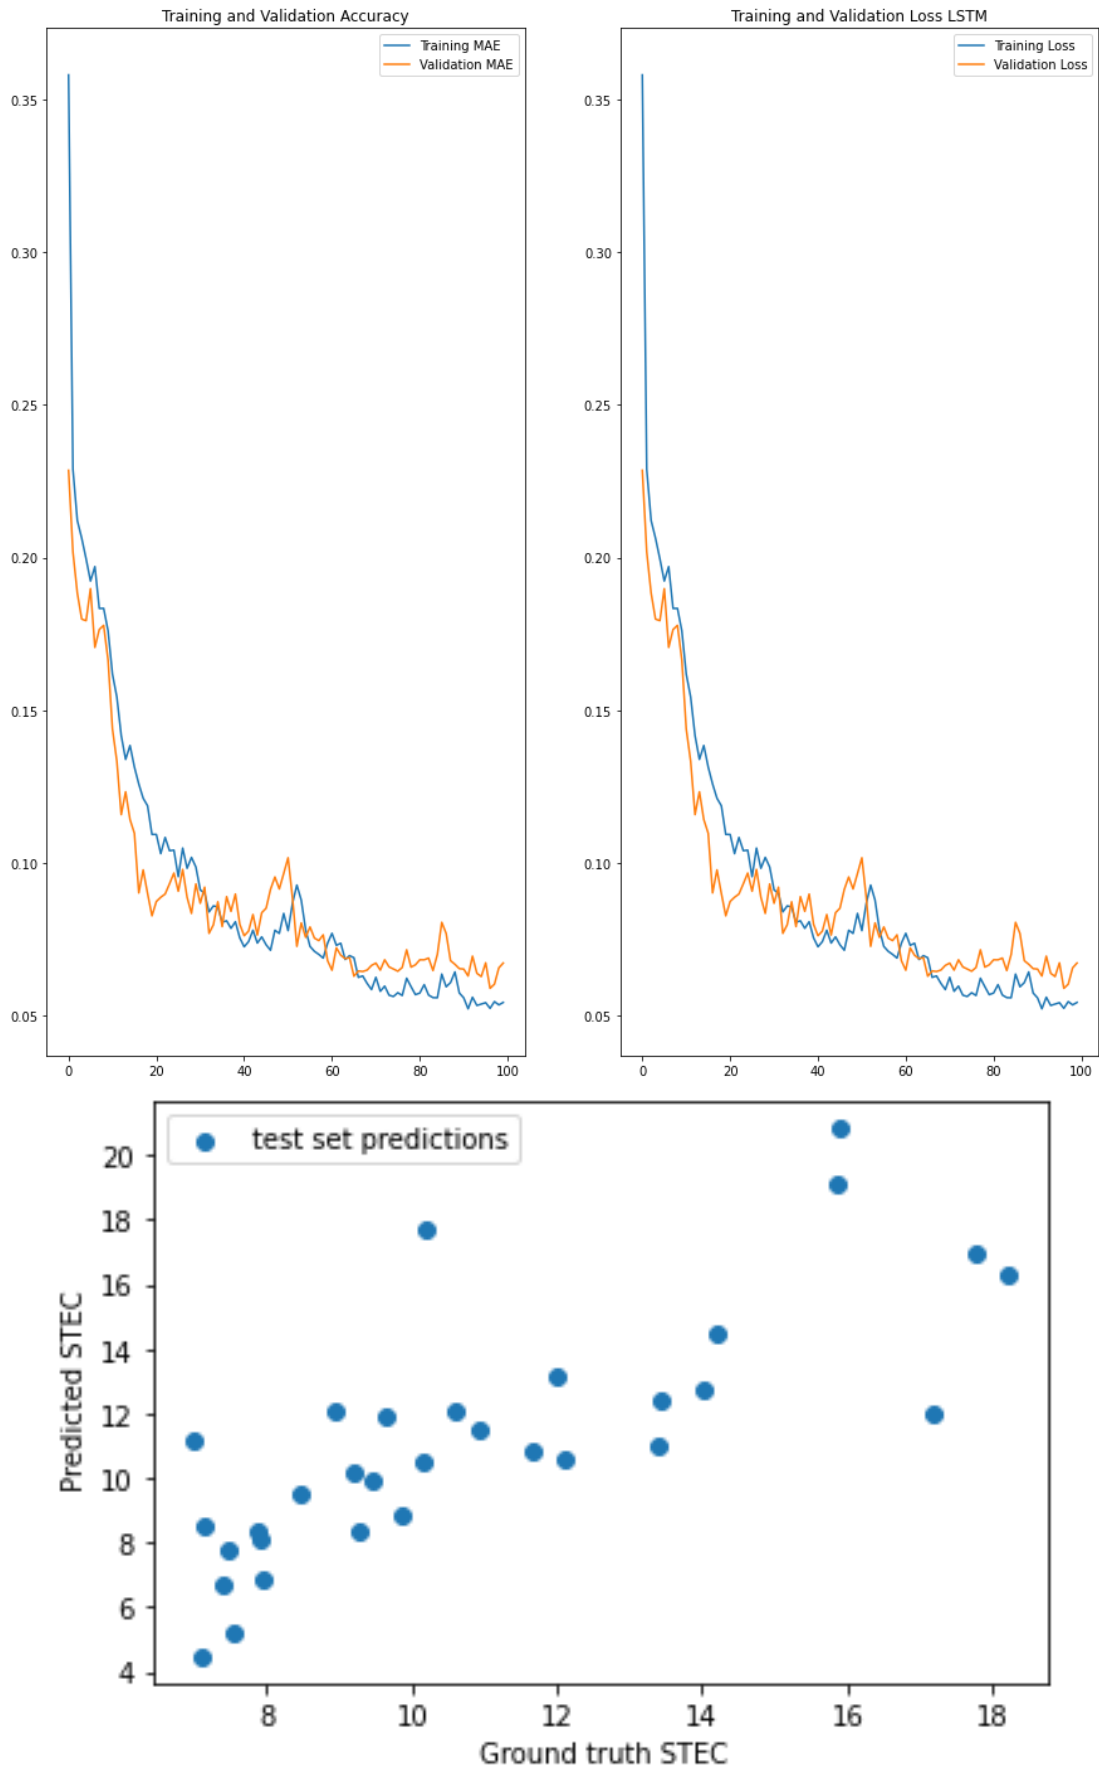




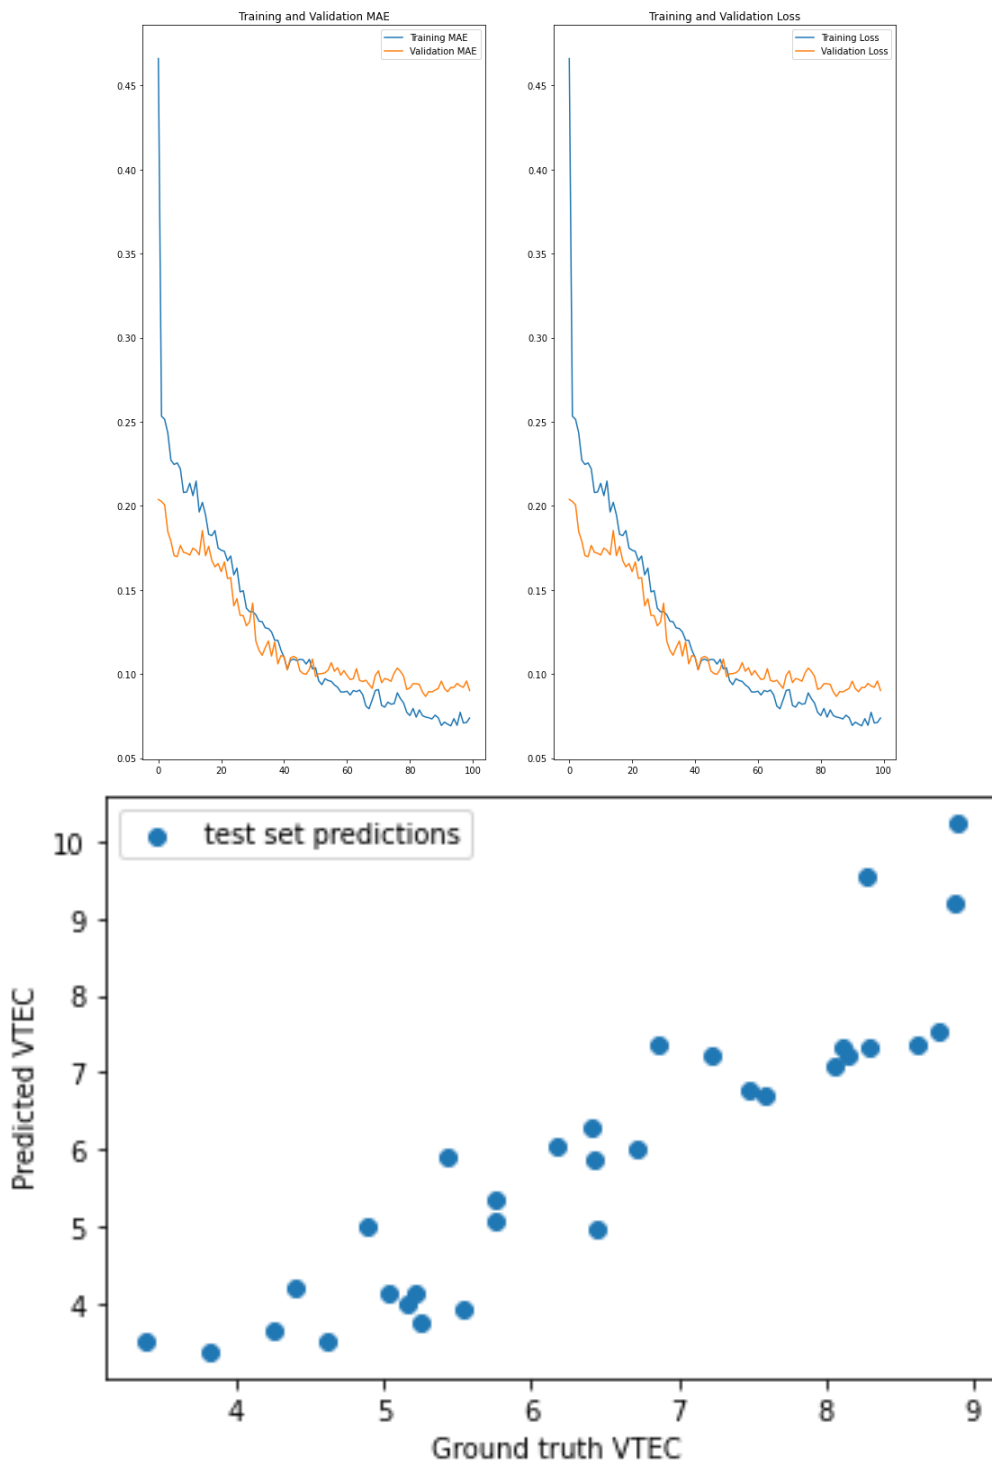


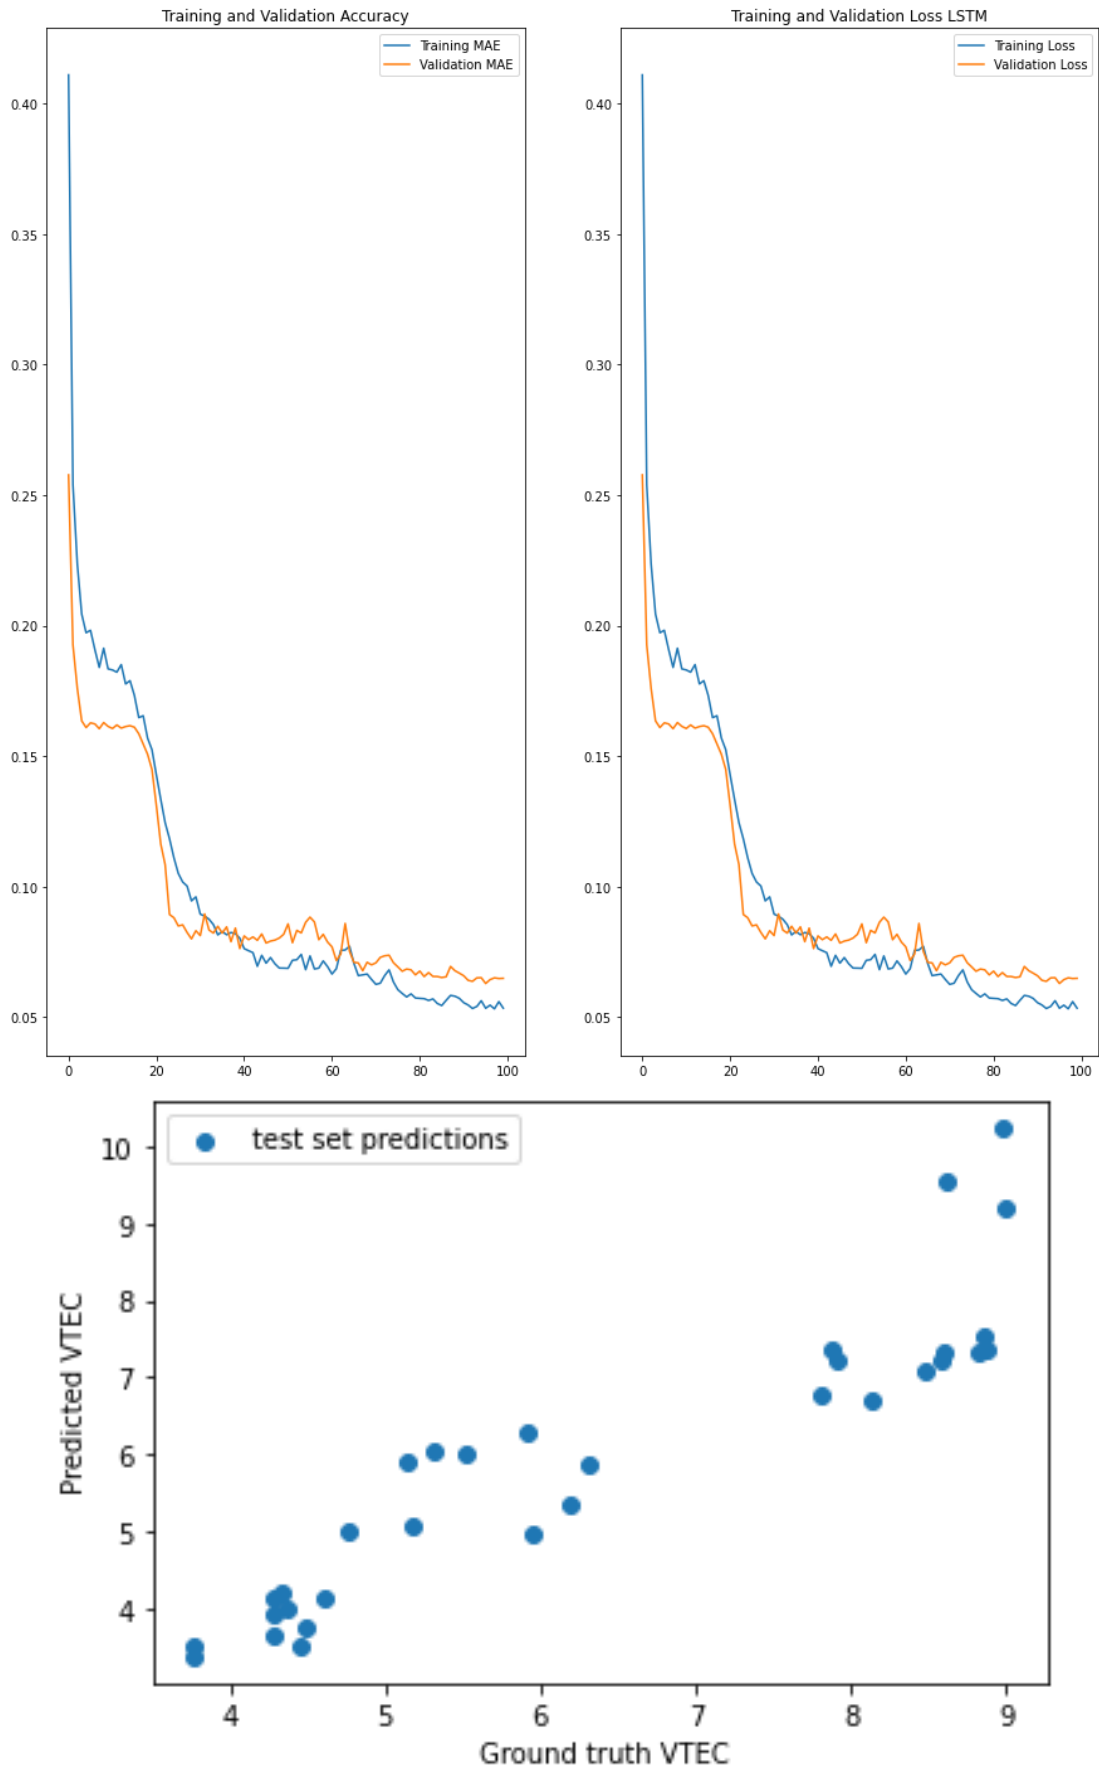


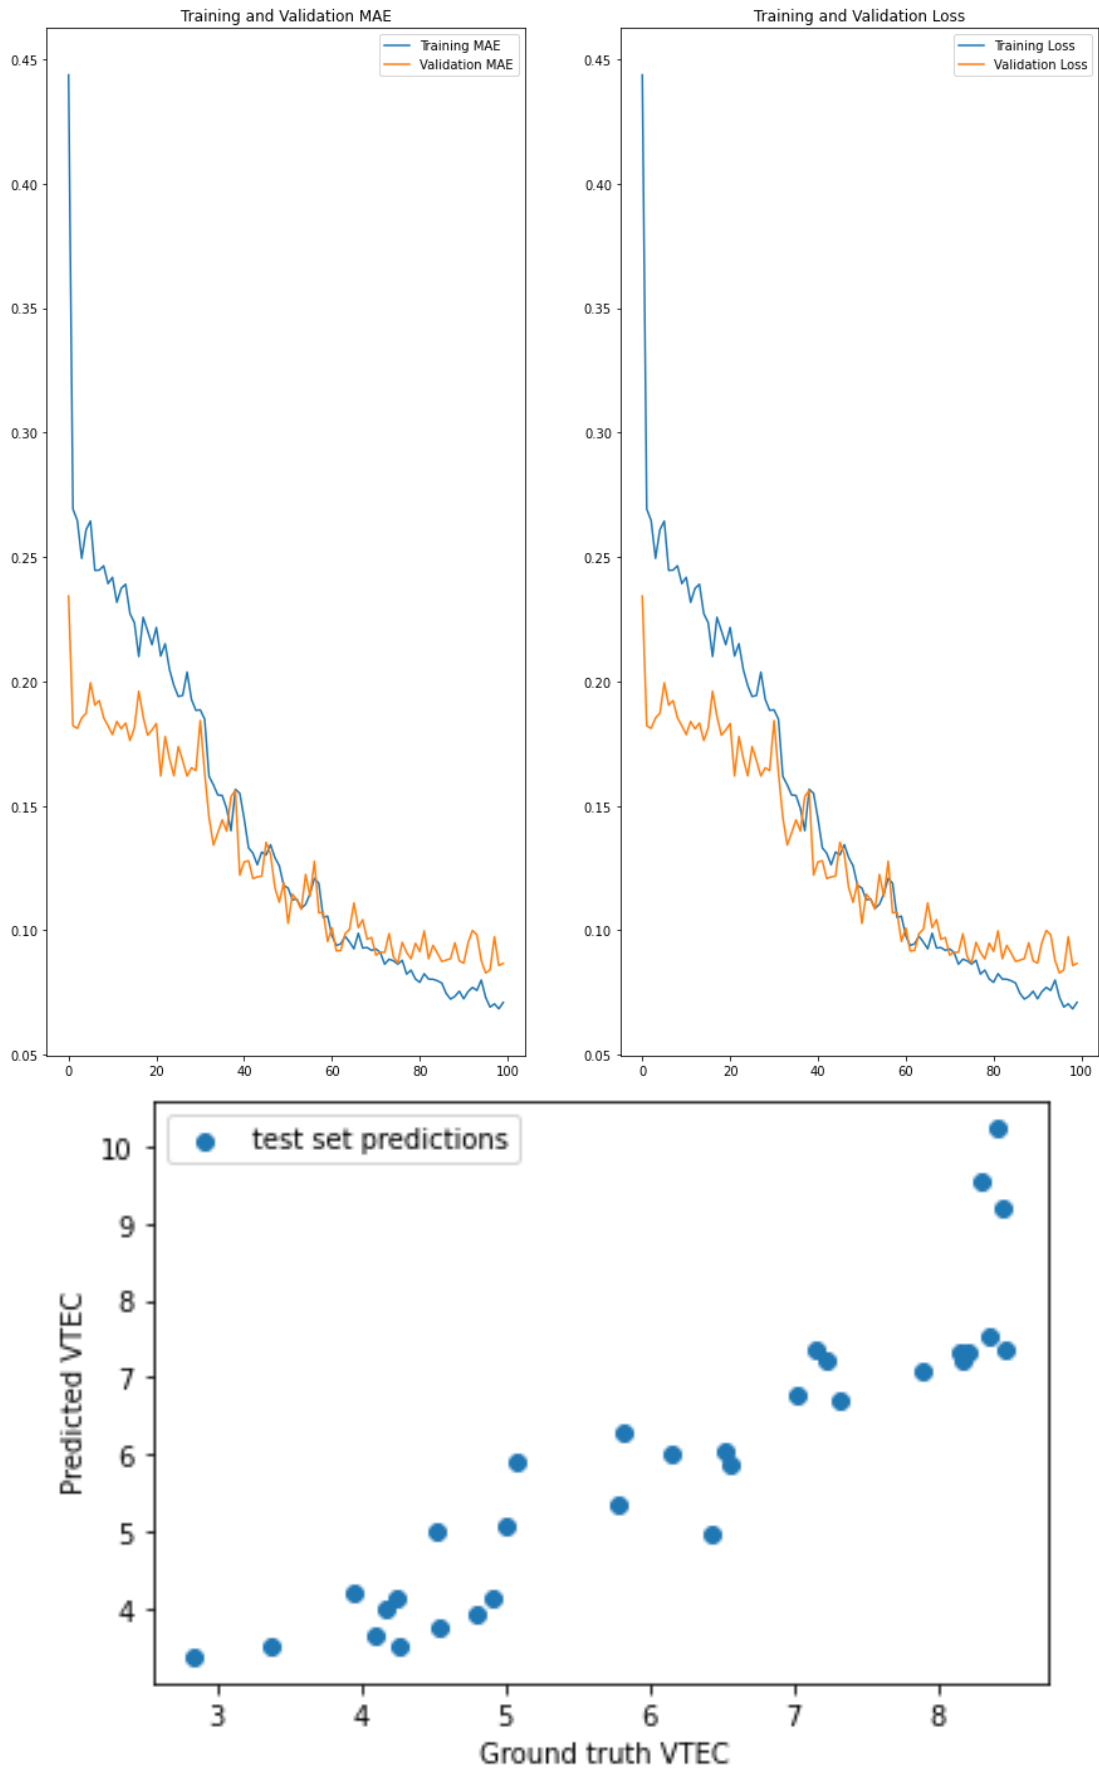







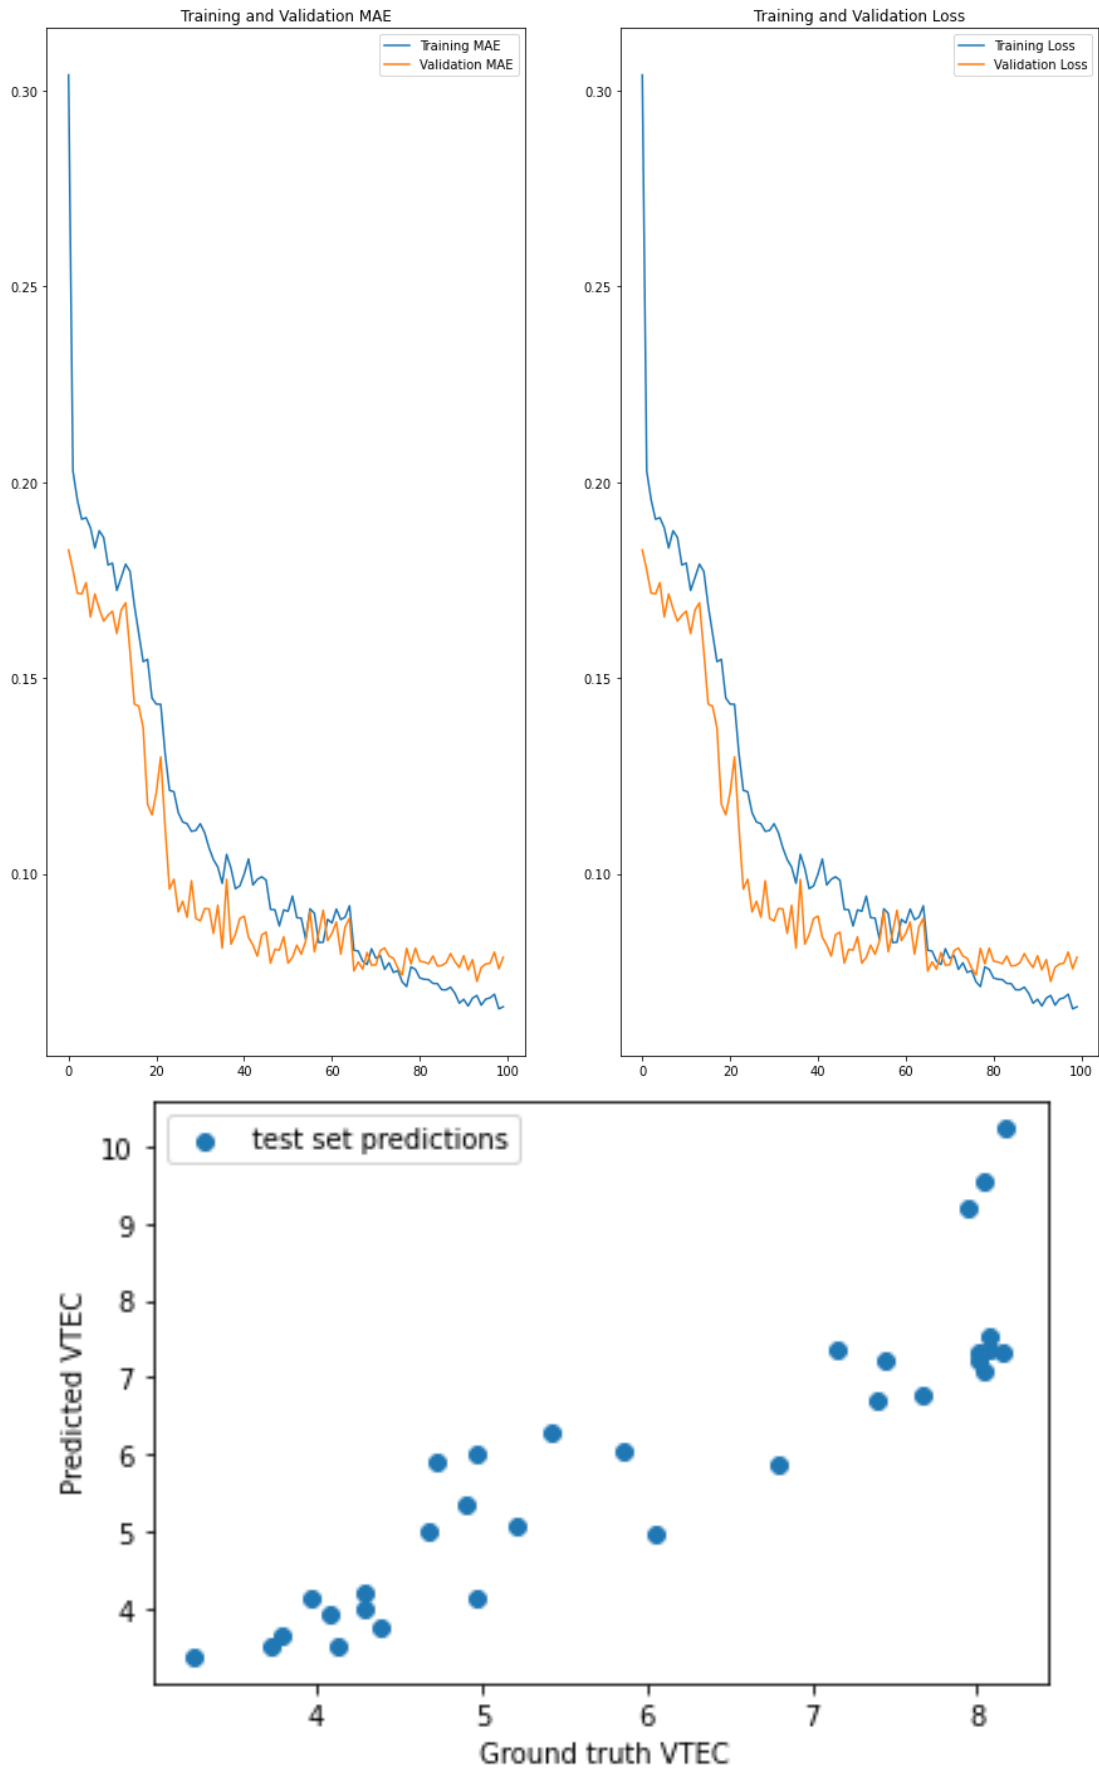
ΥΤΕC ΦΕΒΡΟΥΑΡΙΟΥ






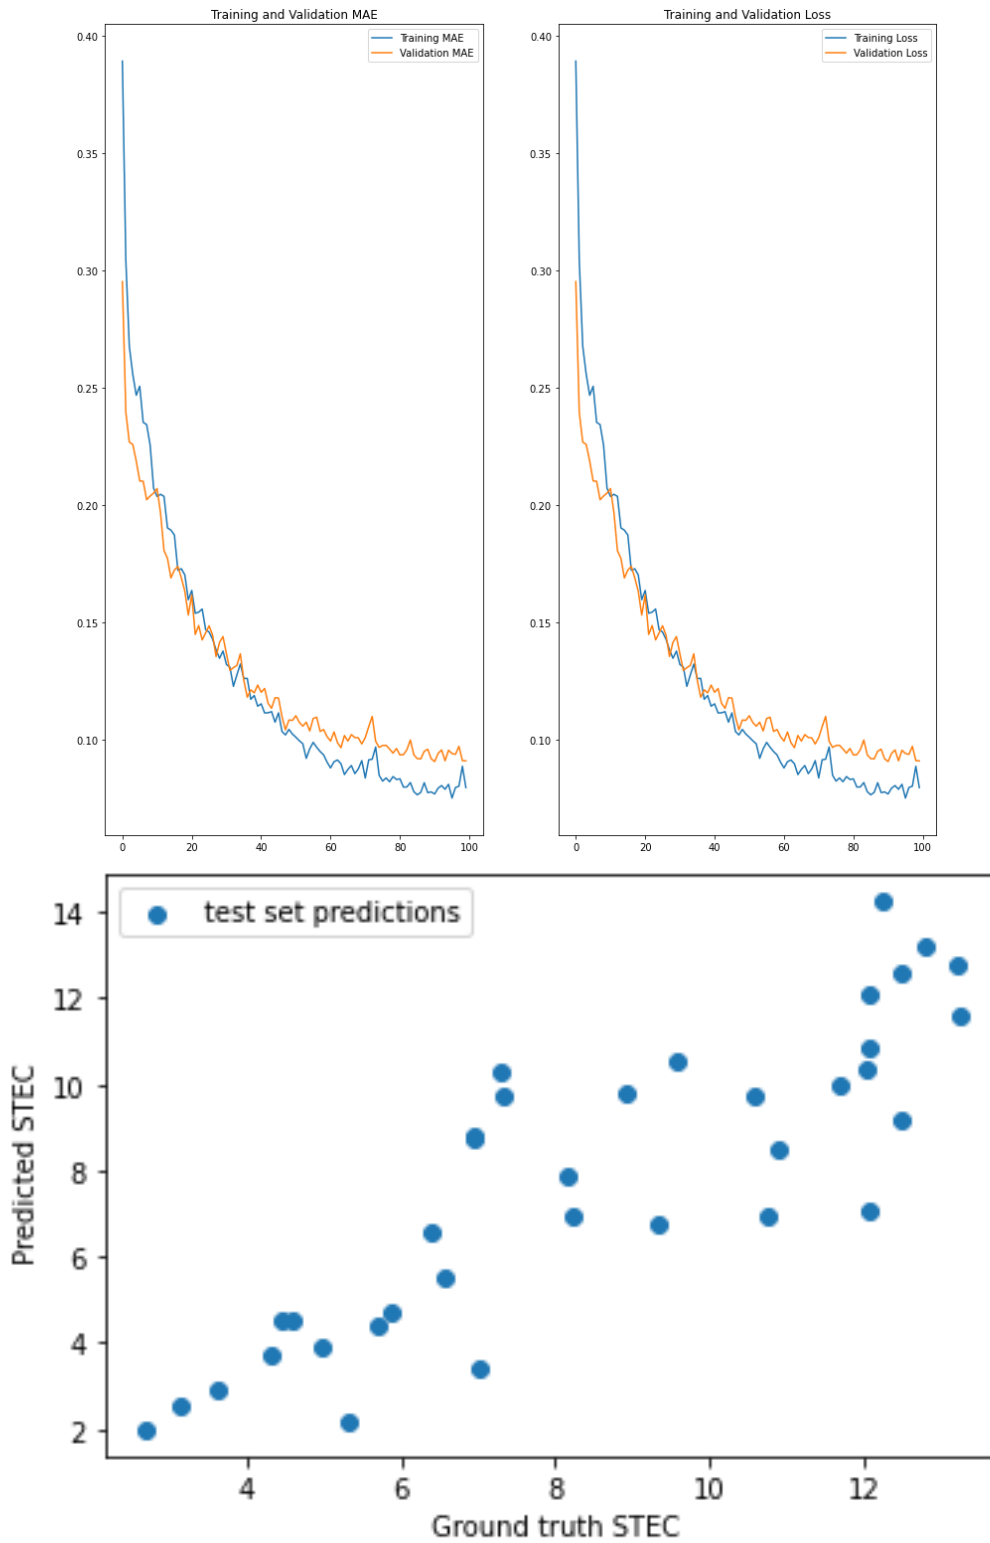








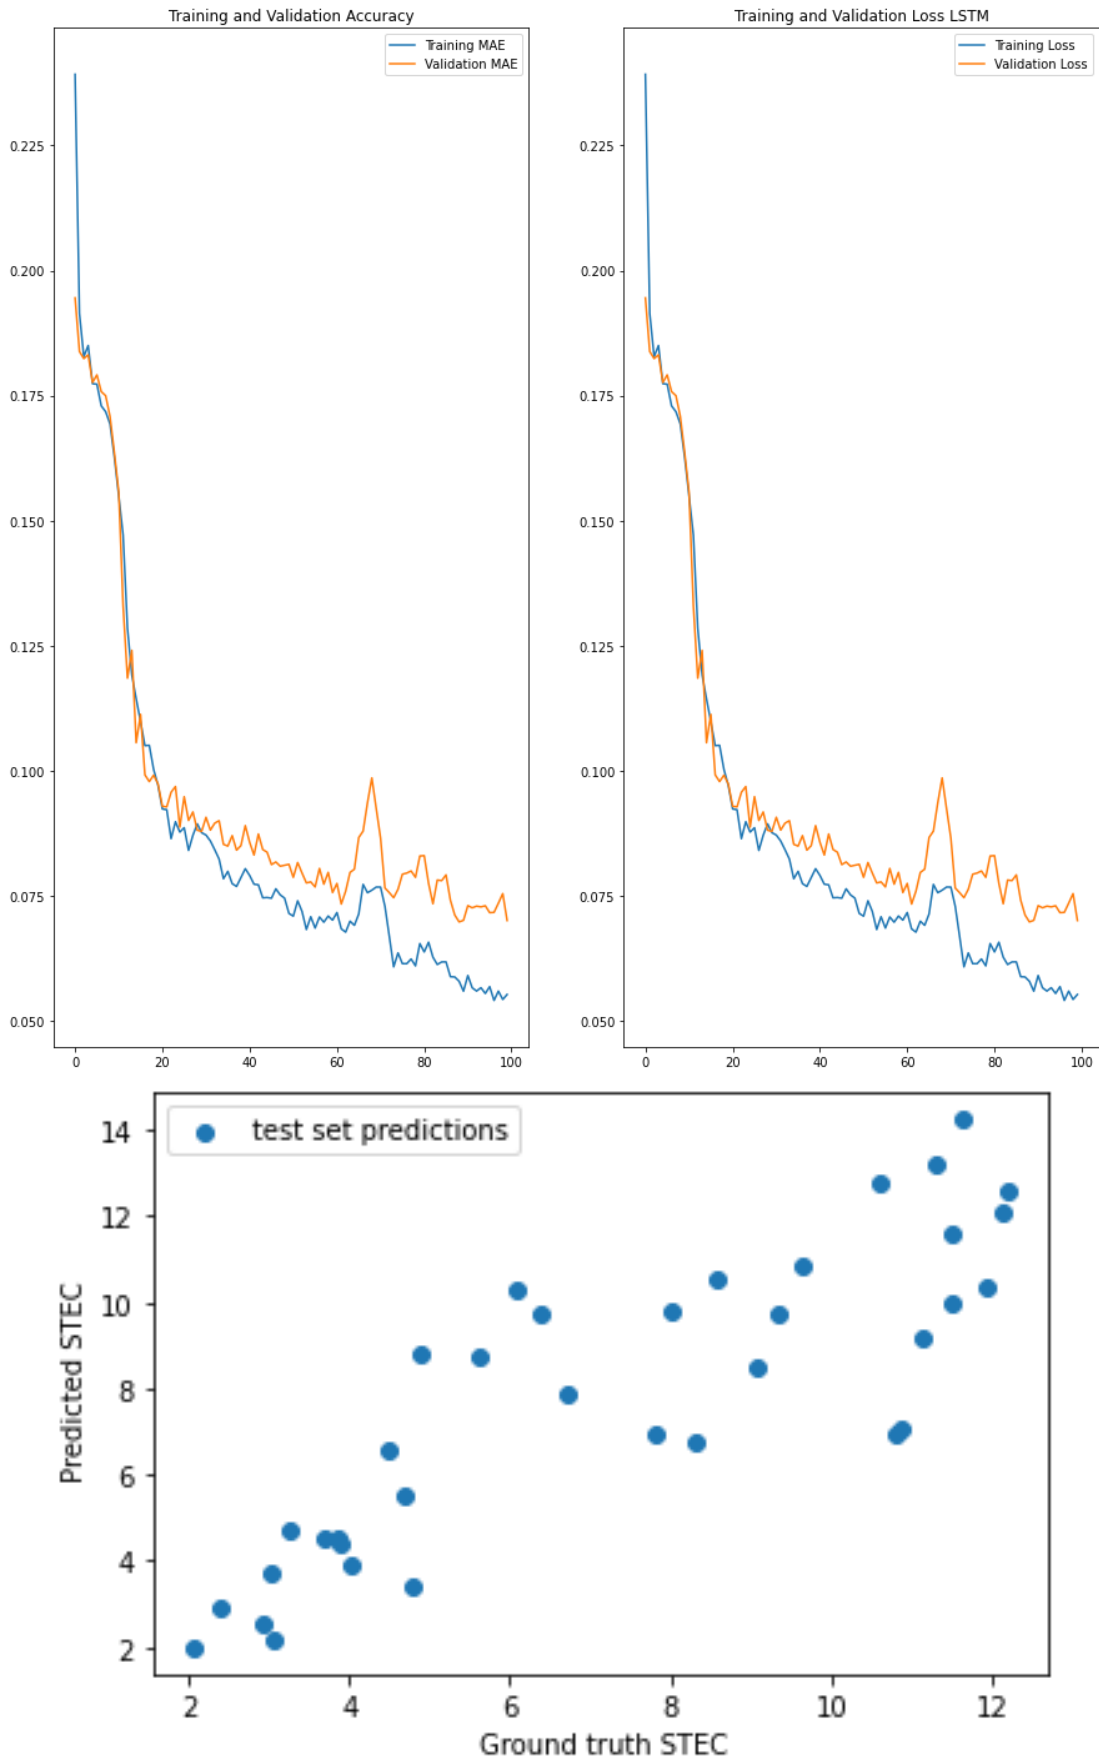





STEC ΜΑΡΤΙΟΥ

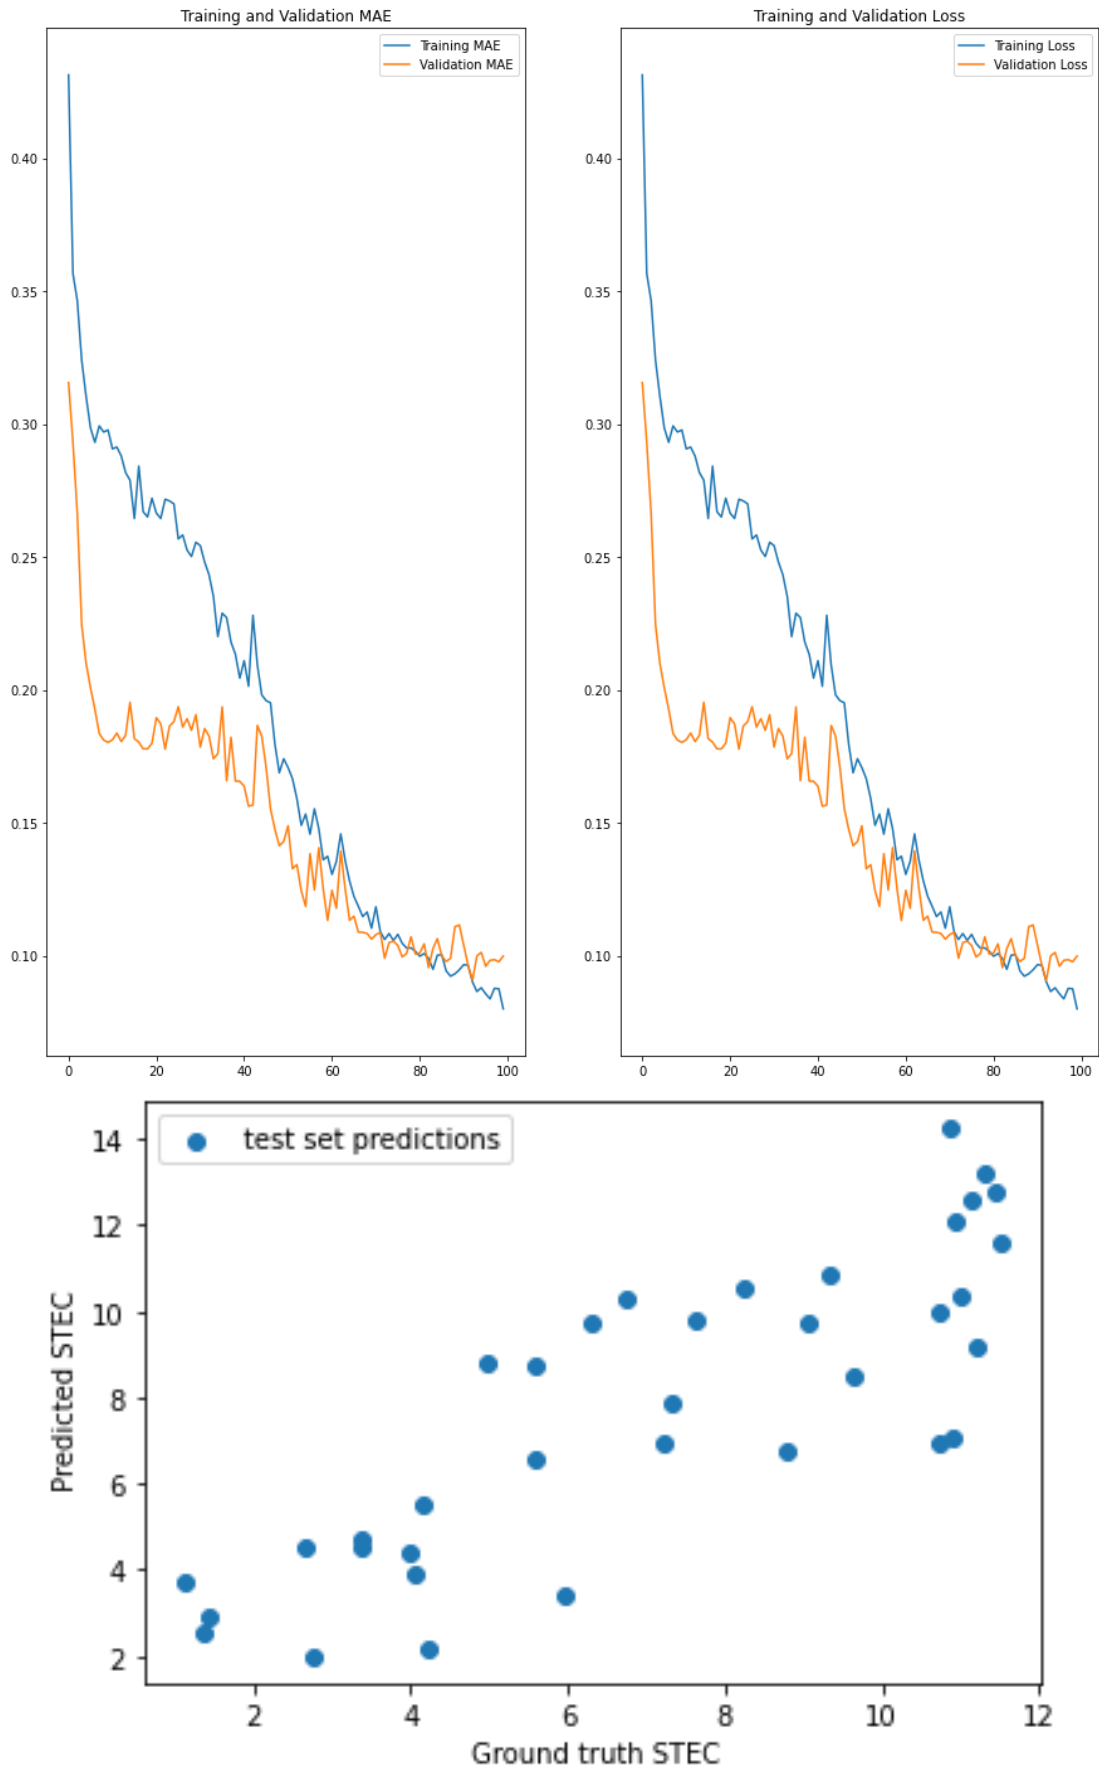




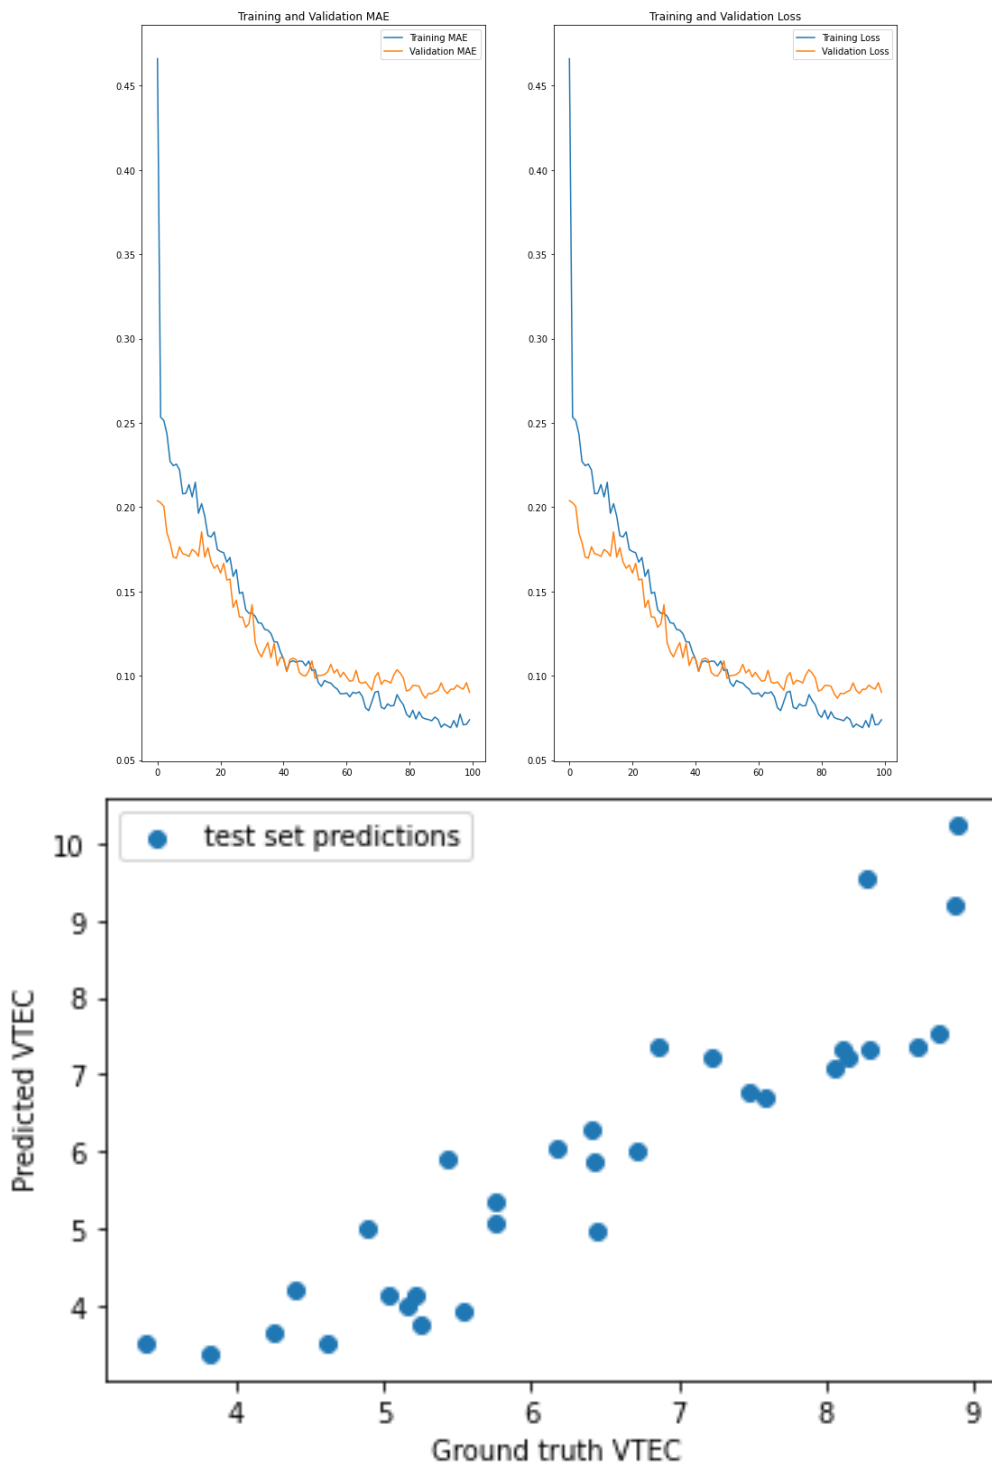


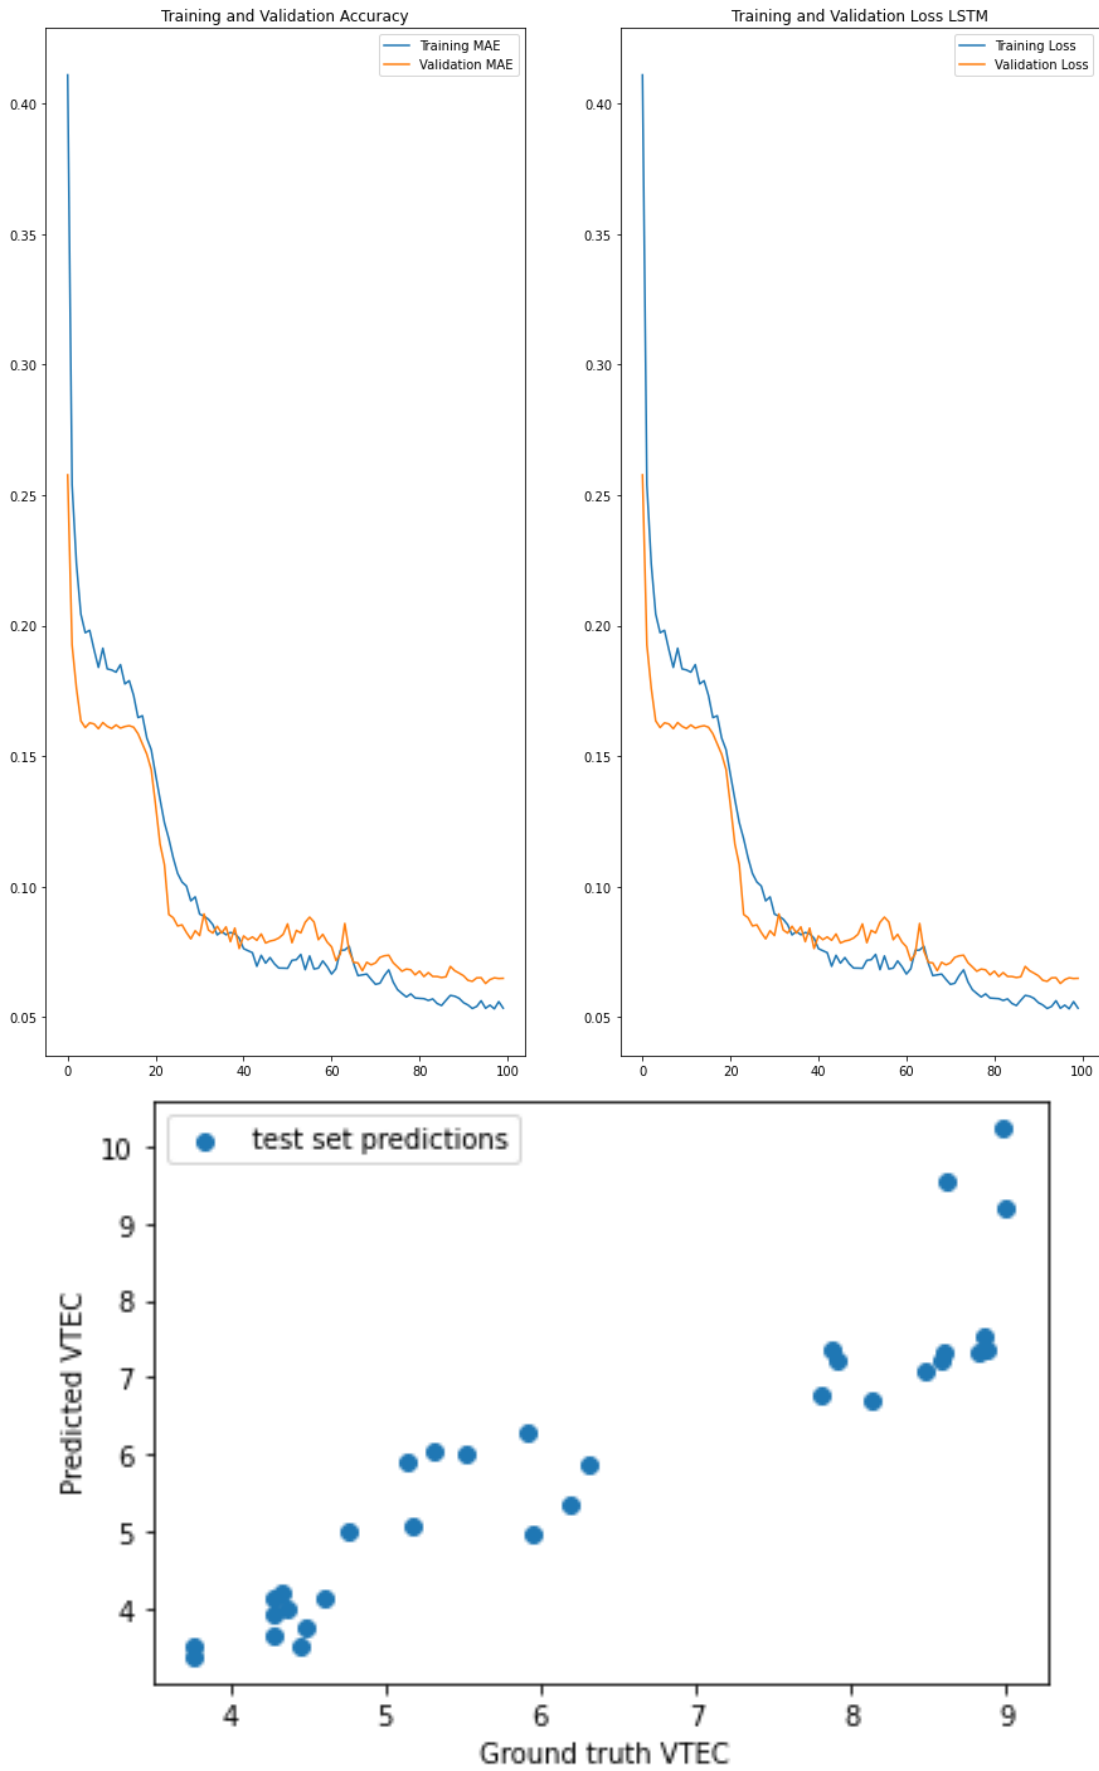


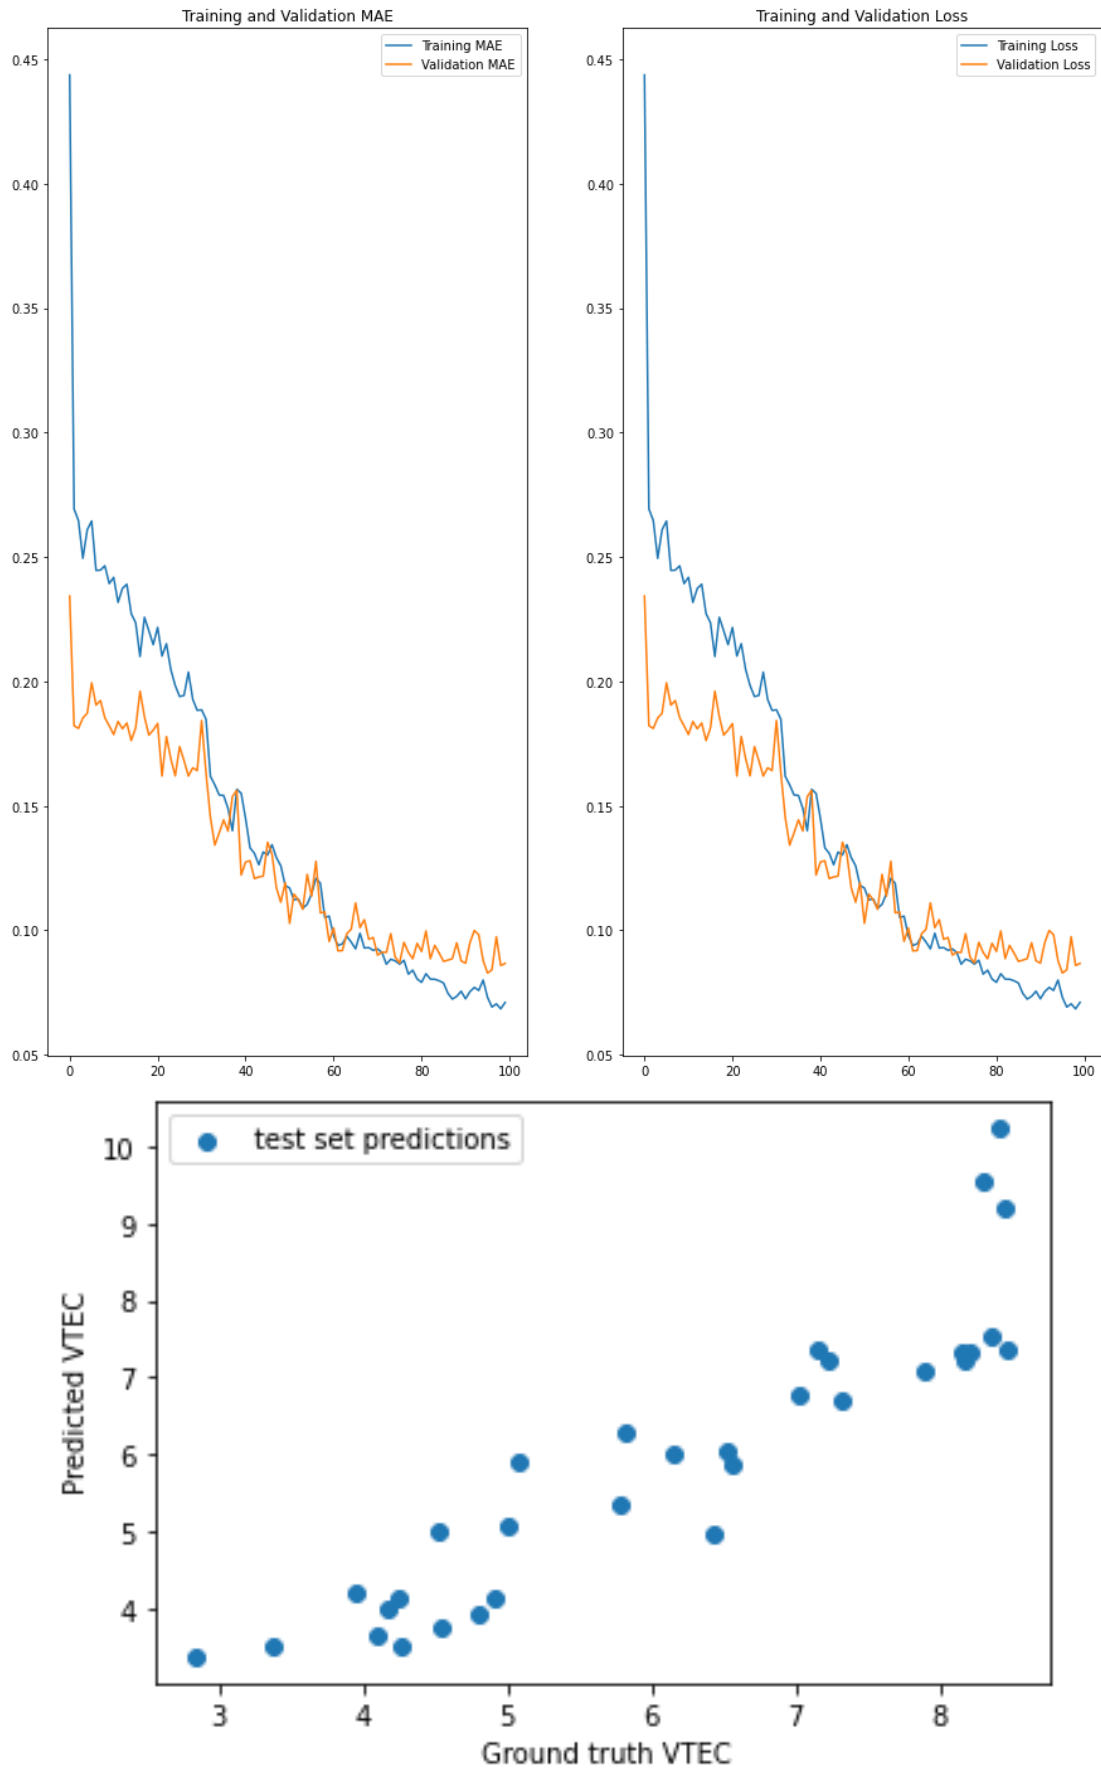







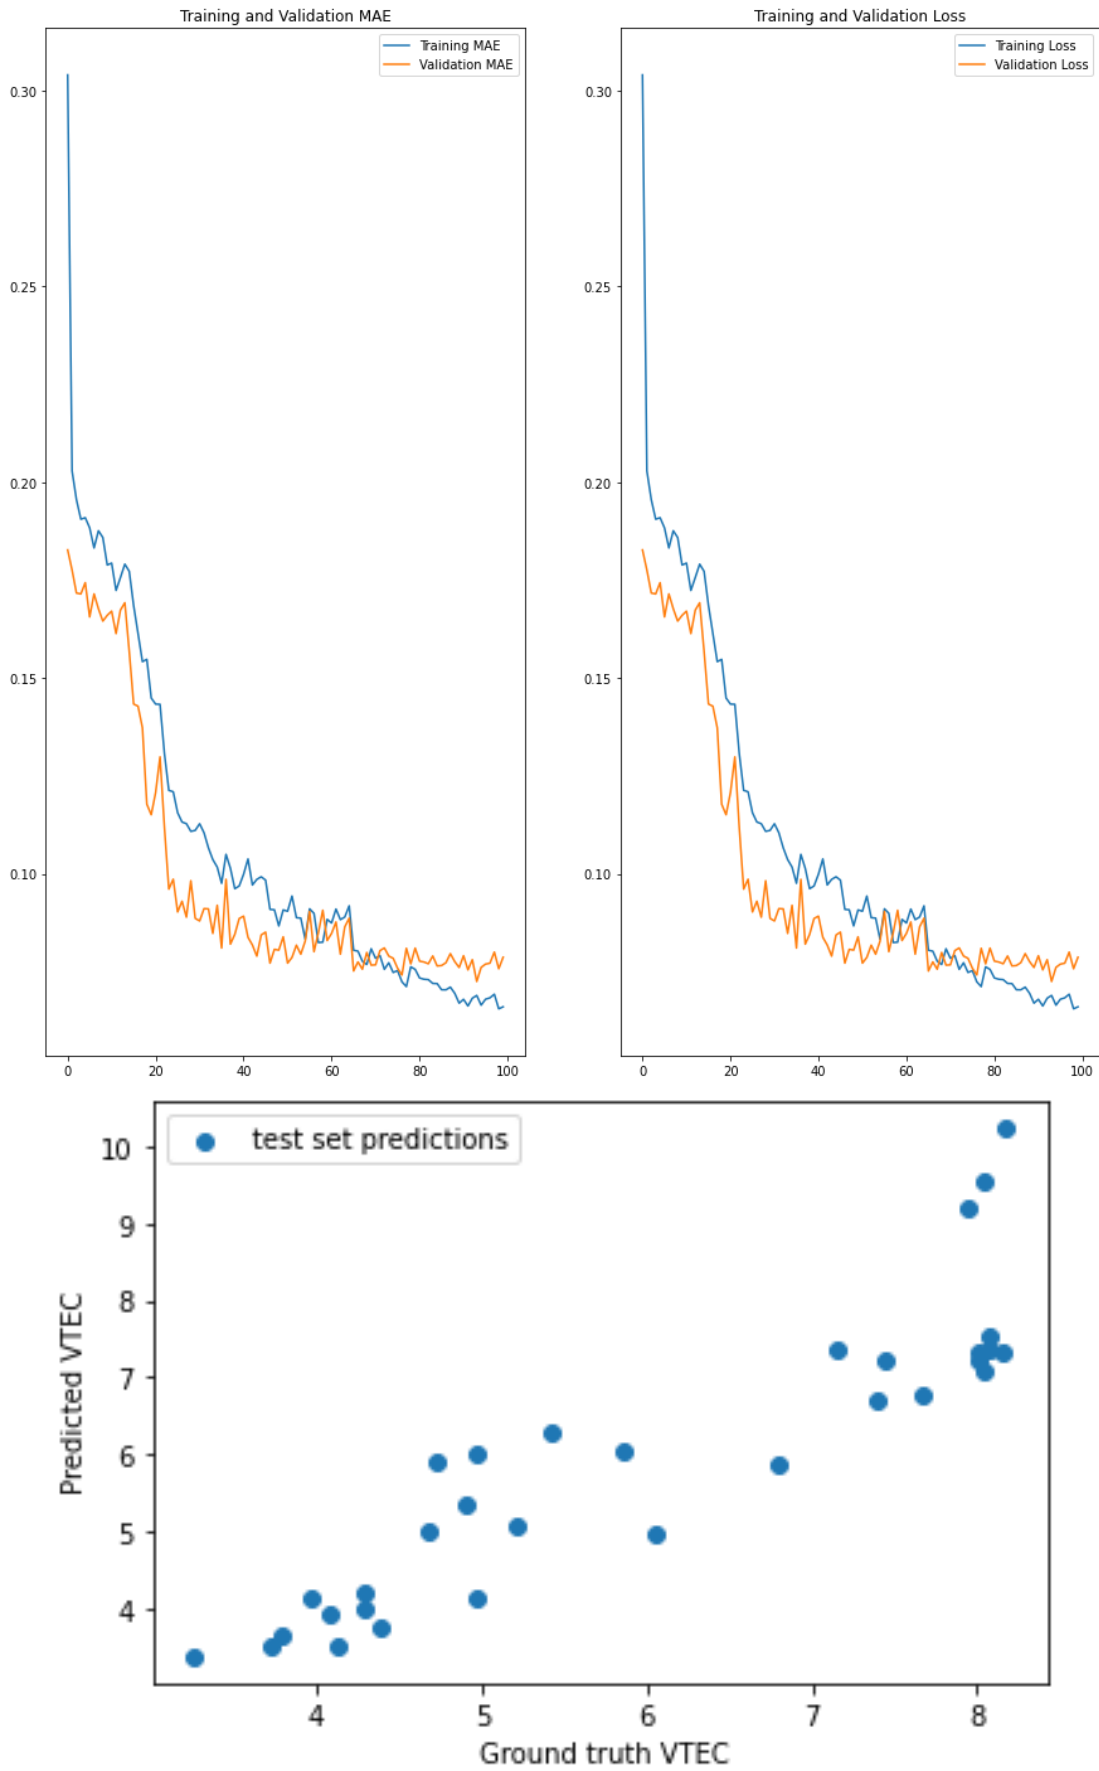
VTEC ΜΑΡΤΙΟΥ

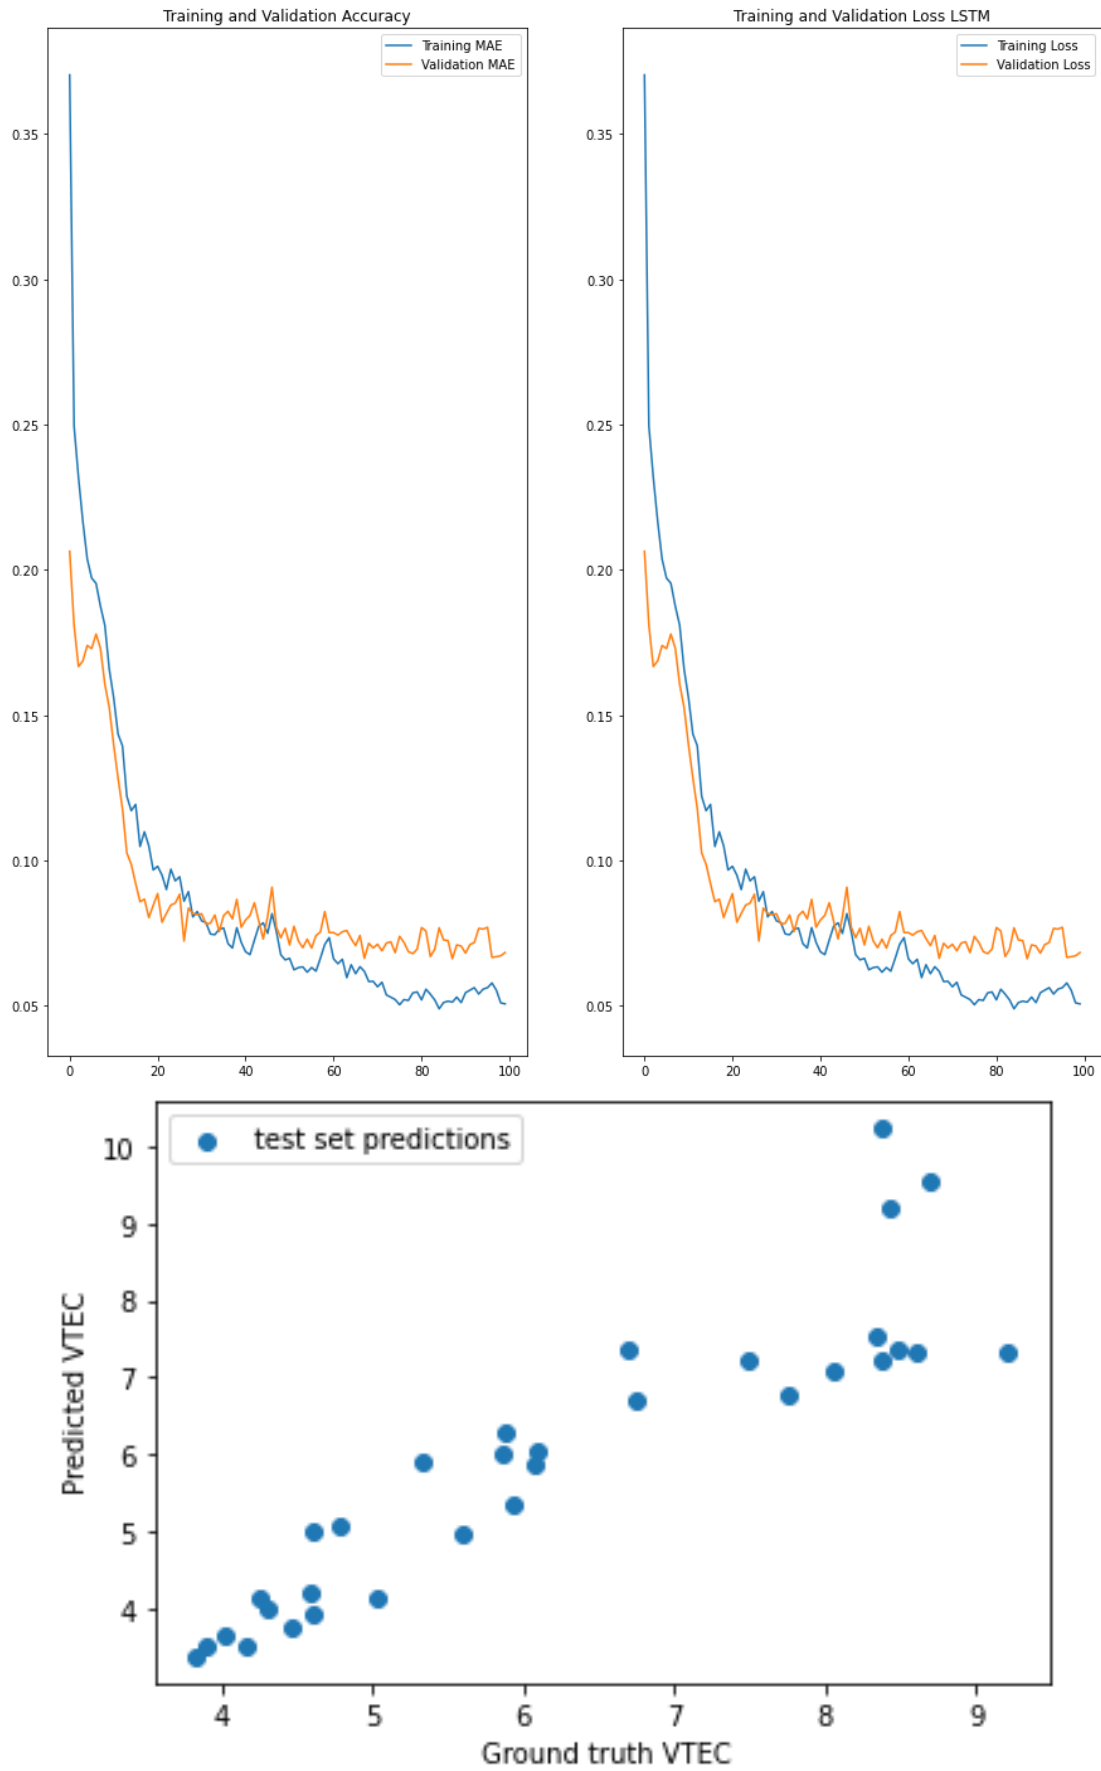






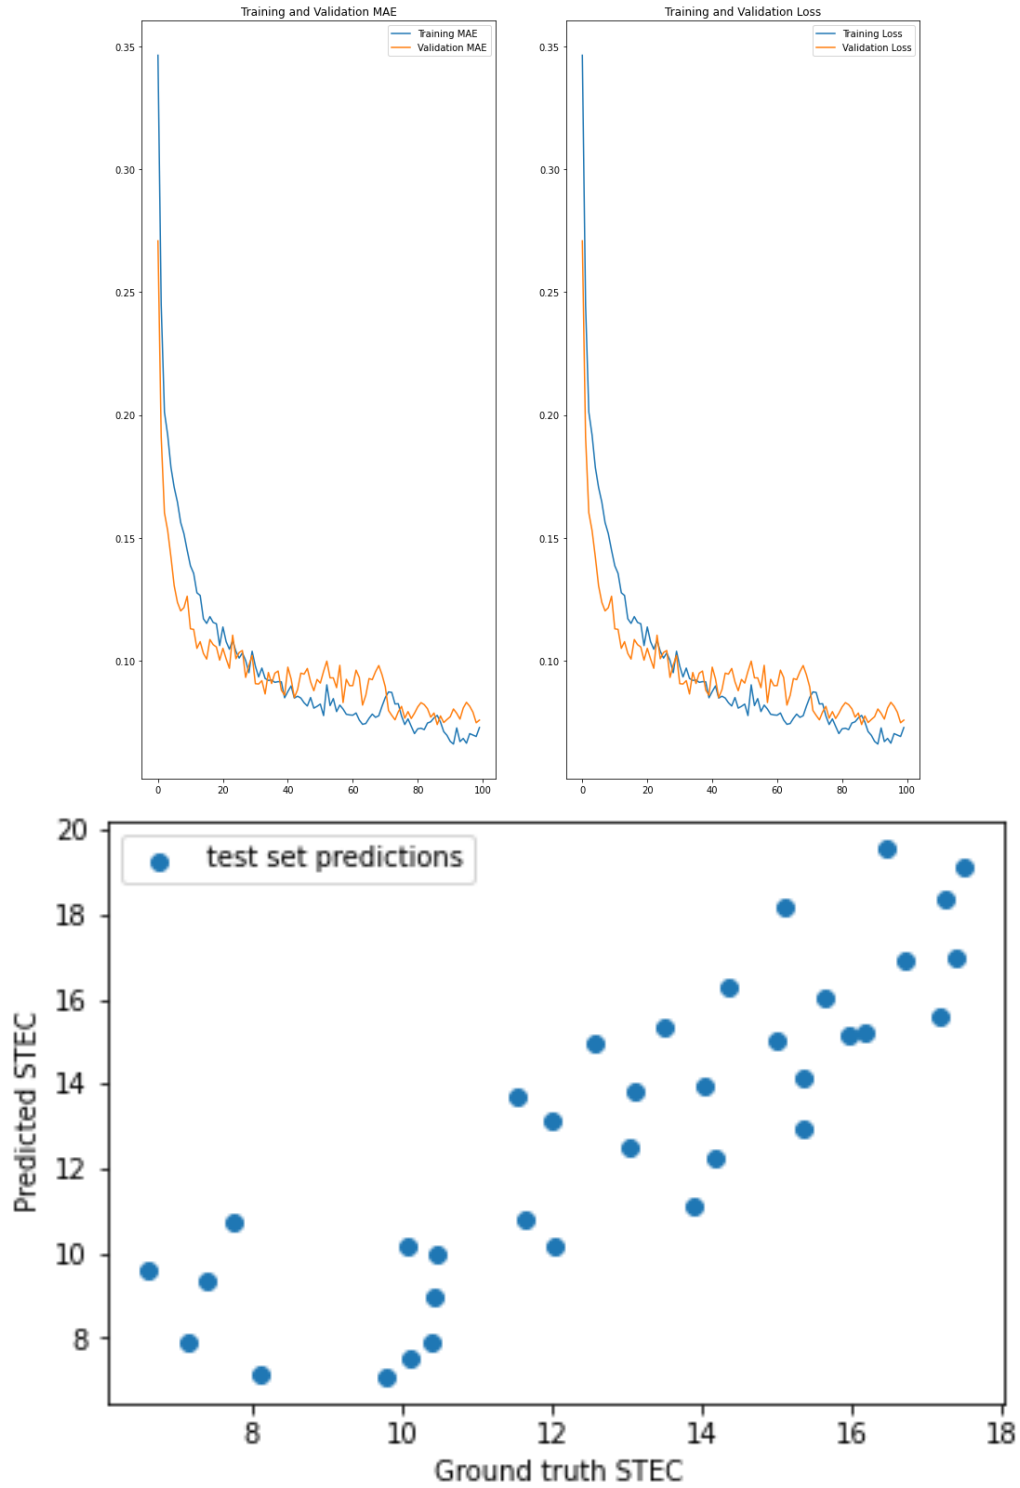


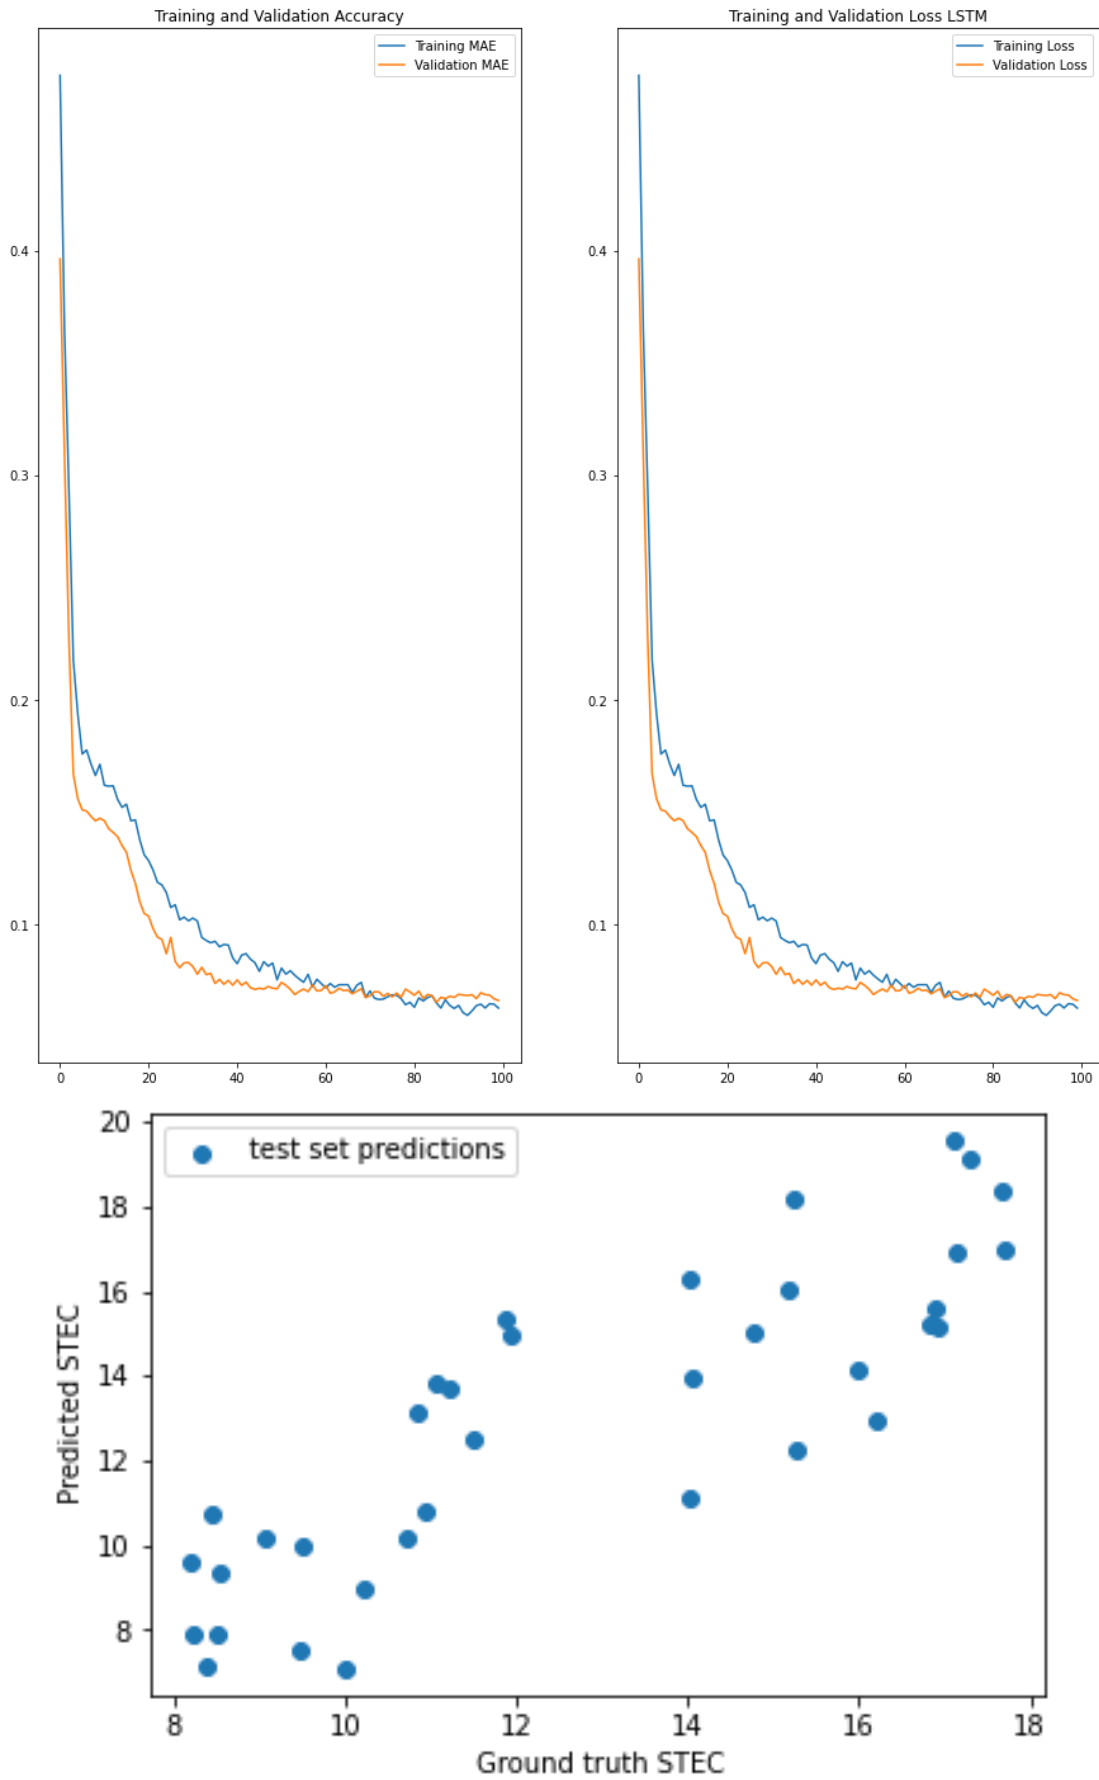


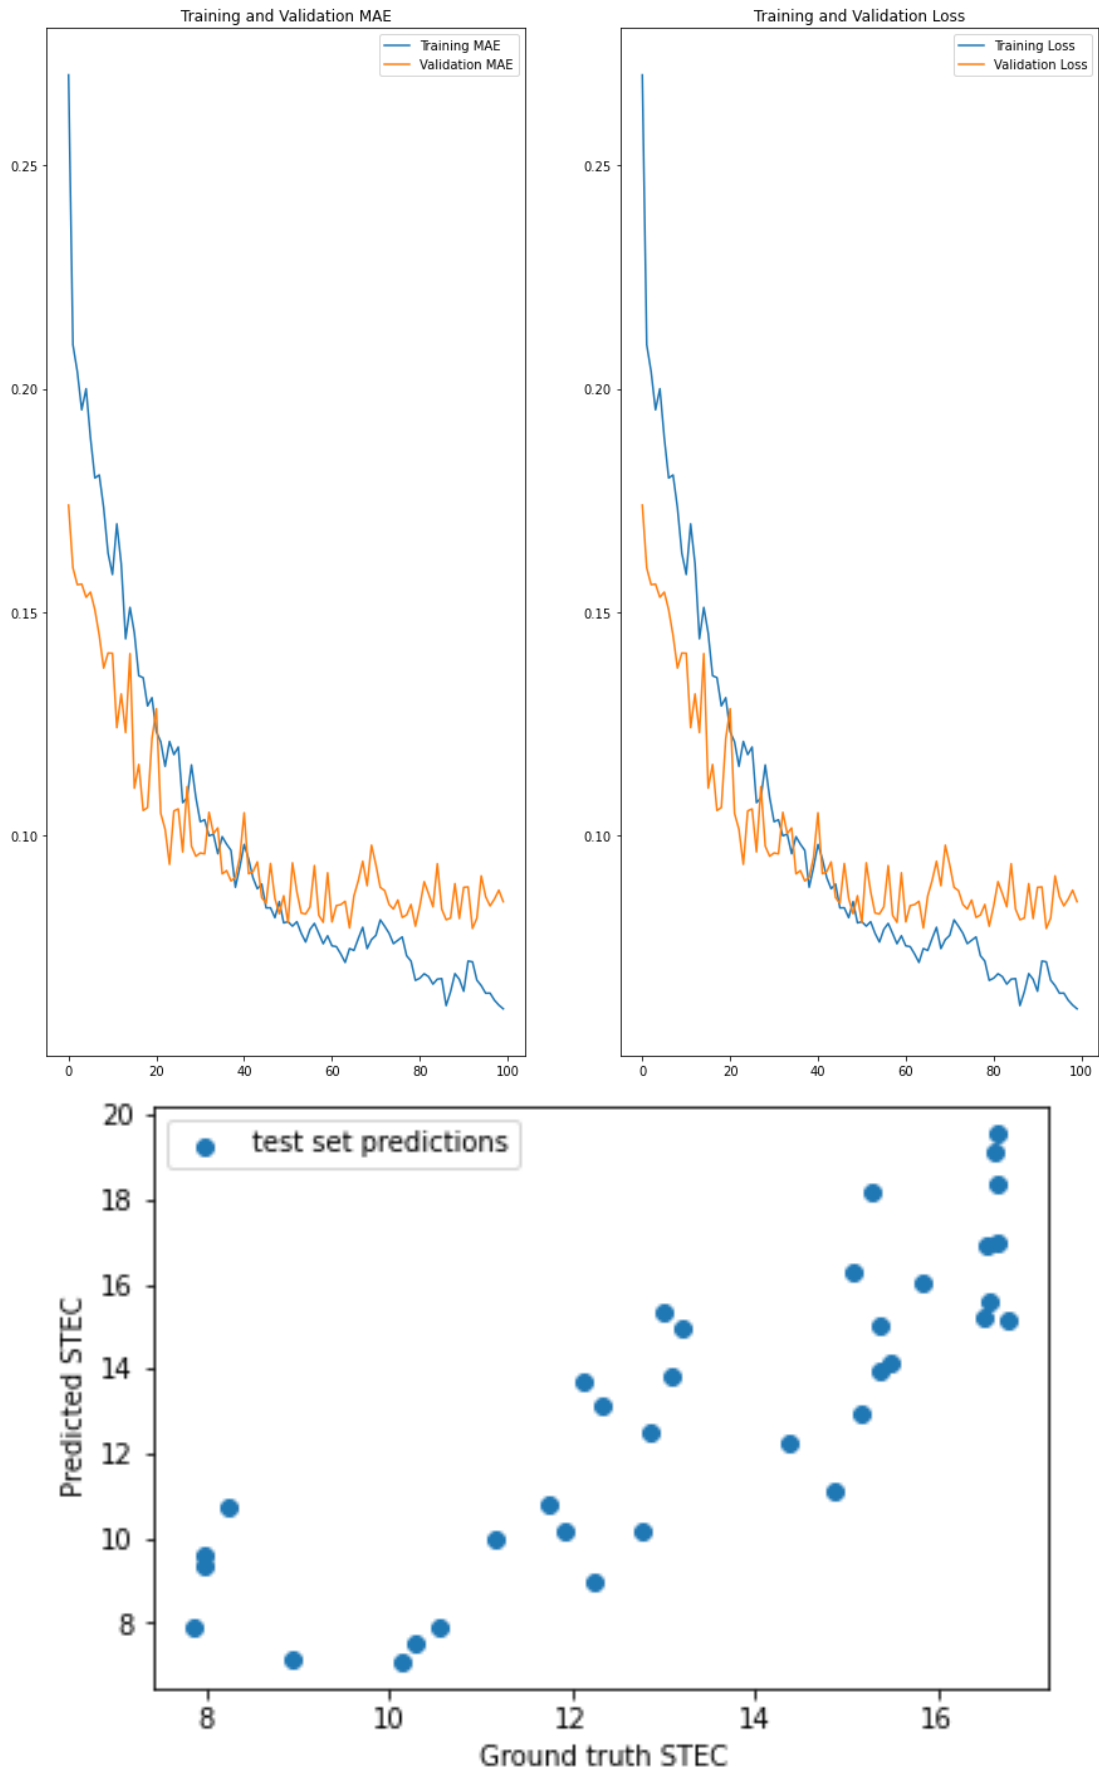


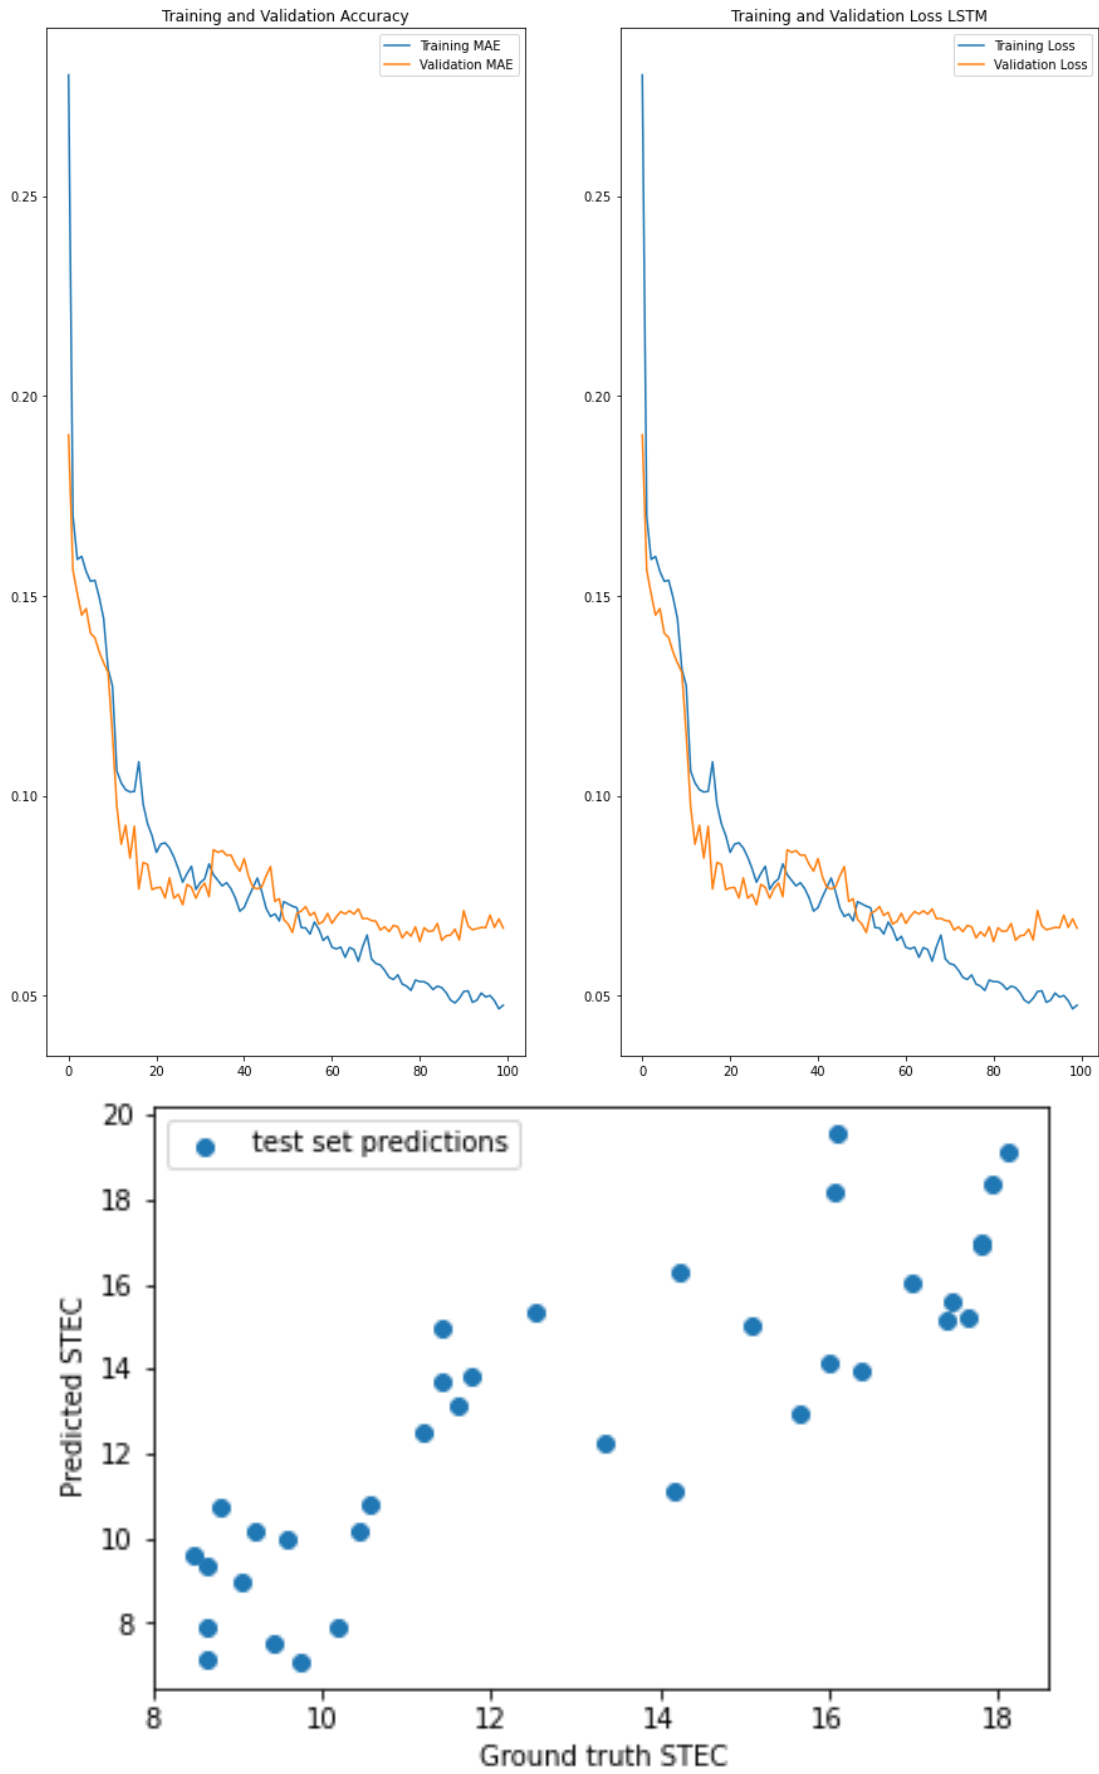
Αποτελέσματα Σεναρίου Νο 6 για τους μήνες Ιανουάριο, Φεβρουάριο και Μάρτιο 2018

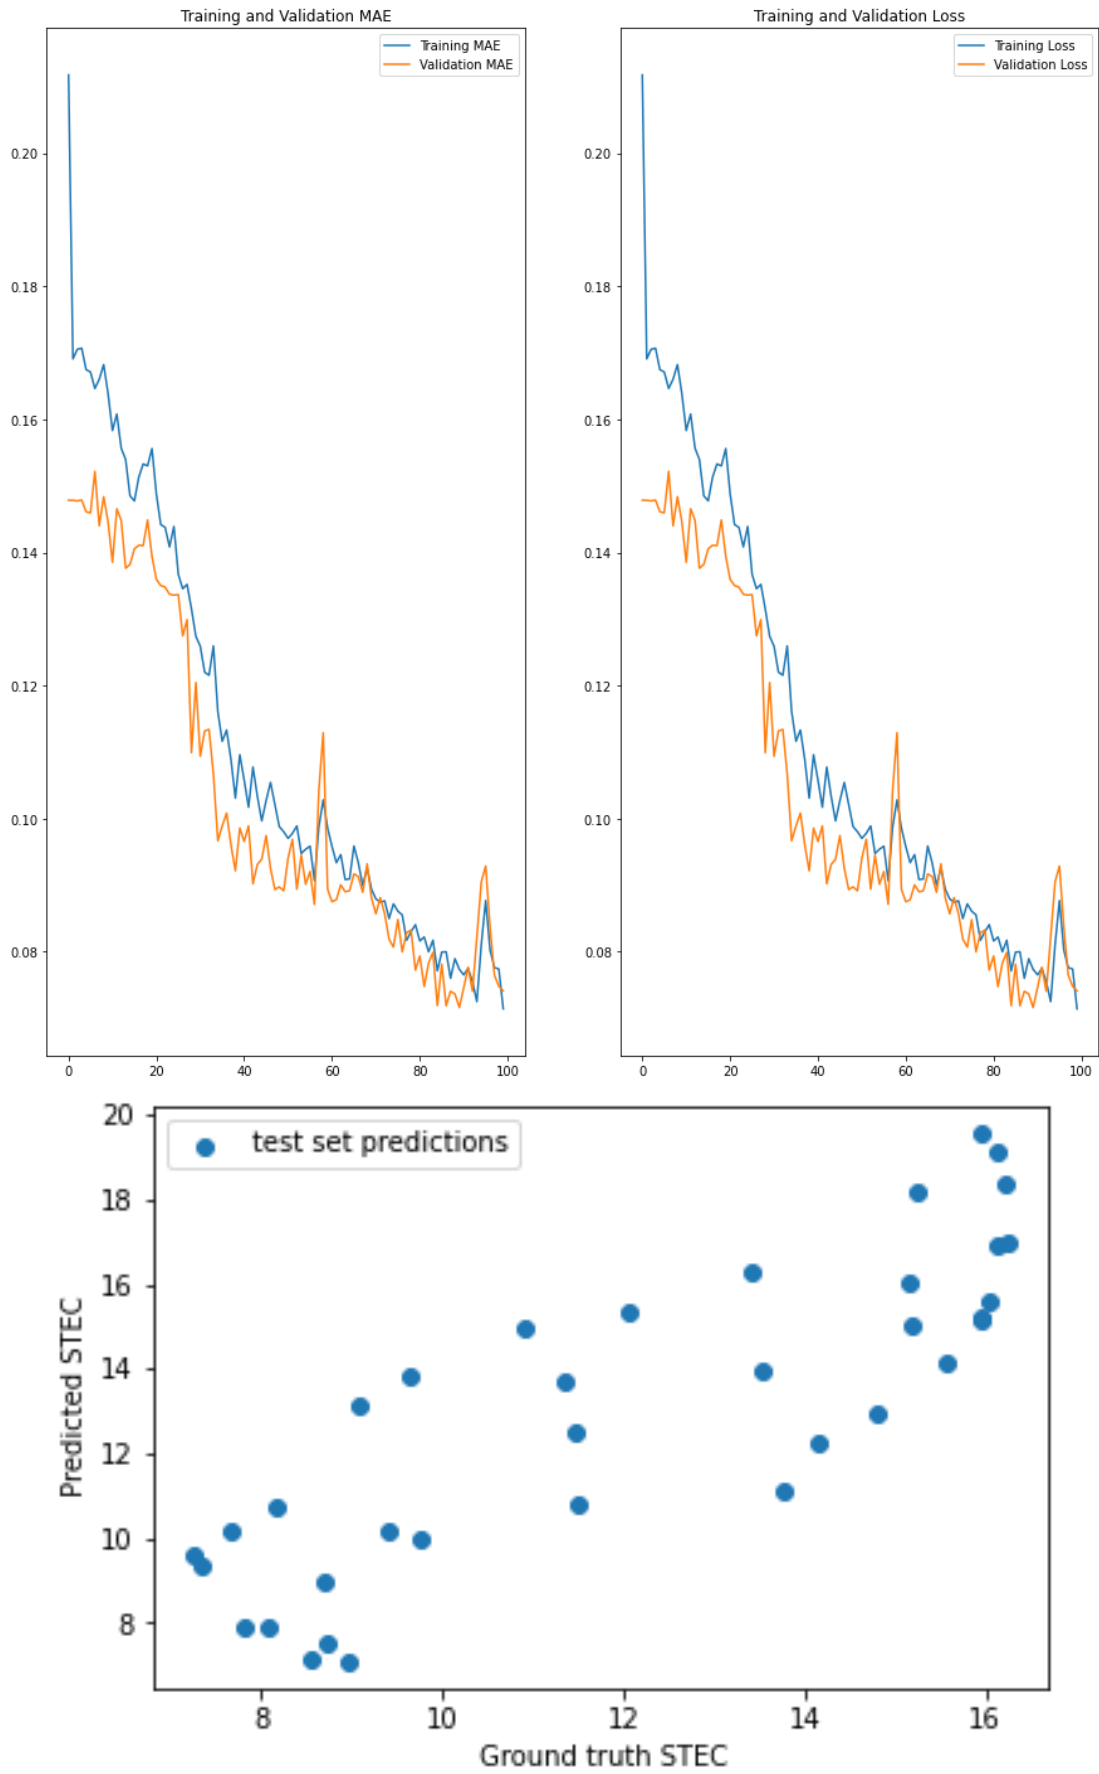
STEC ΙΑΝΟΥΑΡΙΟΥ








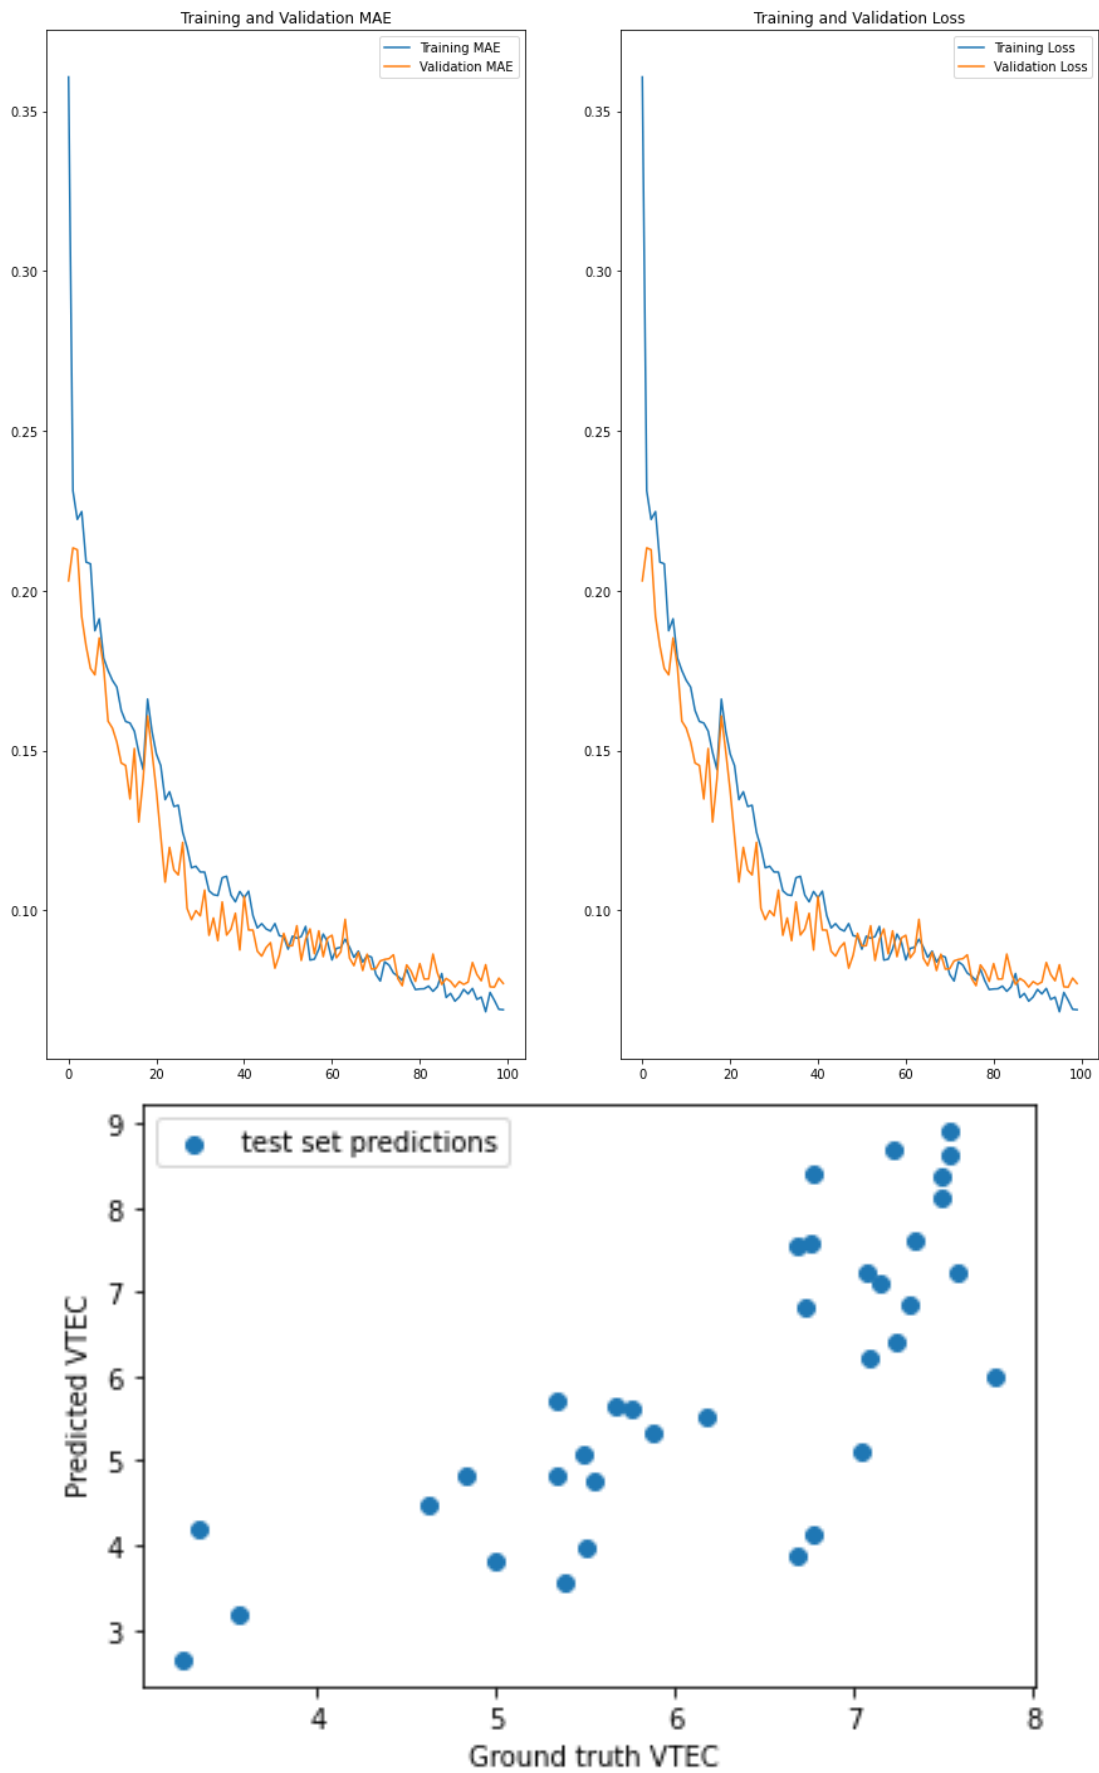


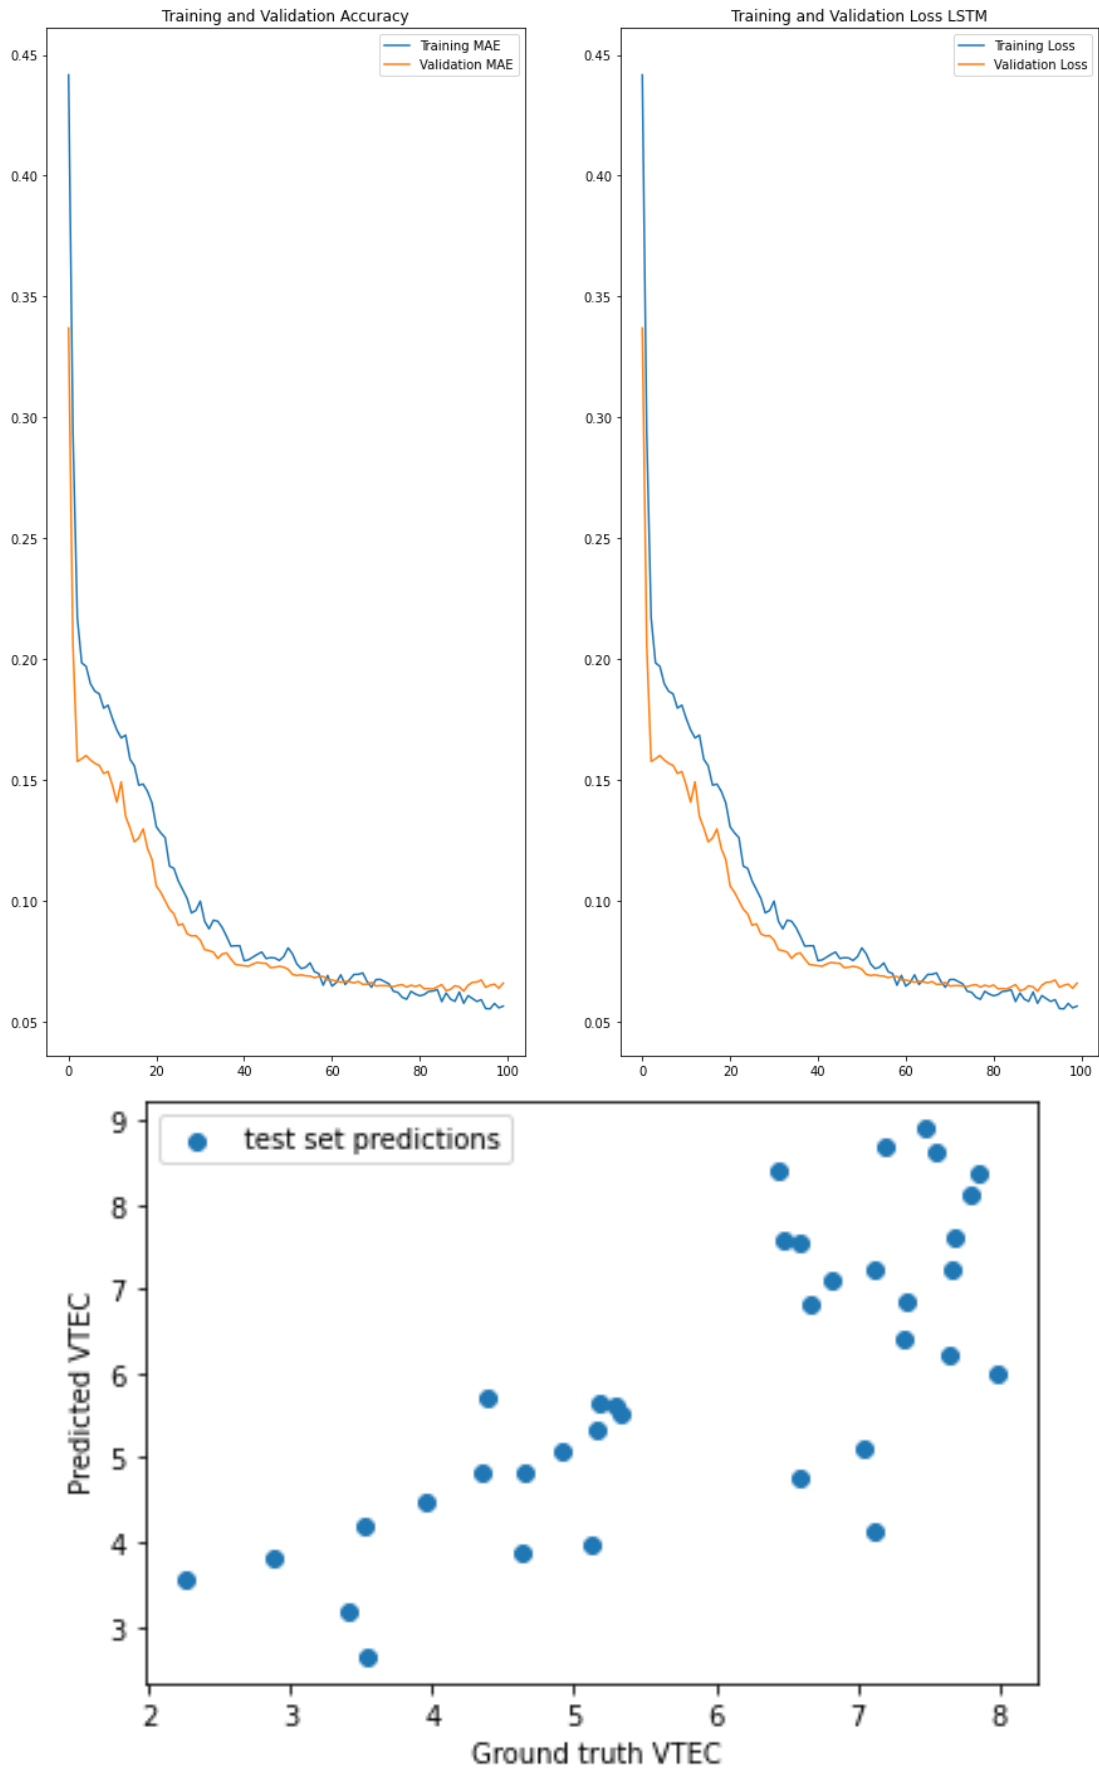







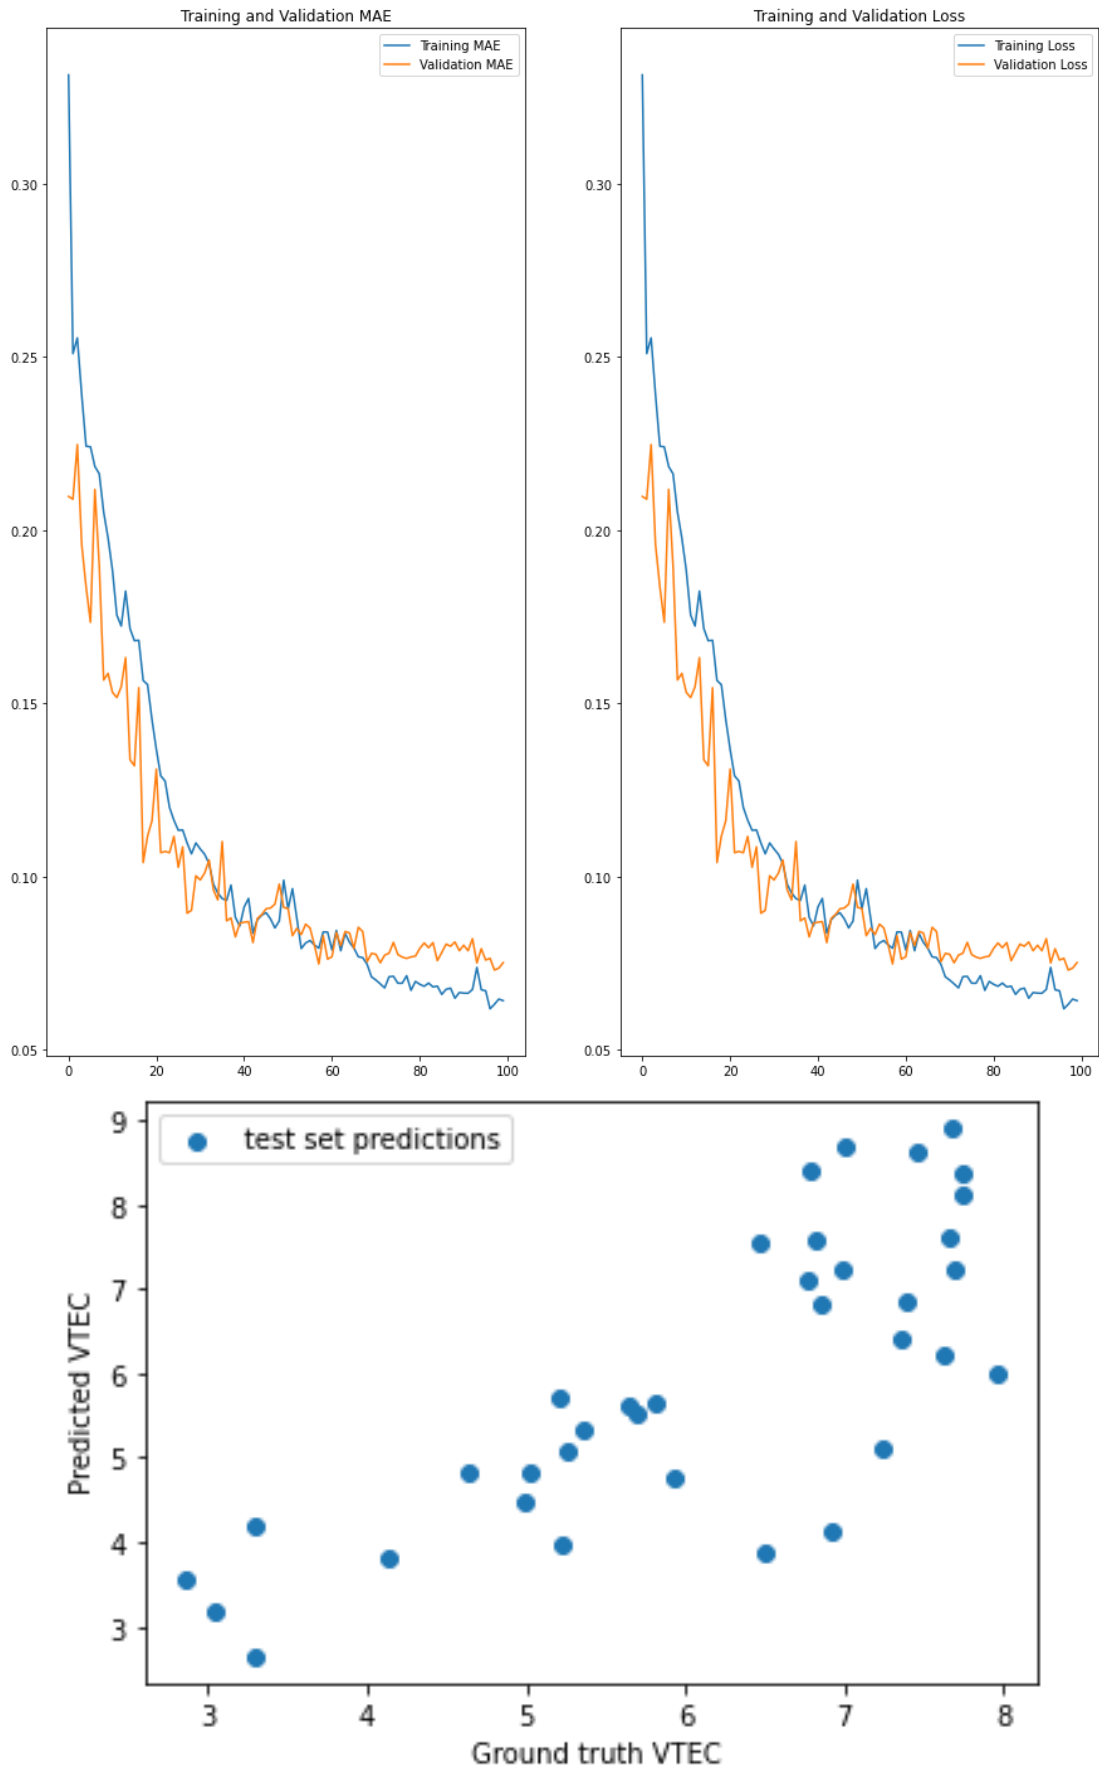





VTEC ΙΑΝΟΥΑΡΙΟΥ

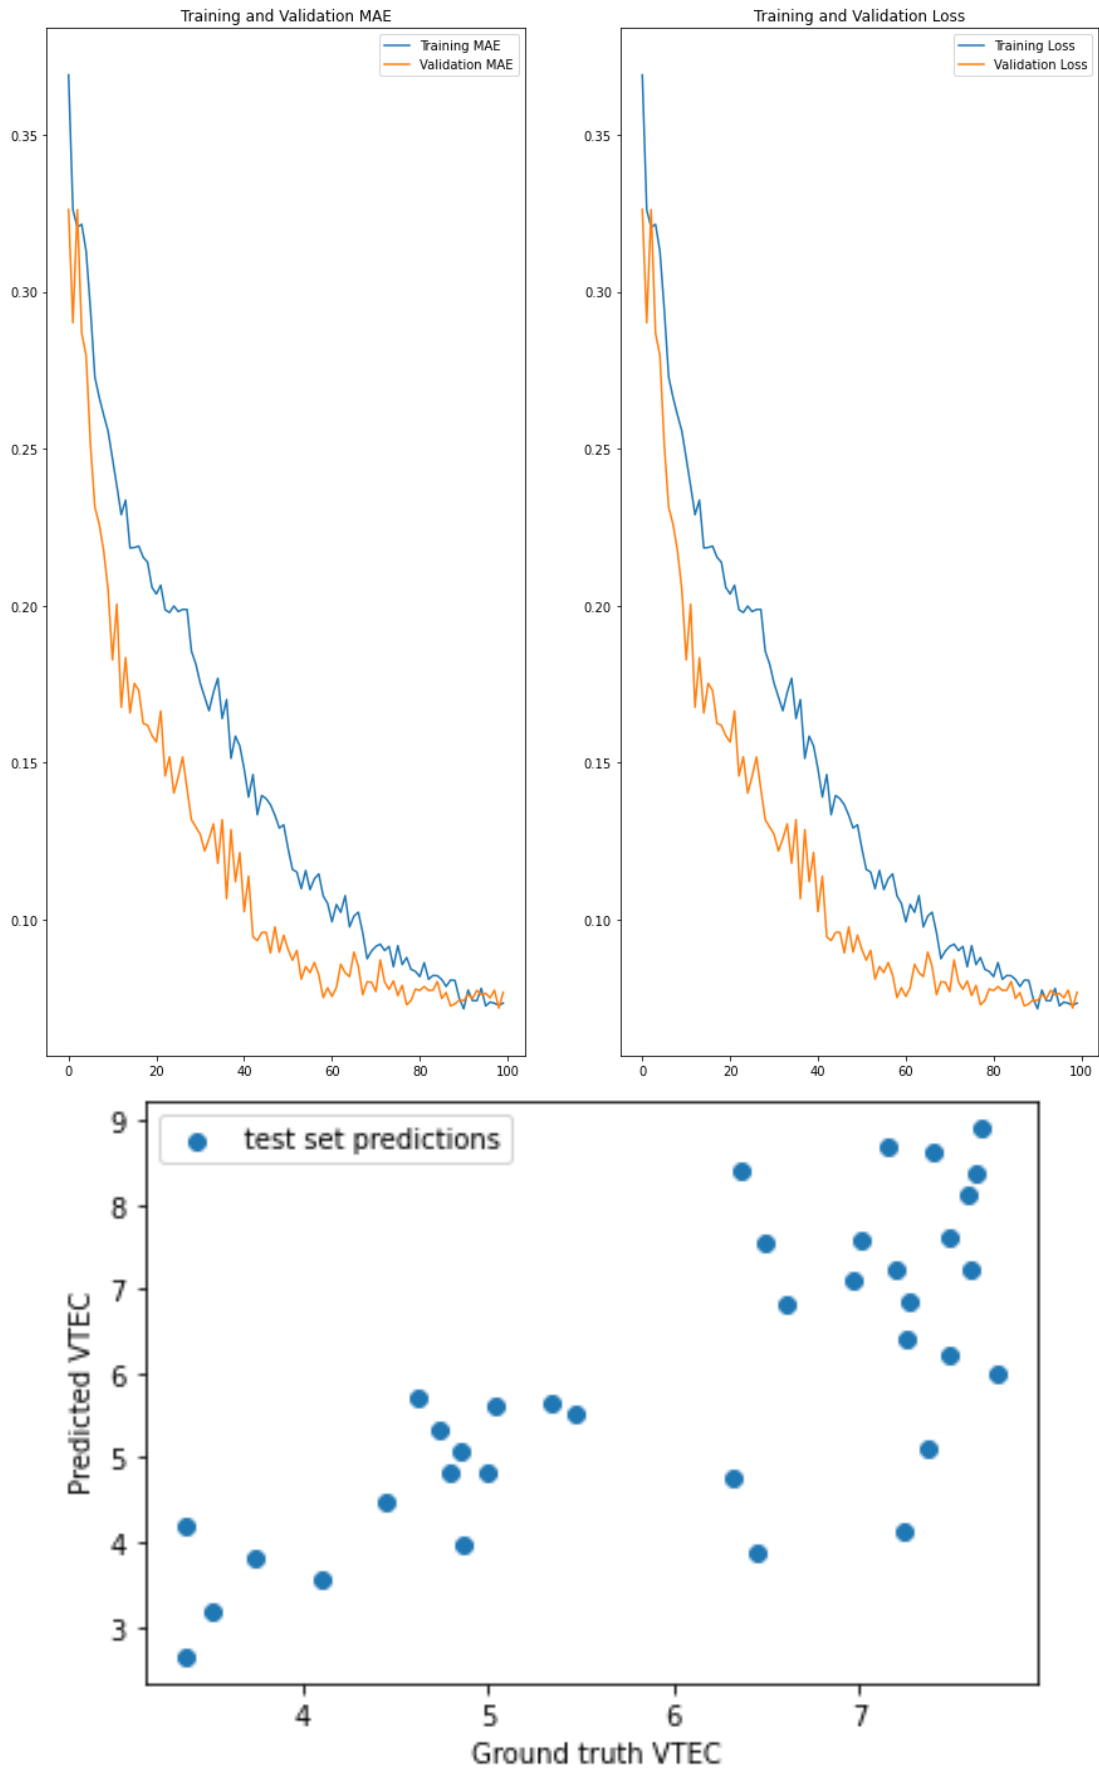




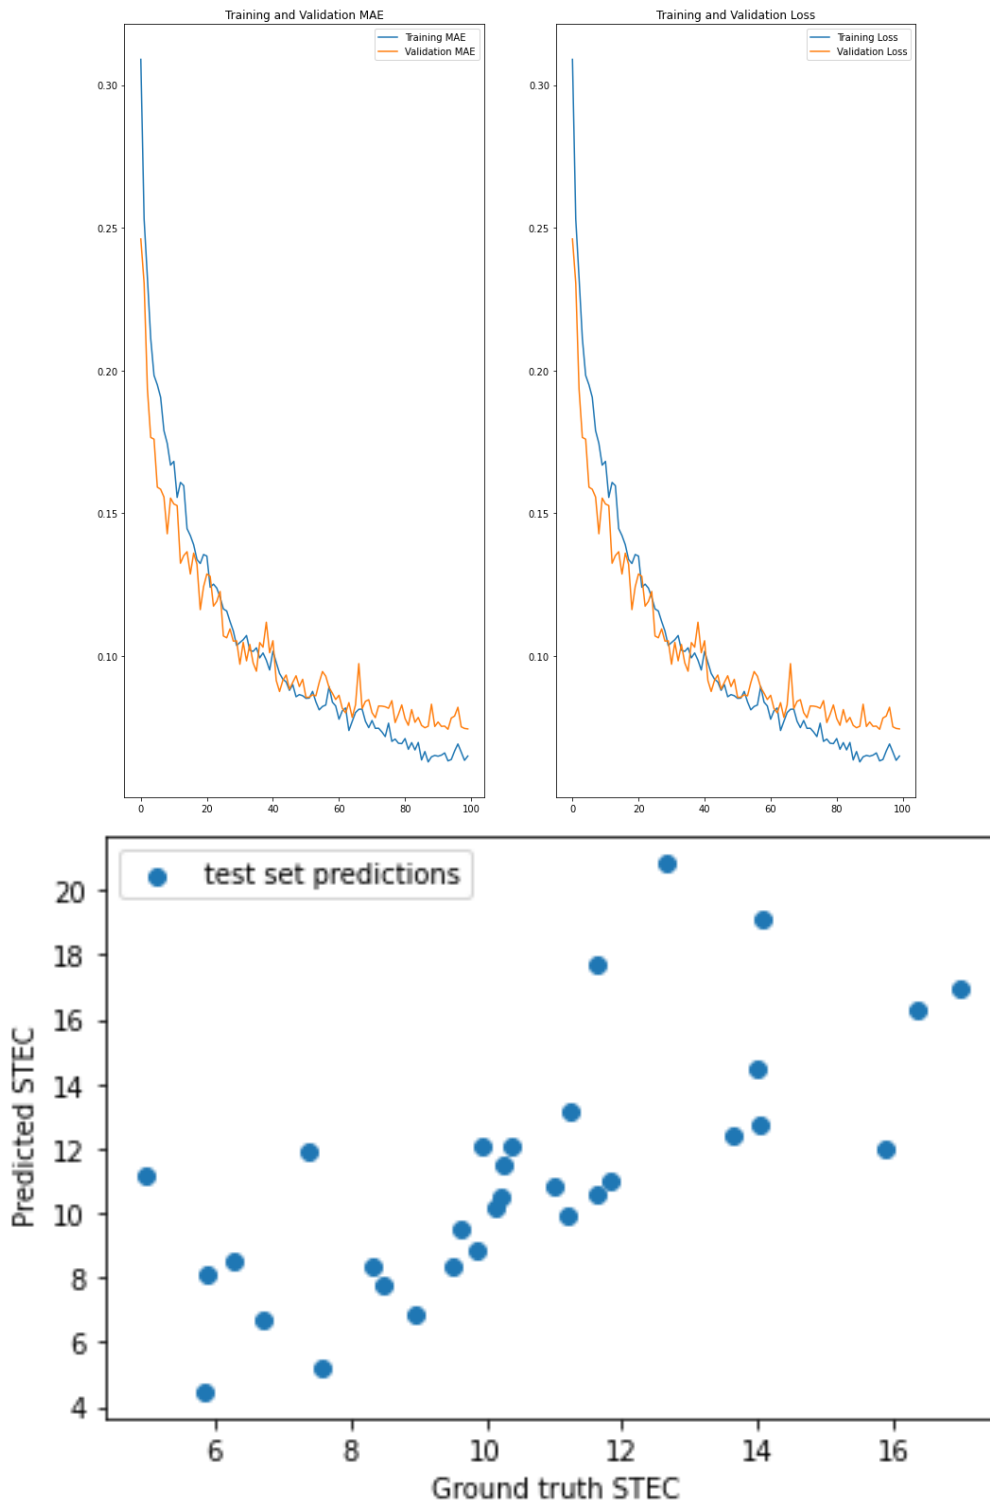







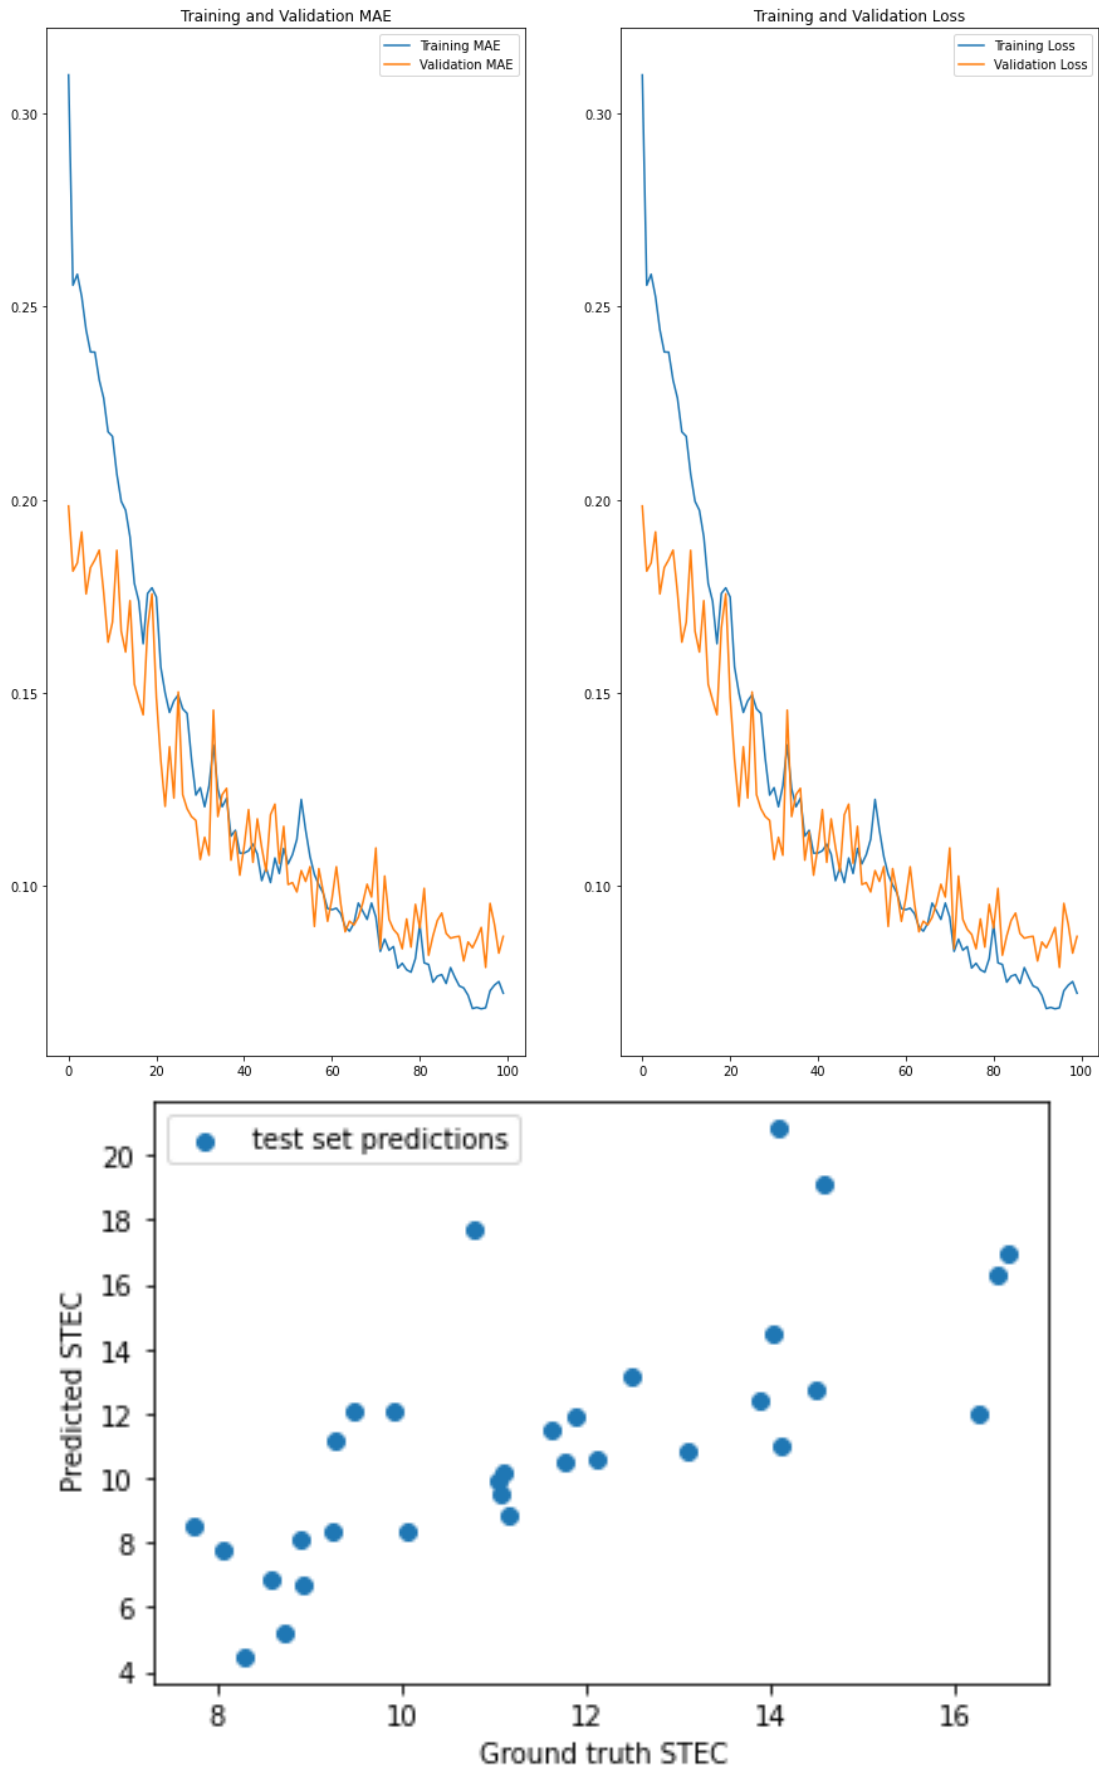


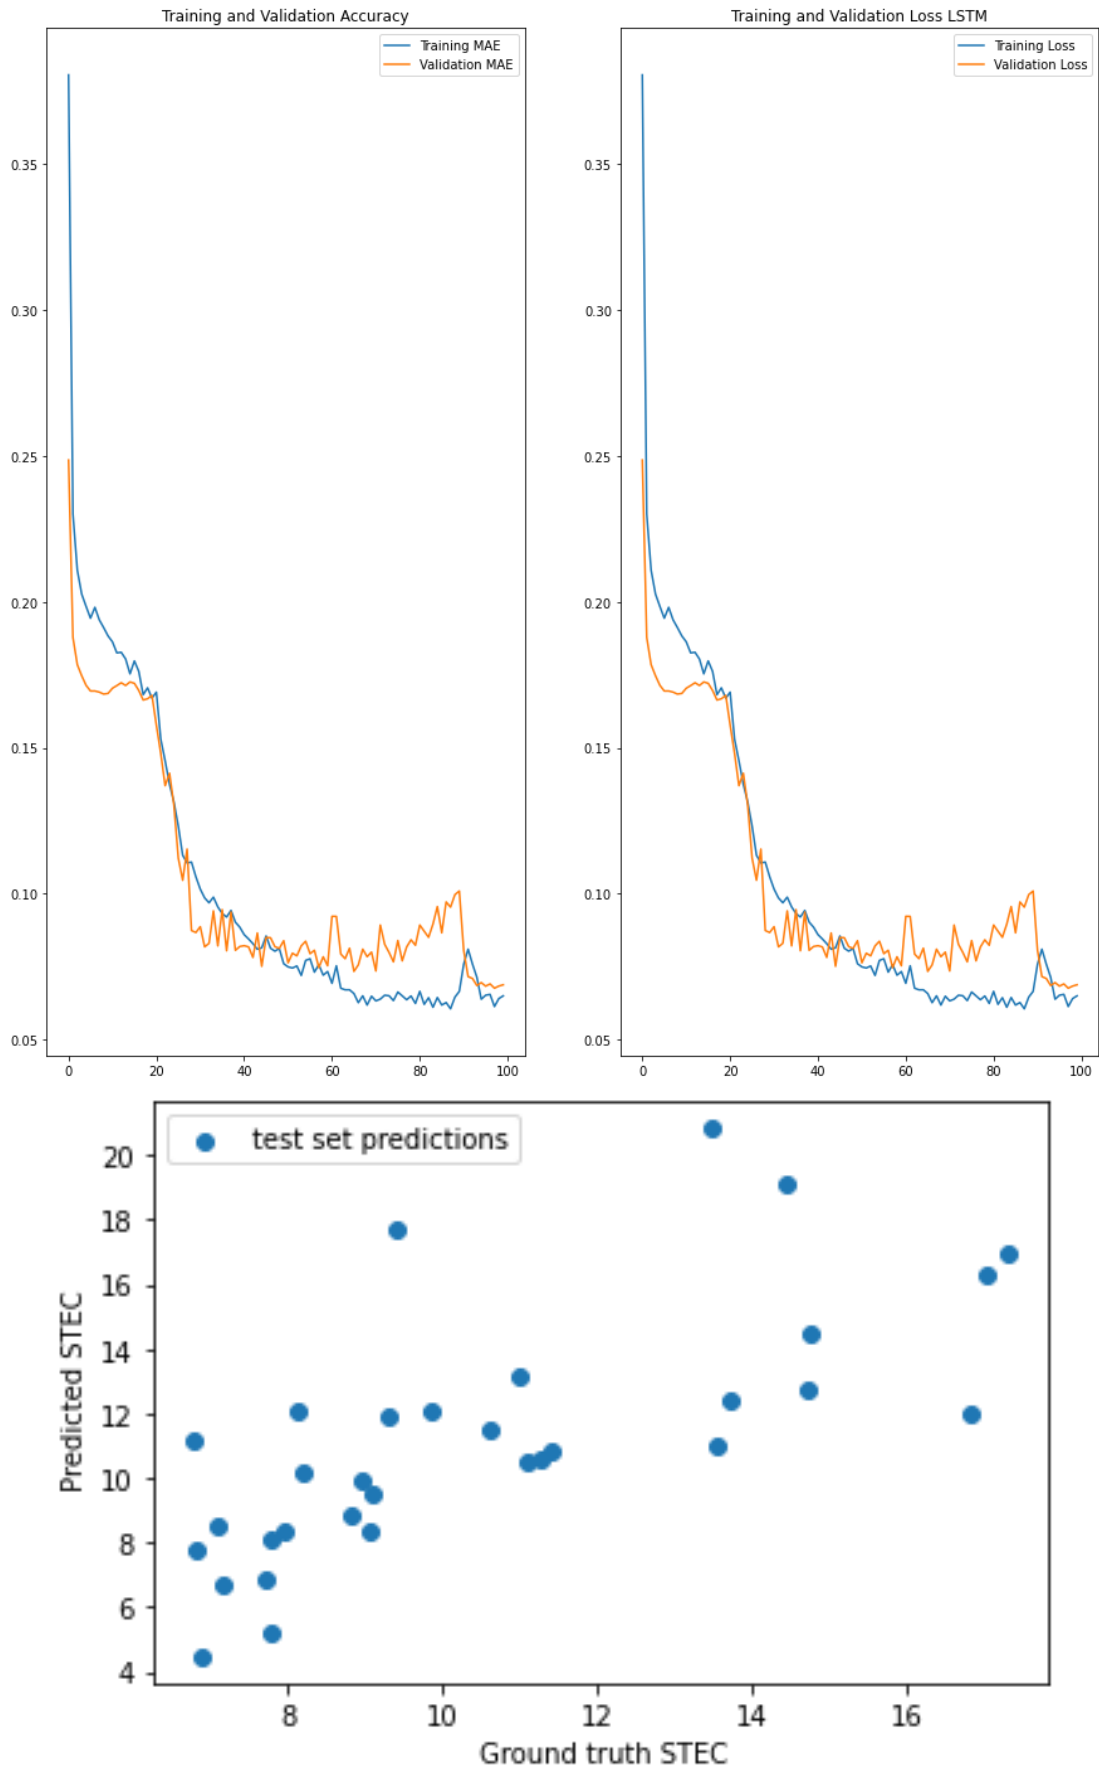





STEC ΦΕΒΡΟΥΑΡΙΟΥ

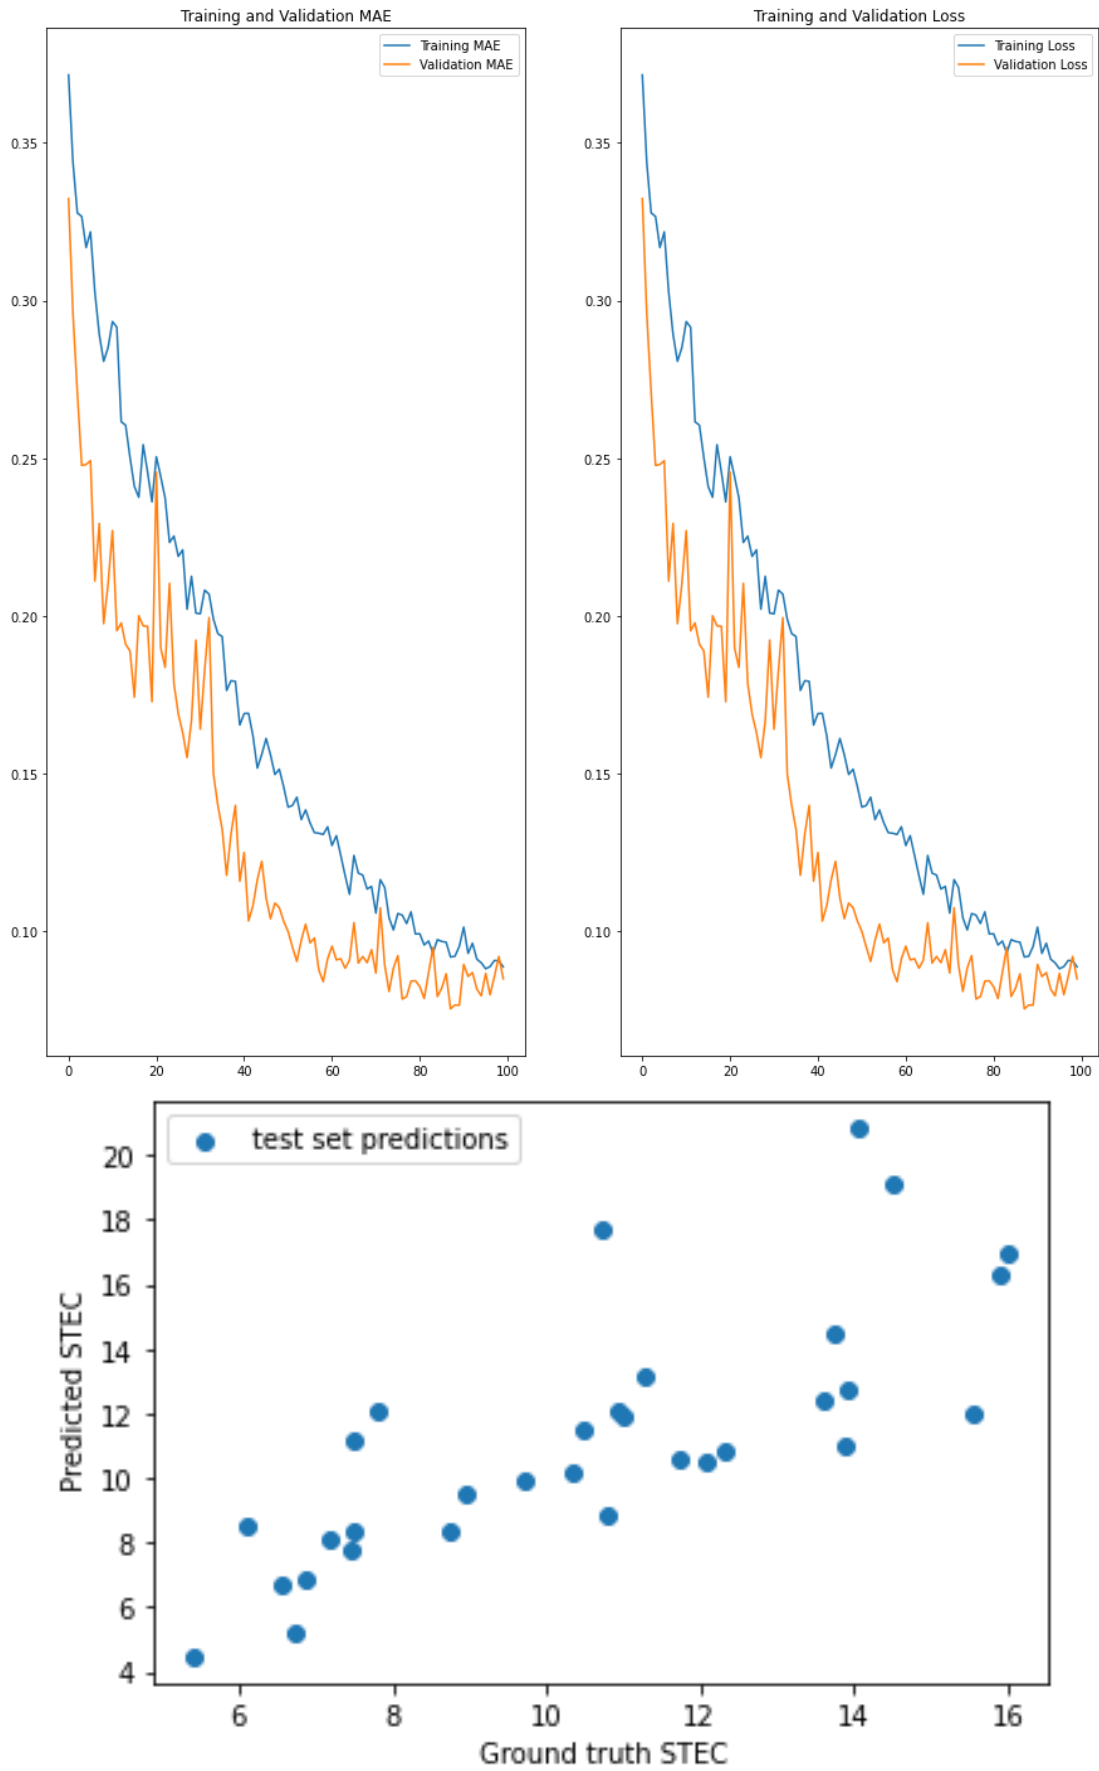




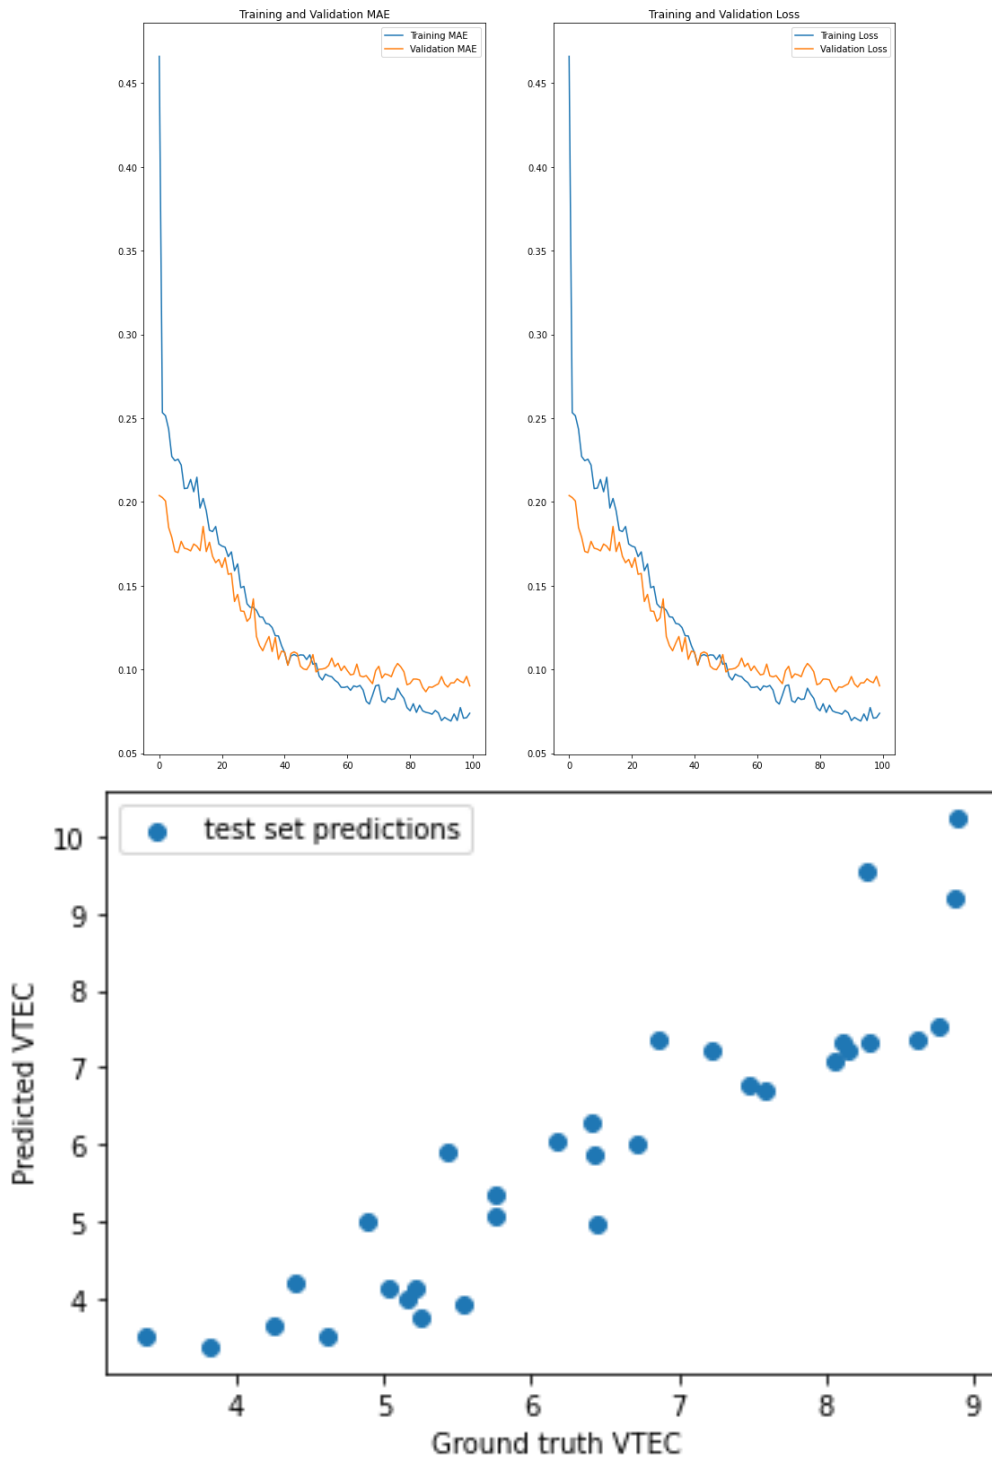


















ΥΤΕC ΦΕΒΡΟΥΑΡΙΟΥ

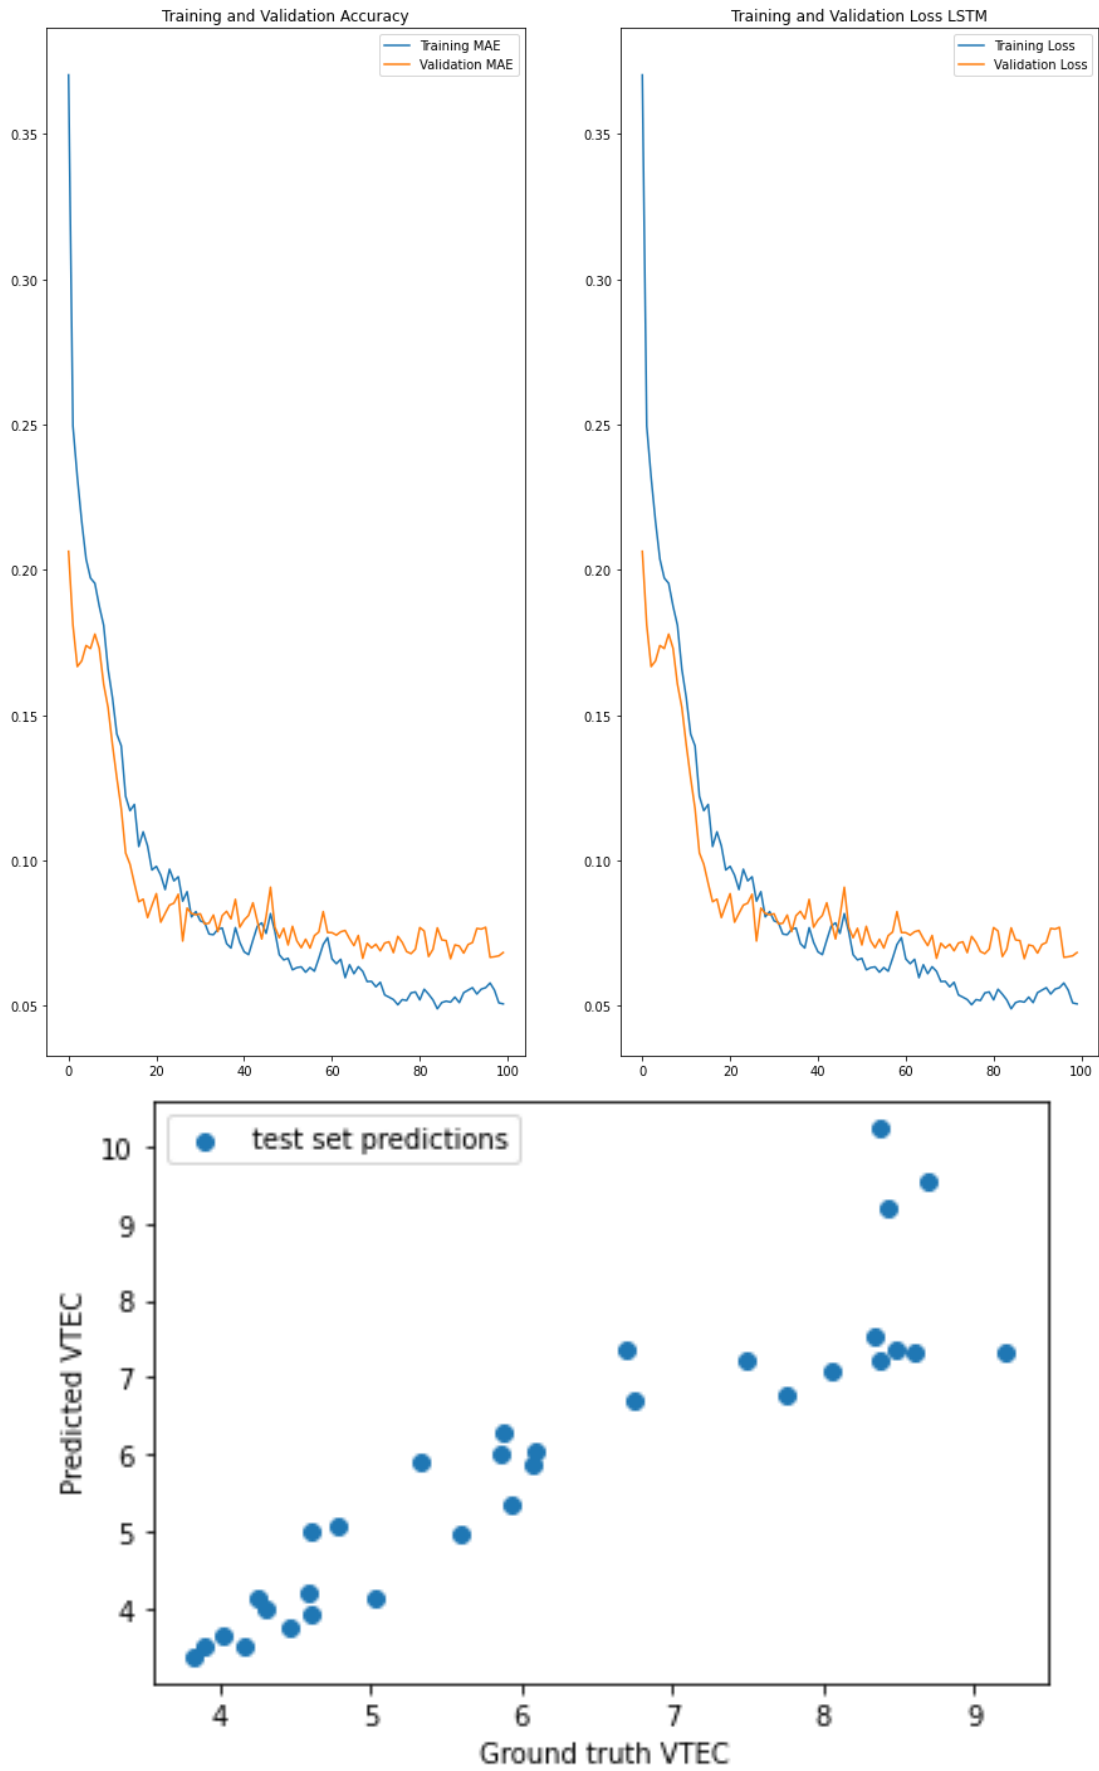




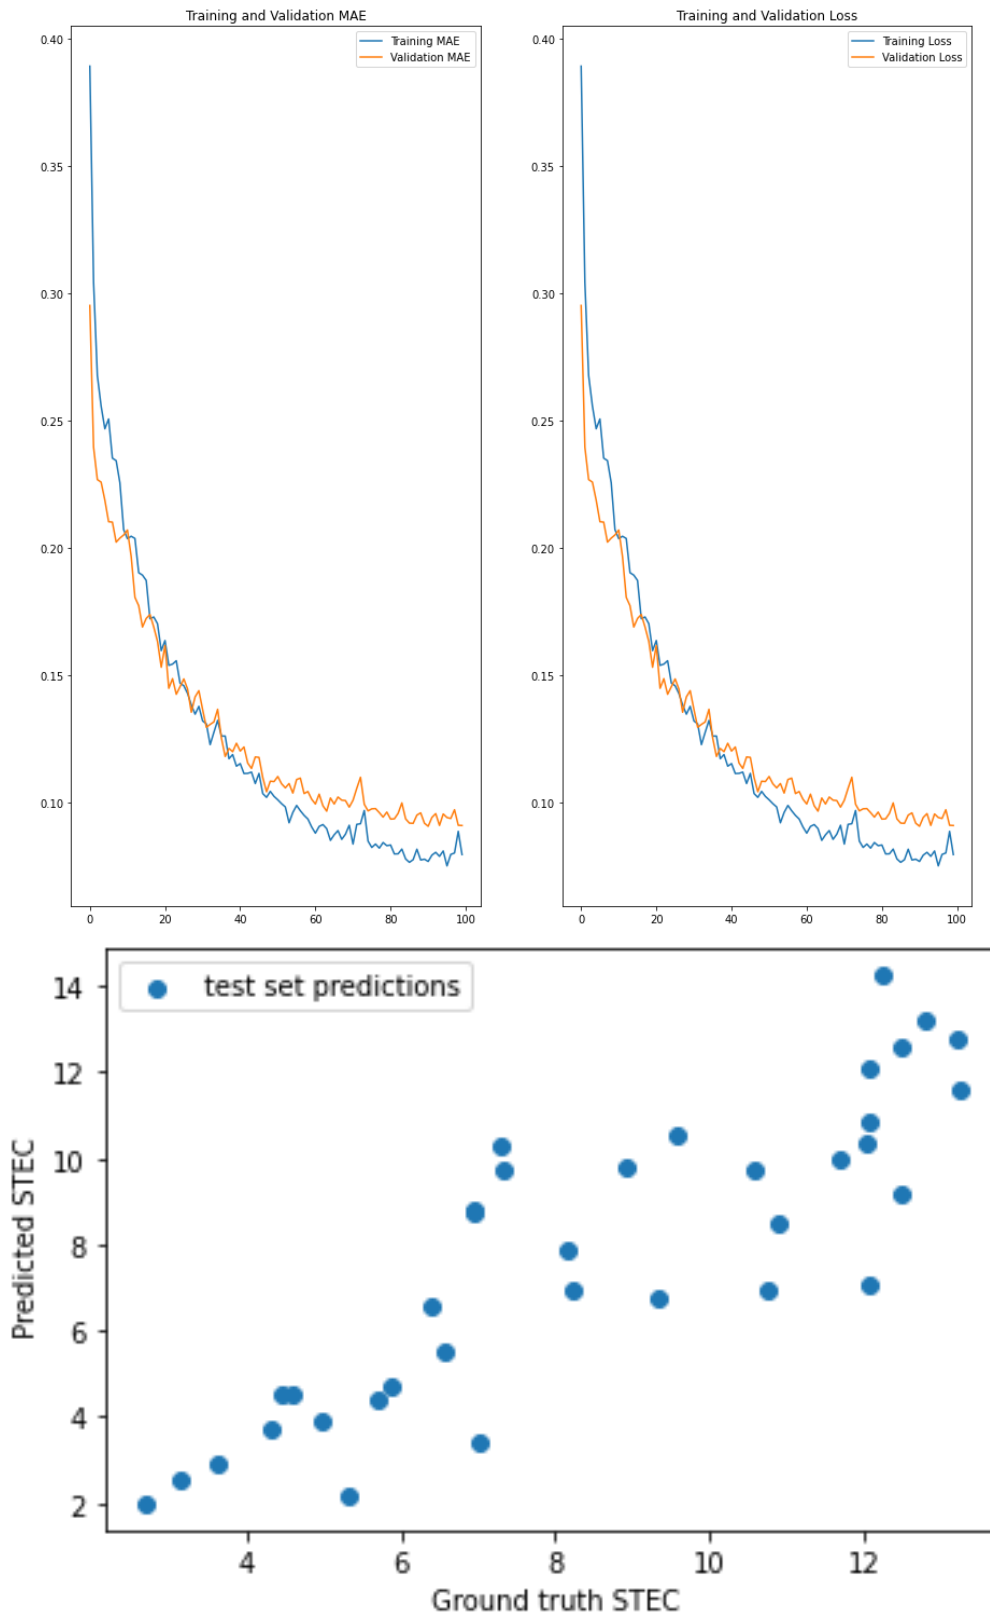


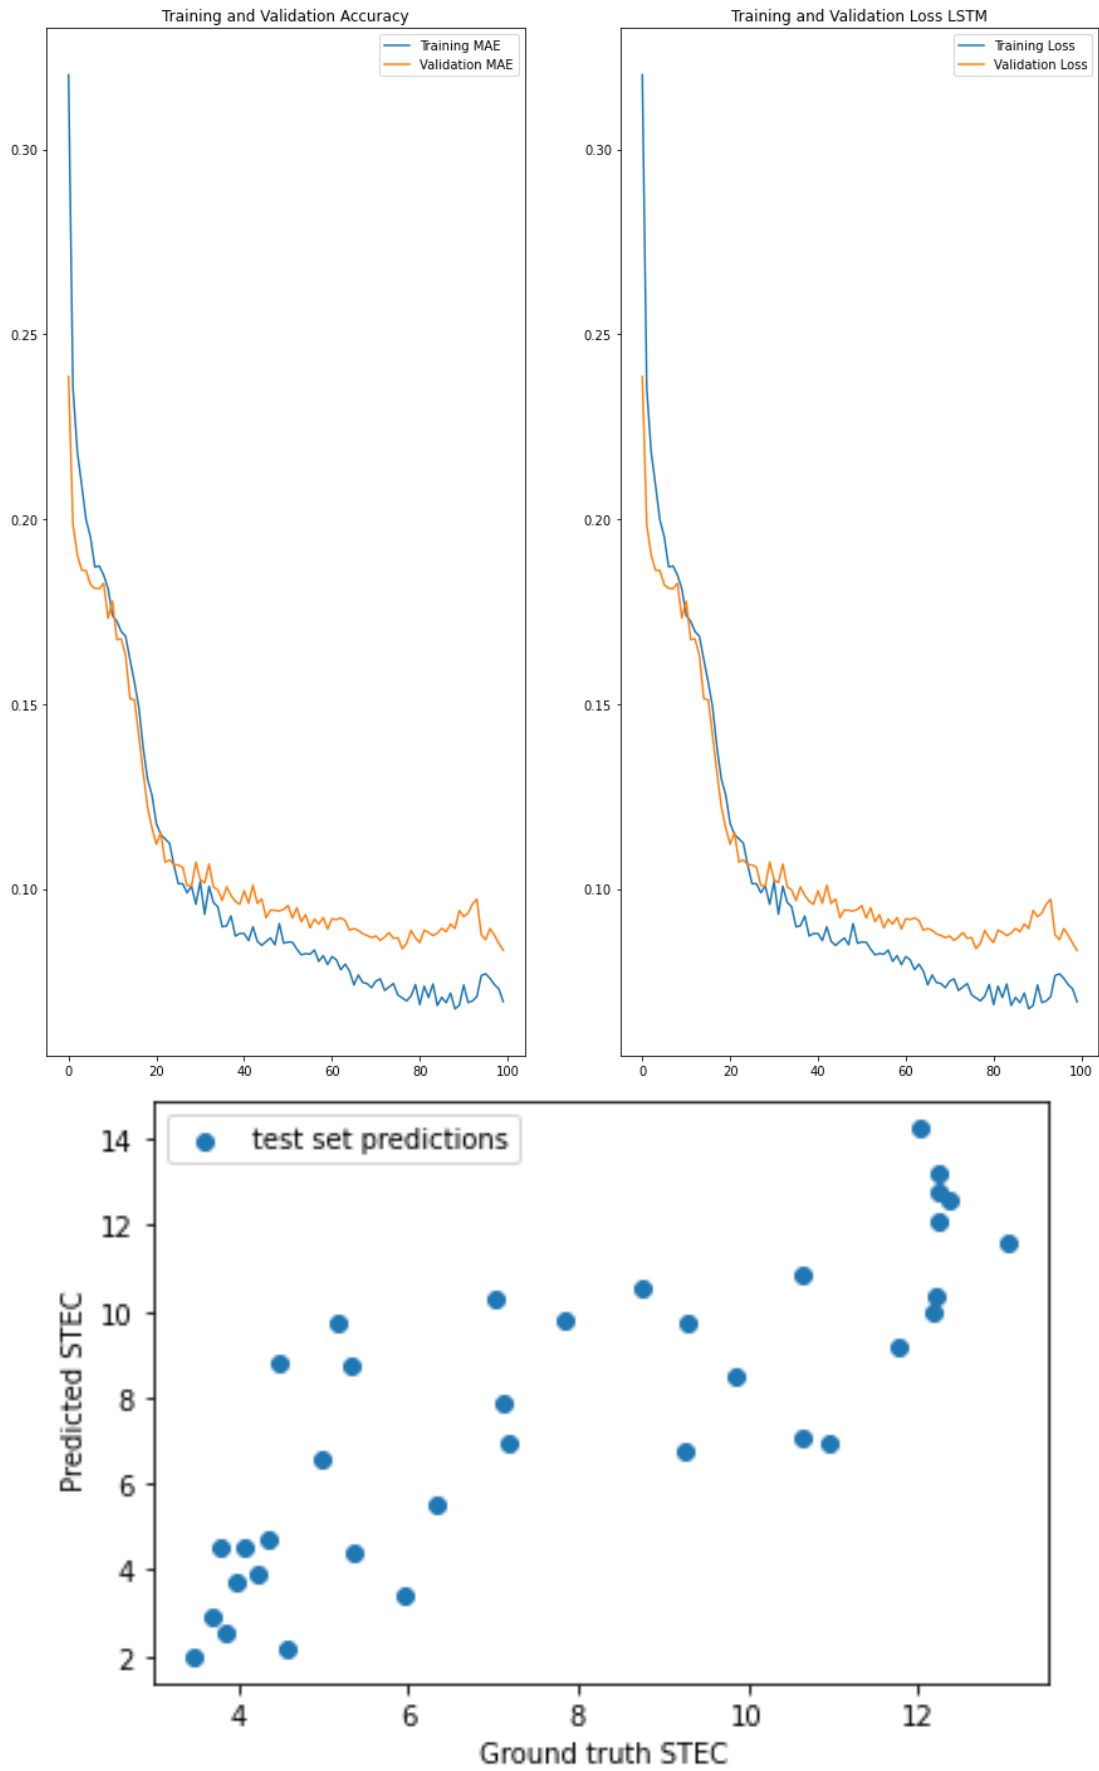







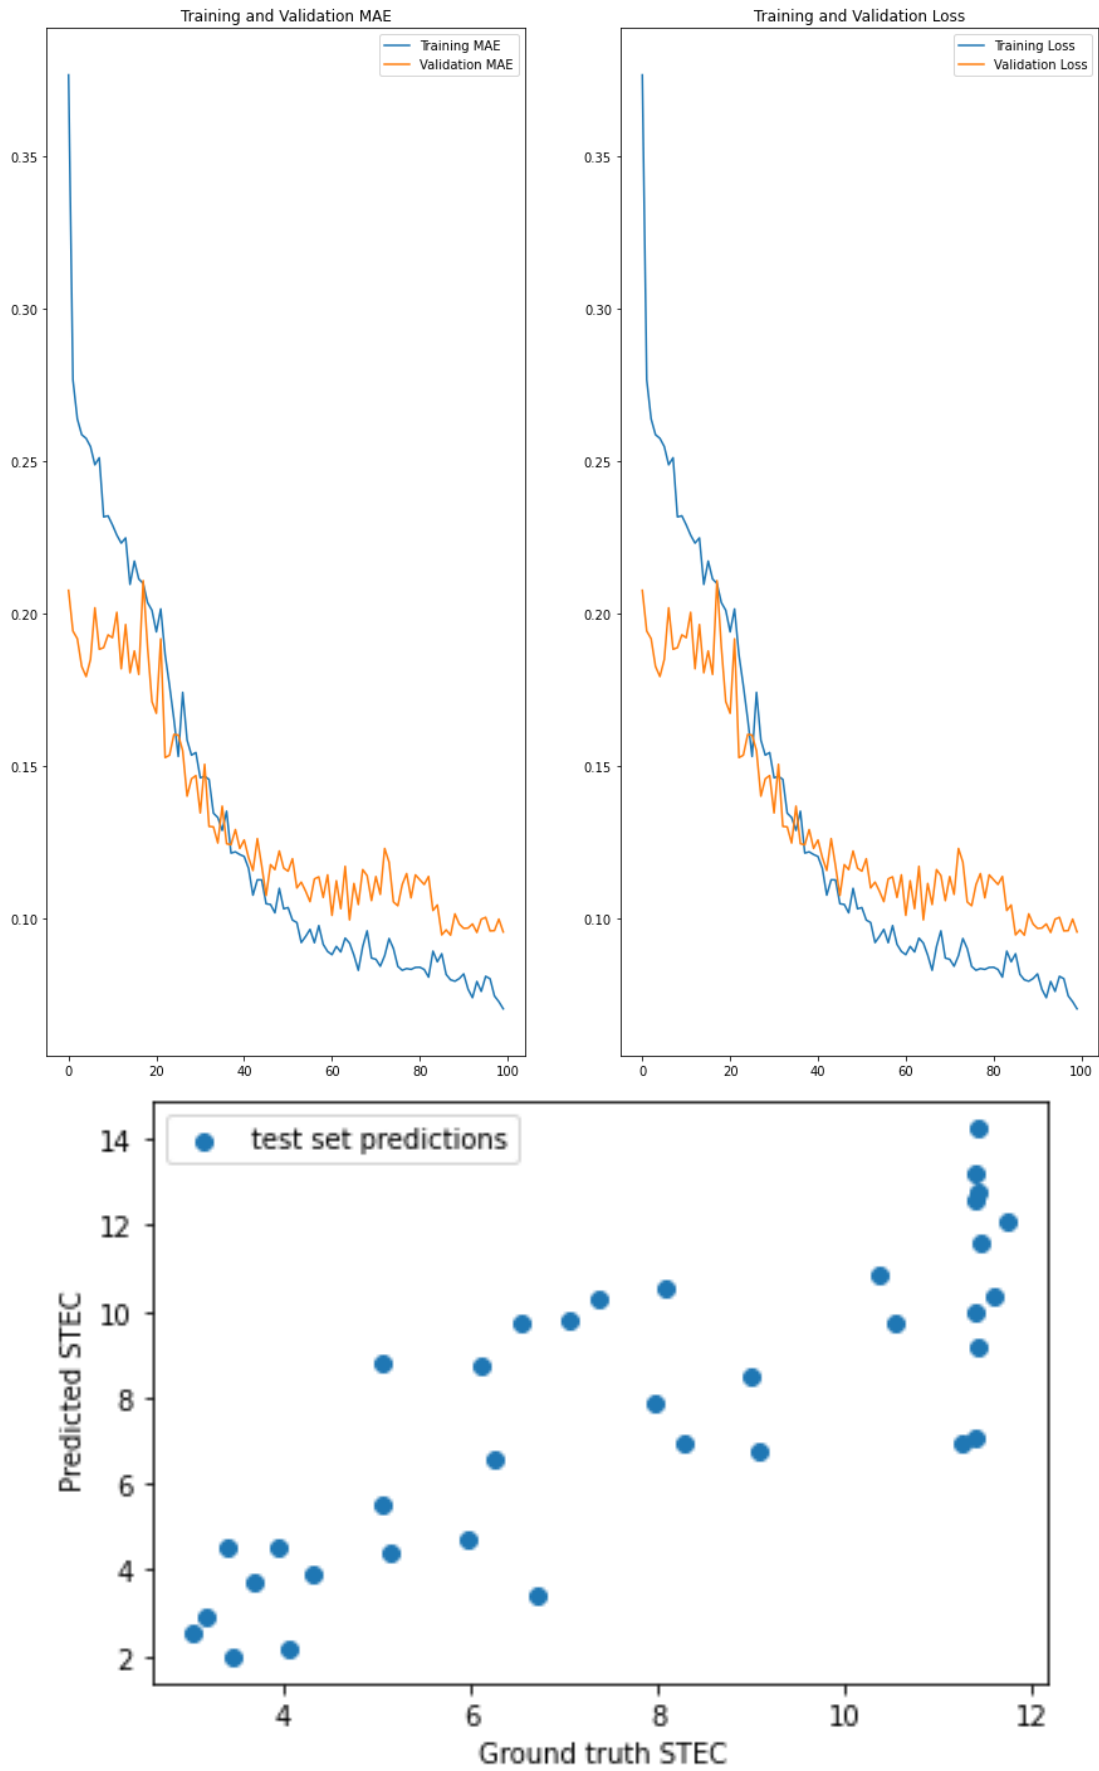



STEC ΜΑΡΤΙΟΥ








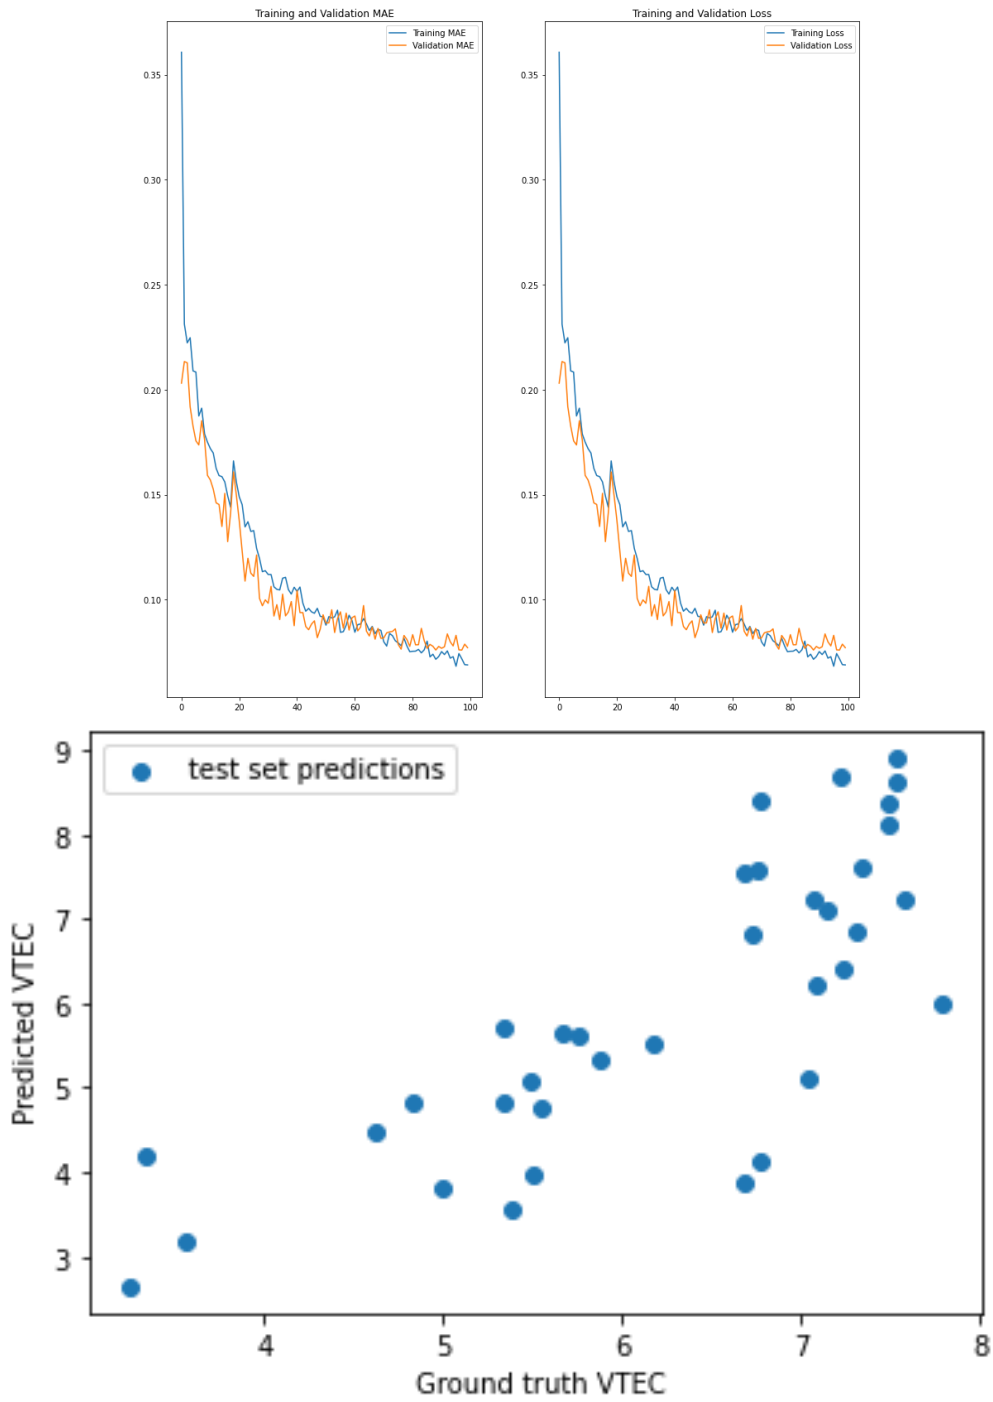












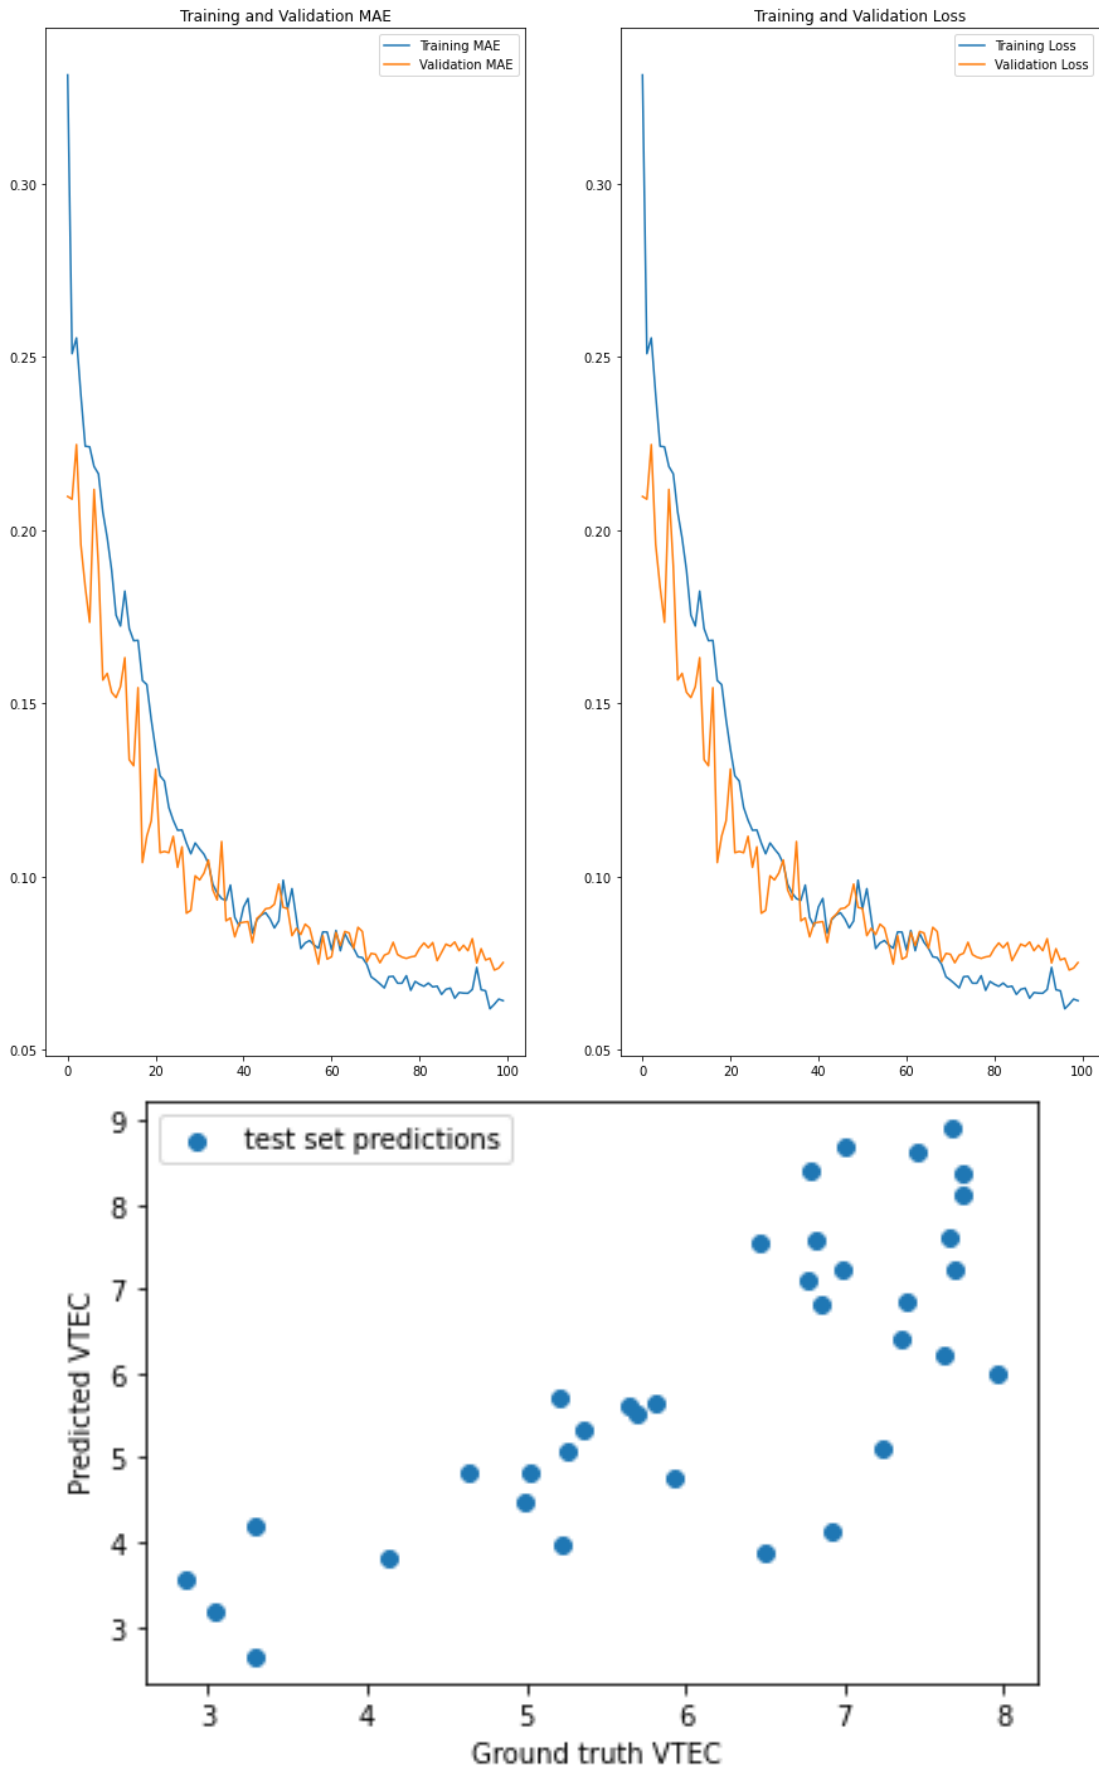





VTEC ΜΑΡΤΙΟΥ

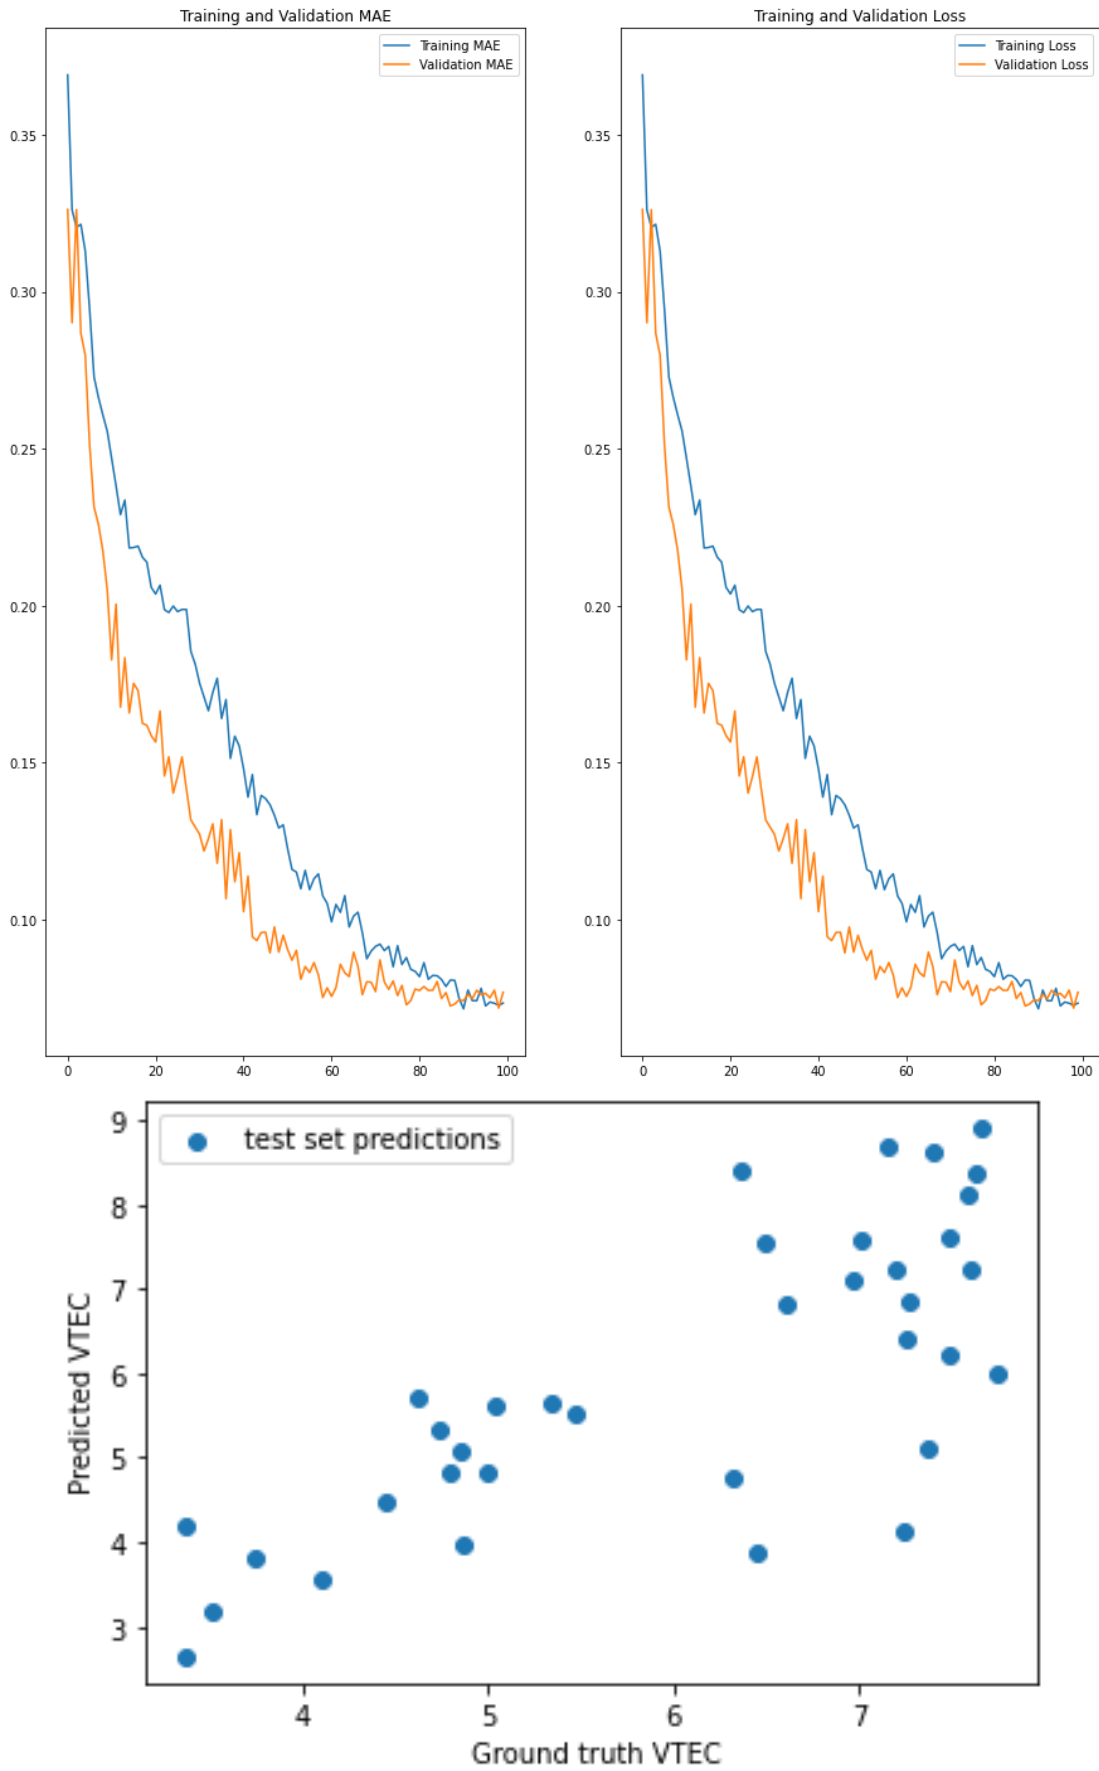






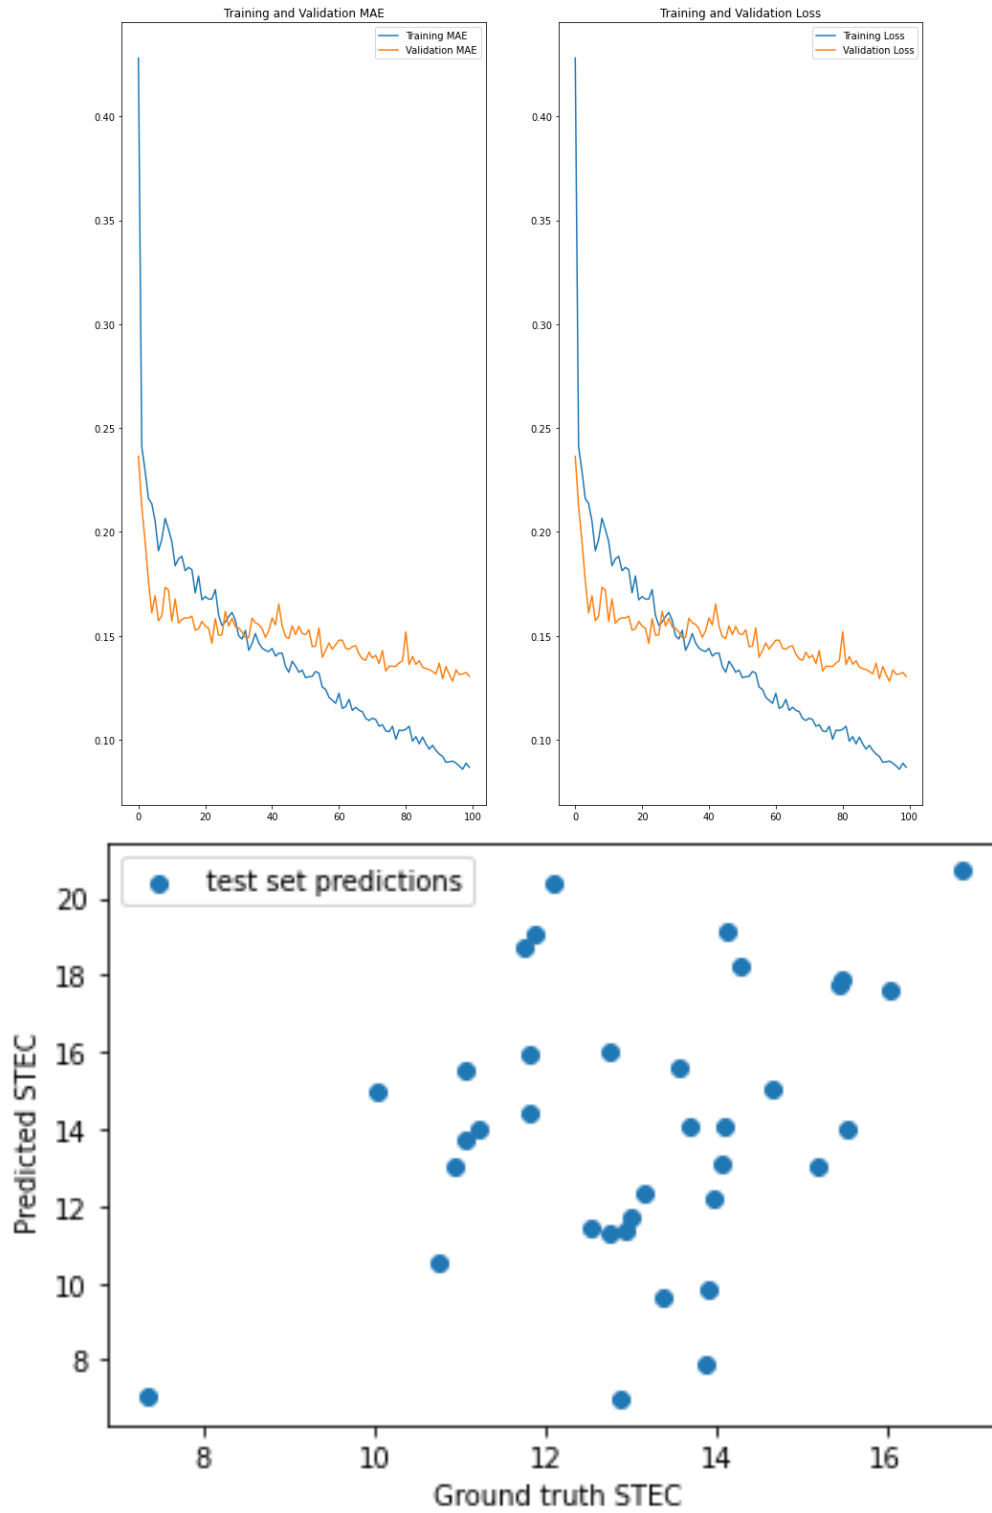


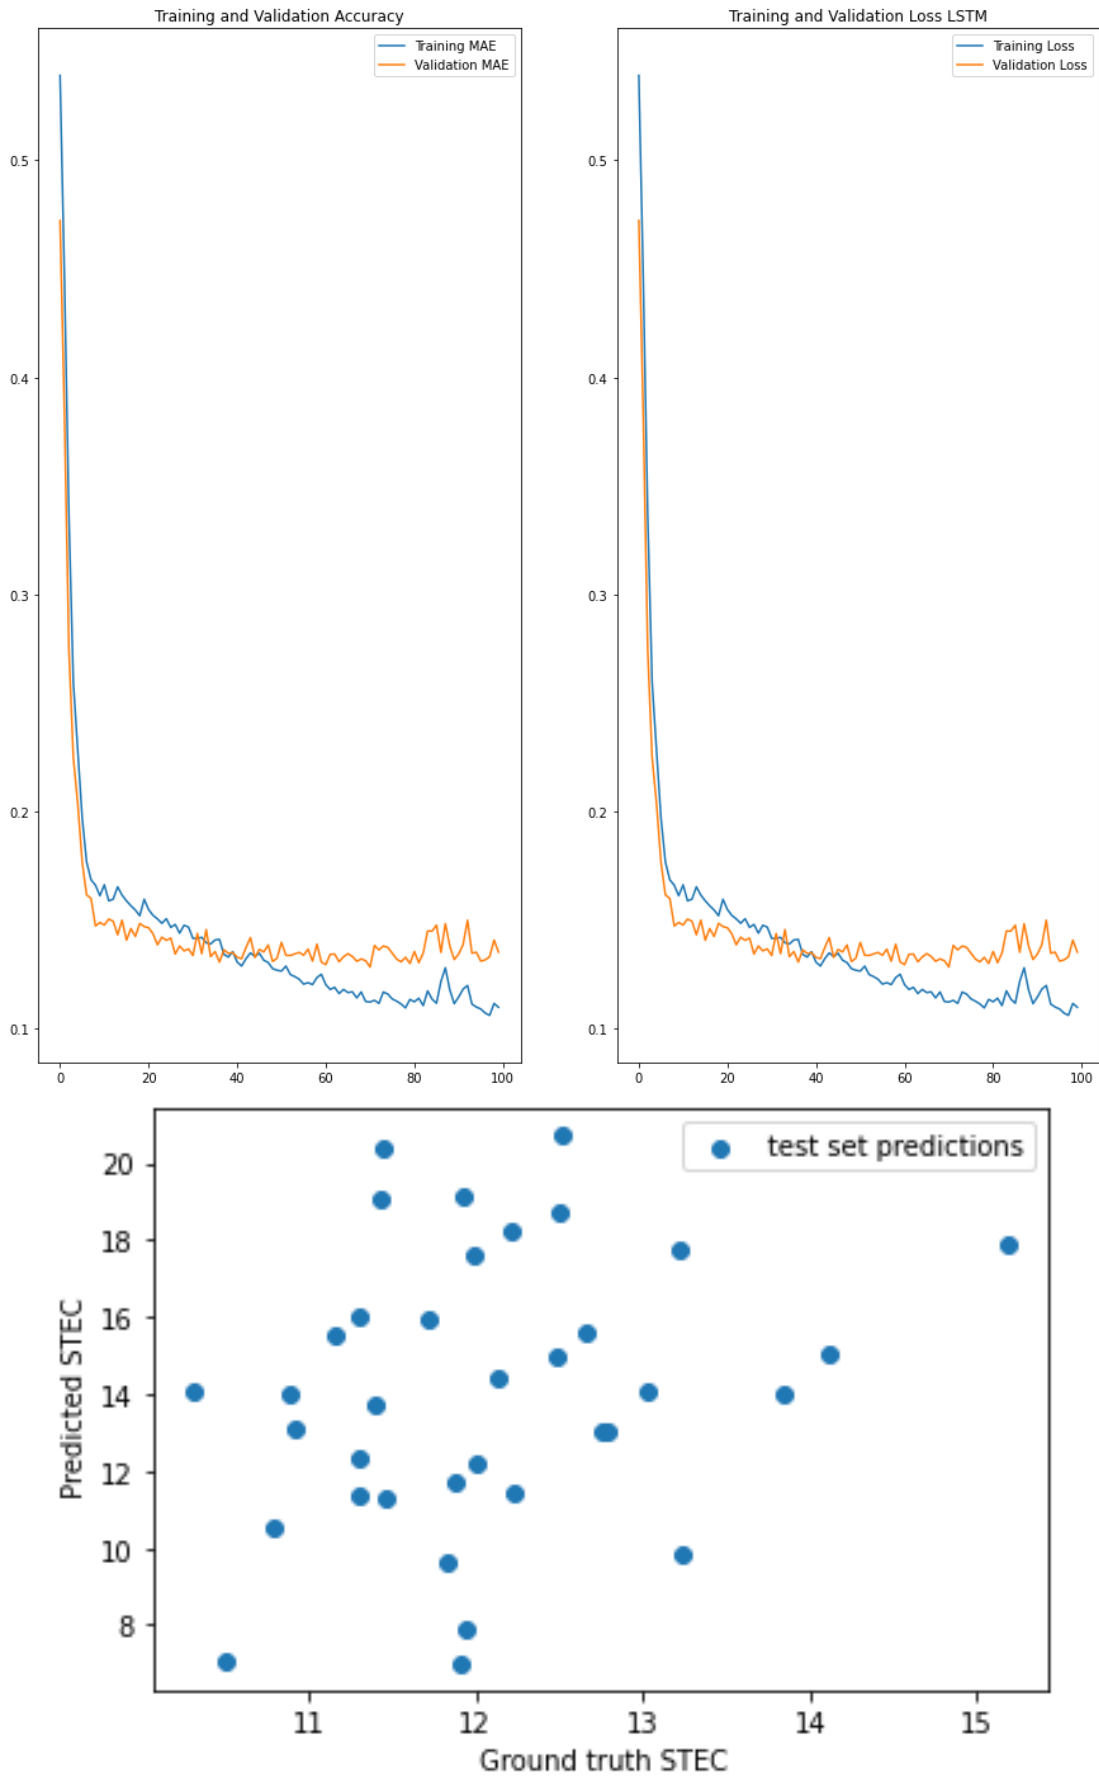


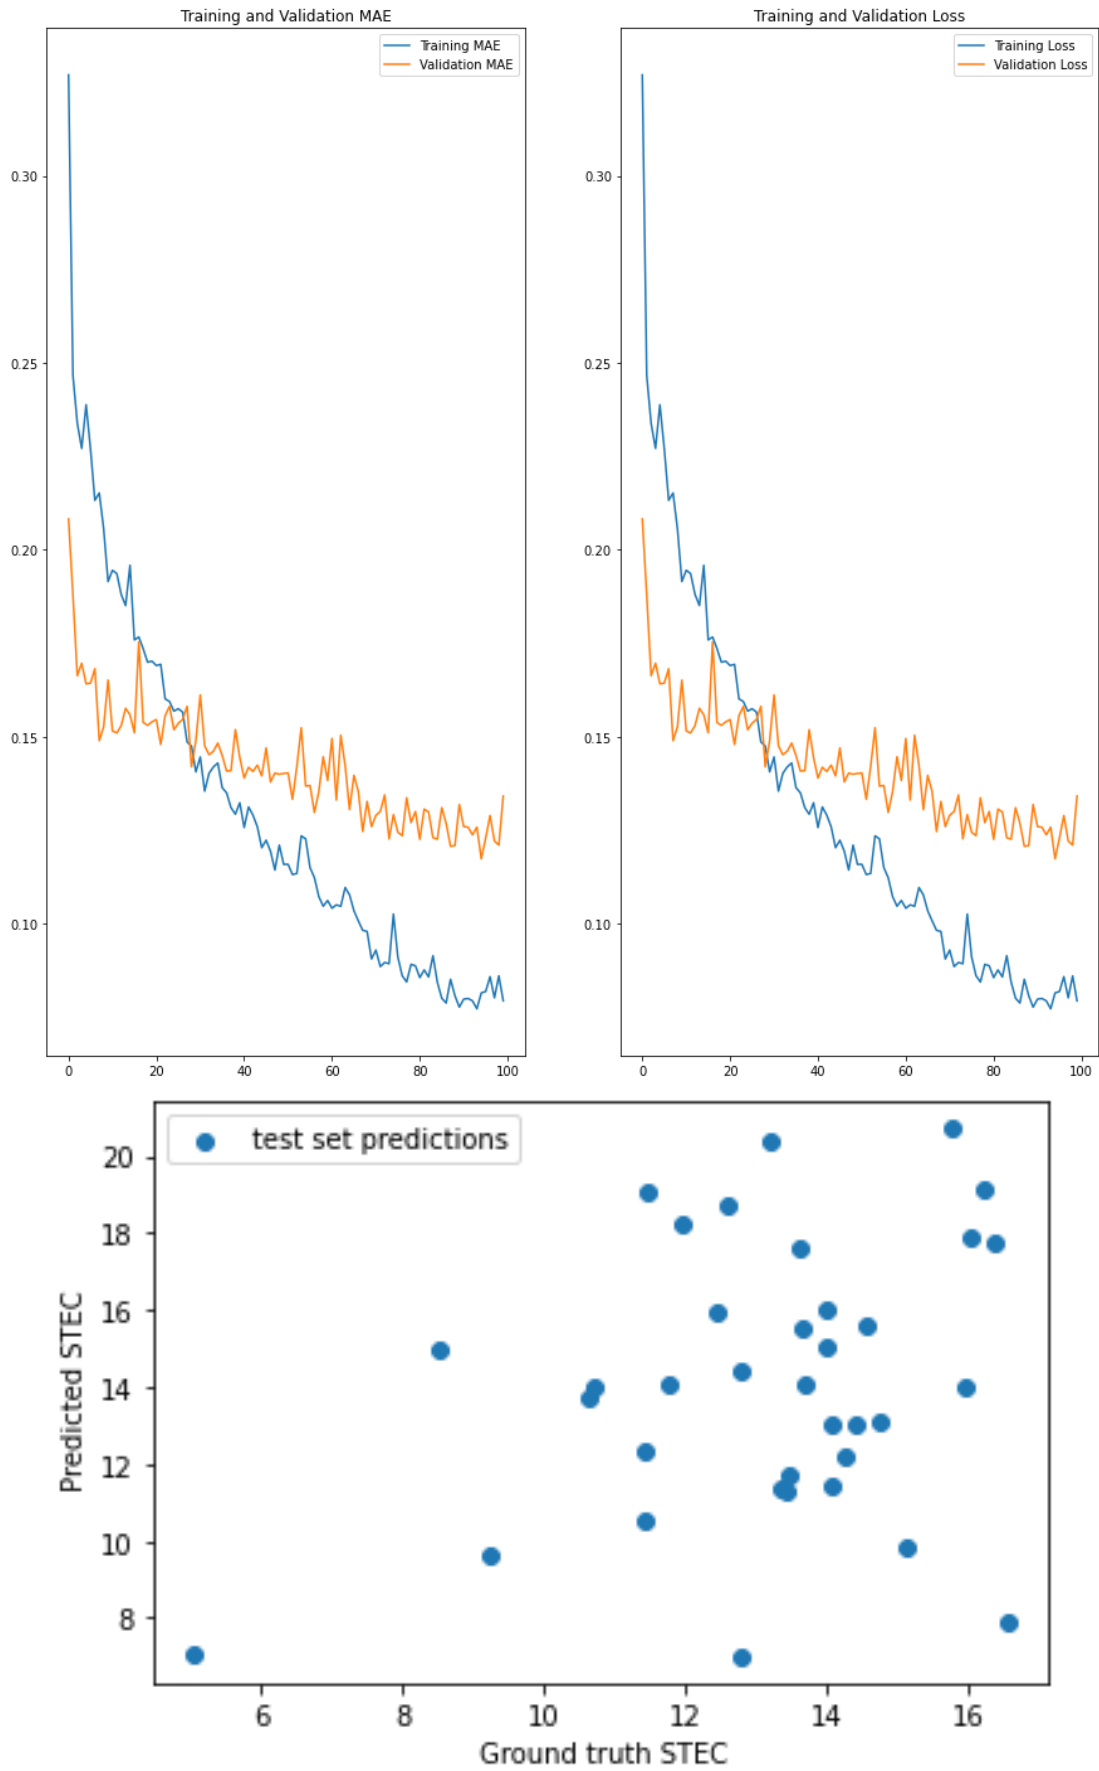


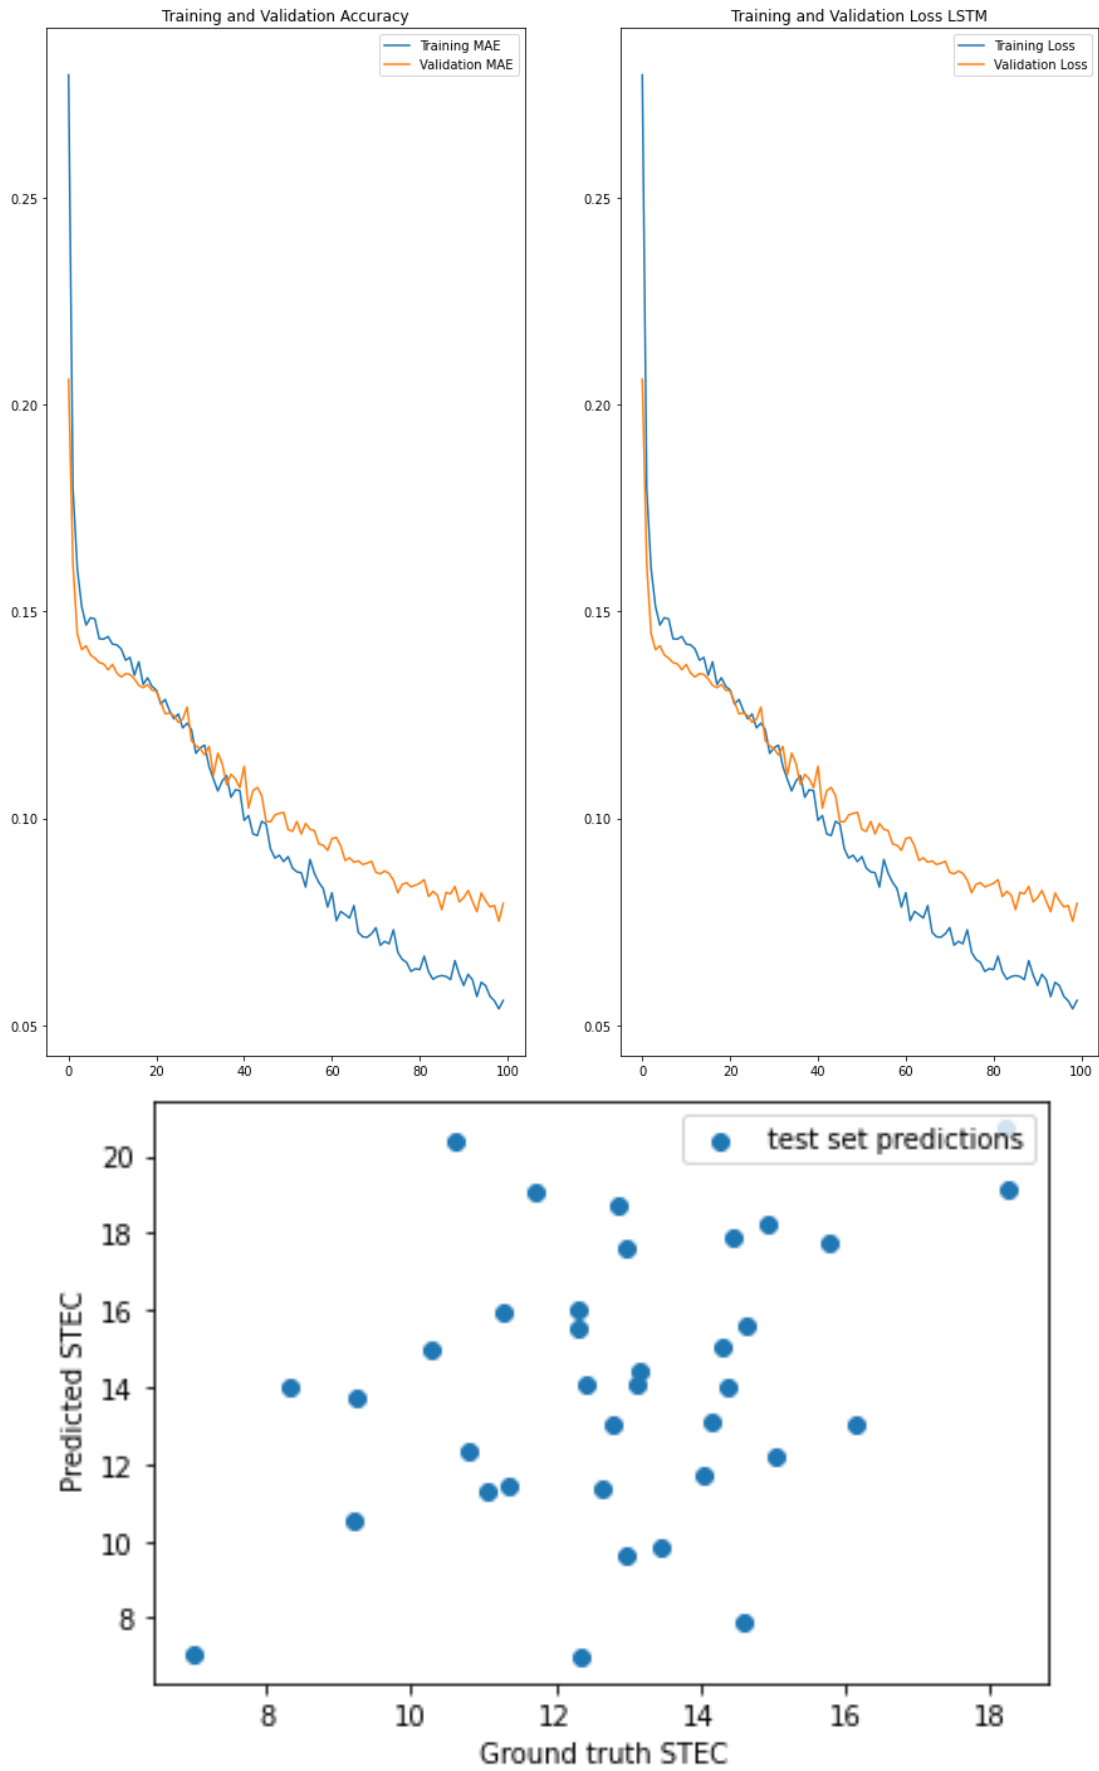
Αποτελέσματα Σεναρίου Νο 7 για τους μήνες Φεβρουάριο και Μάρτιο 2018


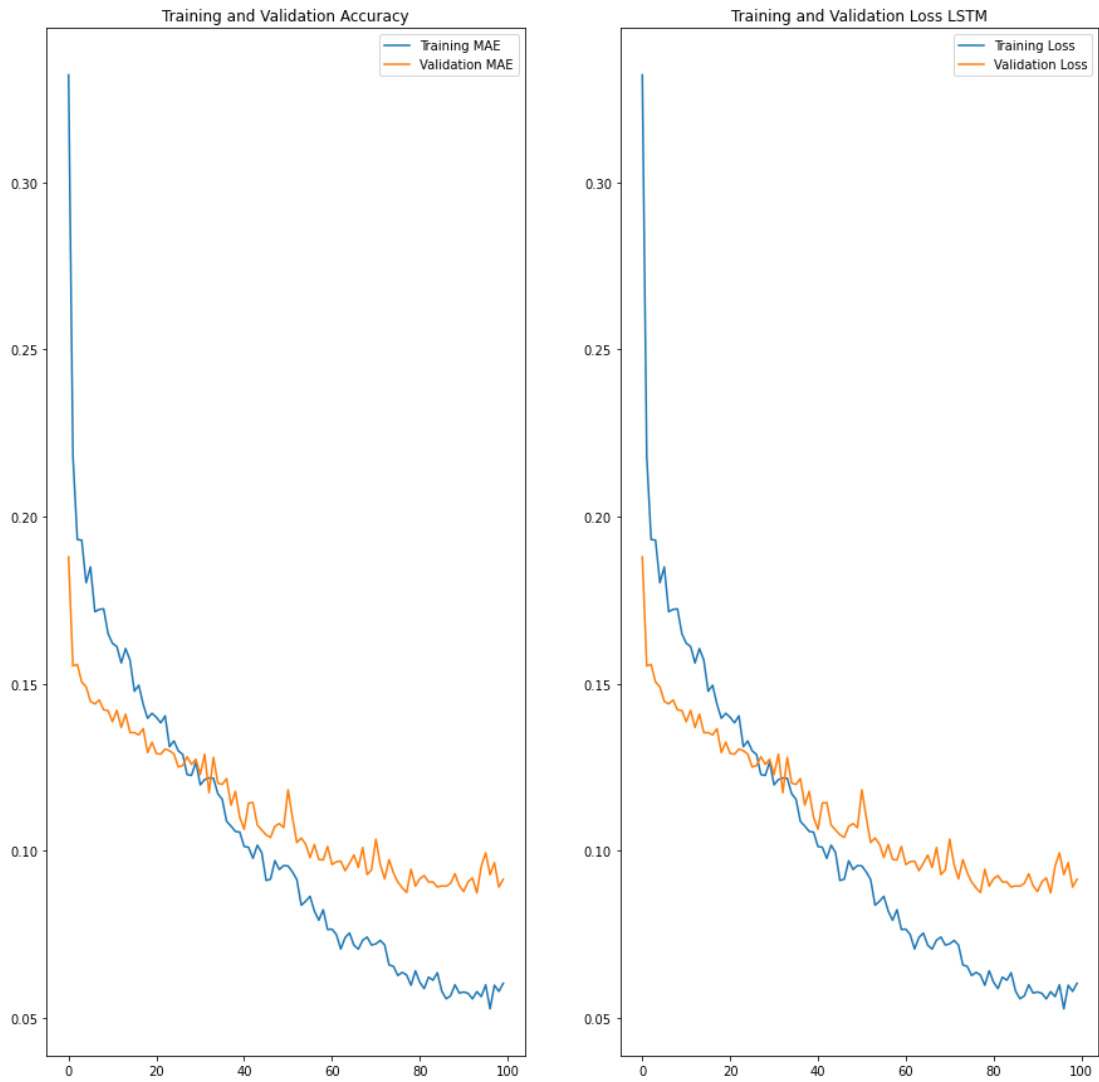
STEC ΙΑΝΟΥΑΡΙΟΥ








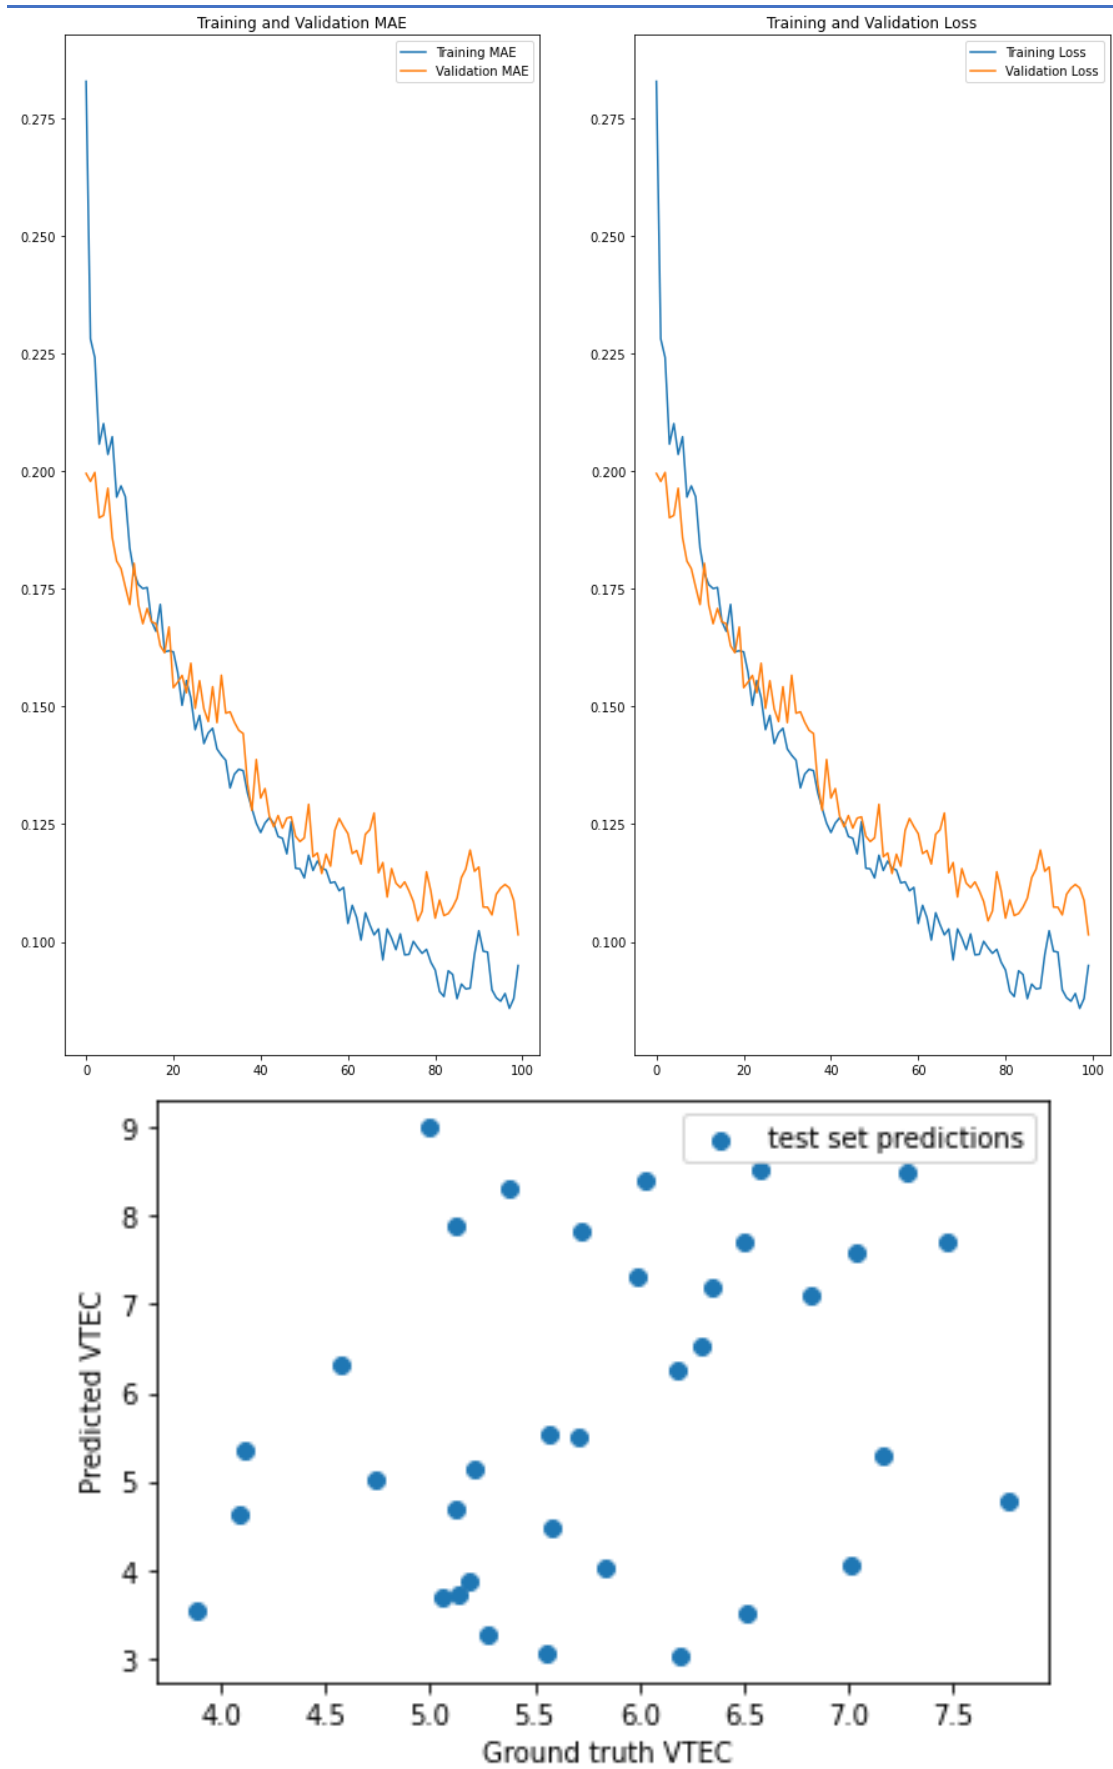


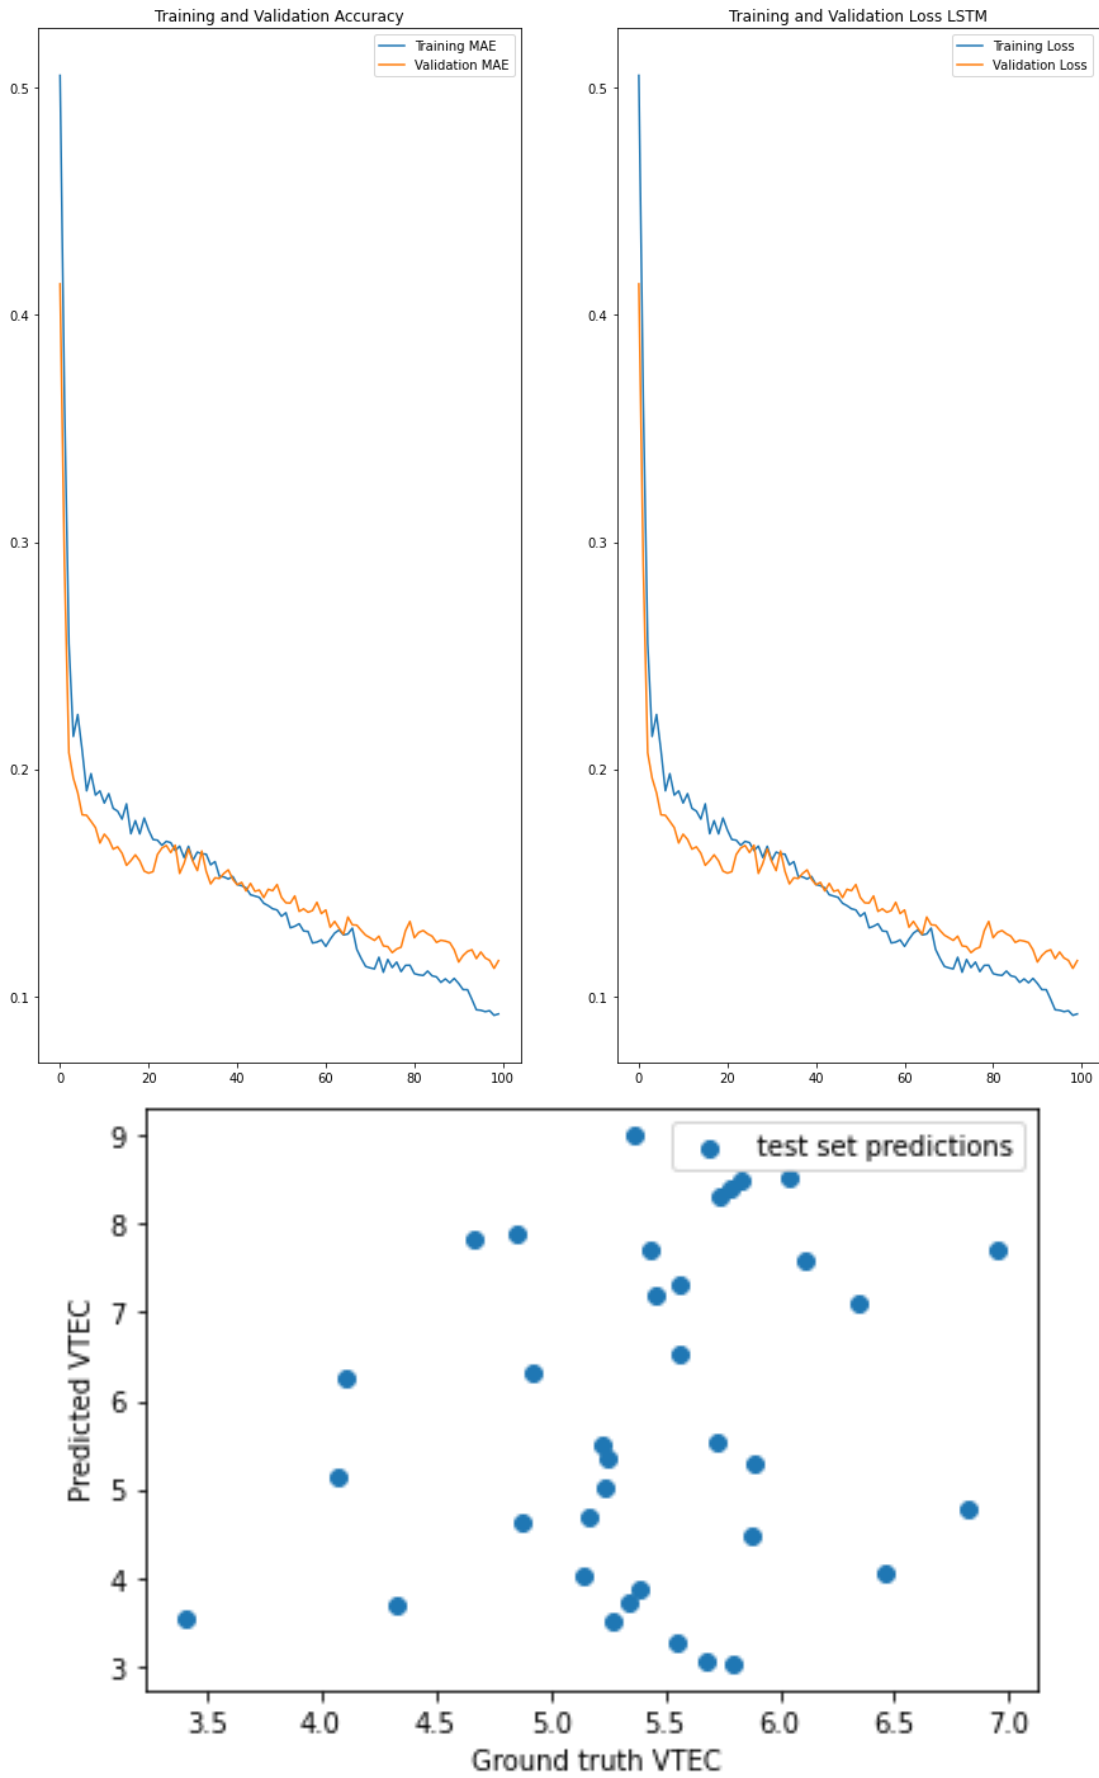








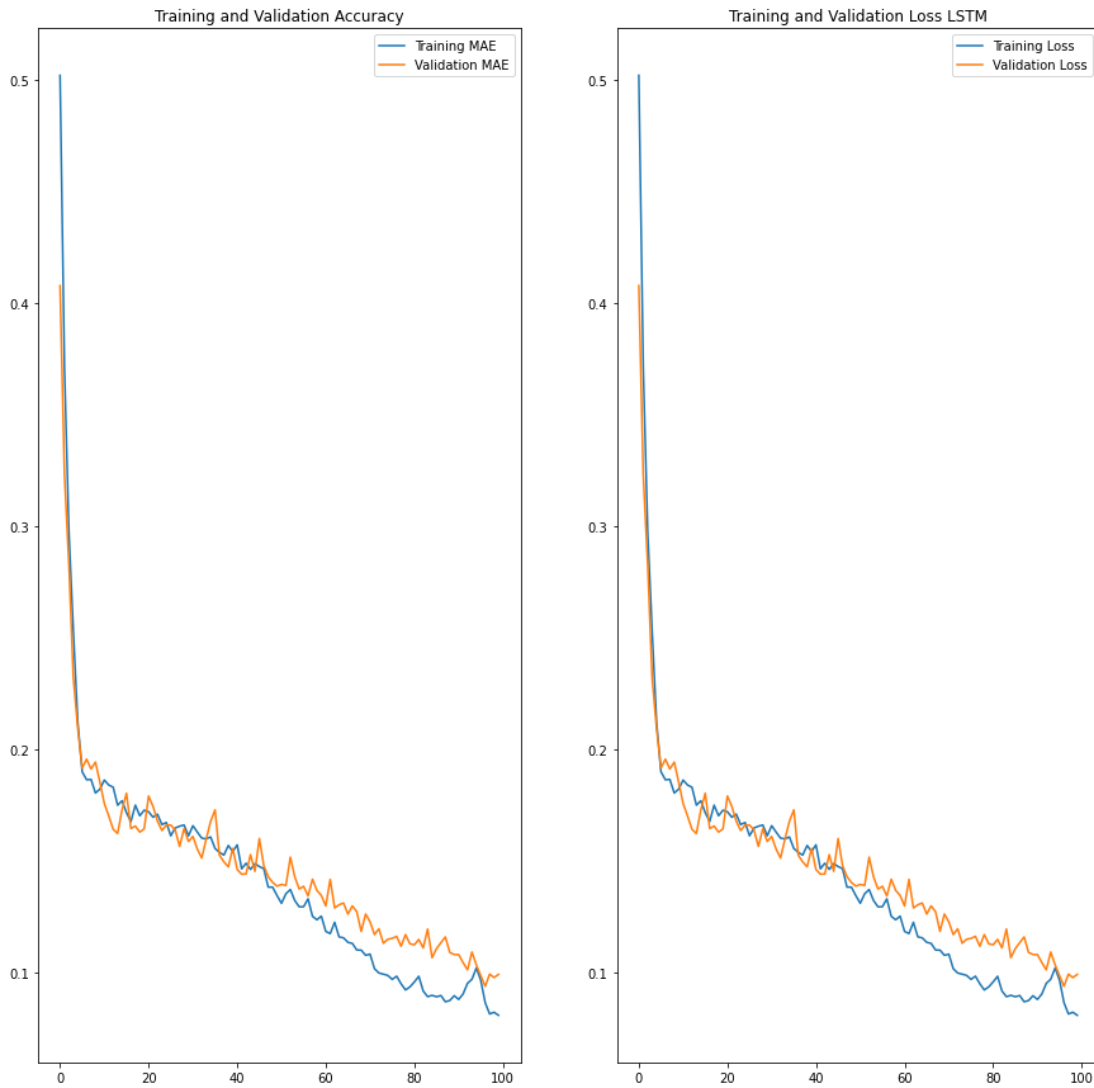





VTEC ΙΑΝΟΥΑΡΙΟΥ

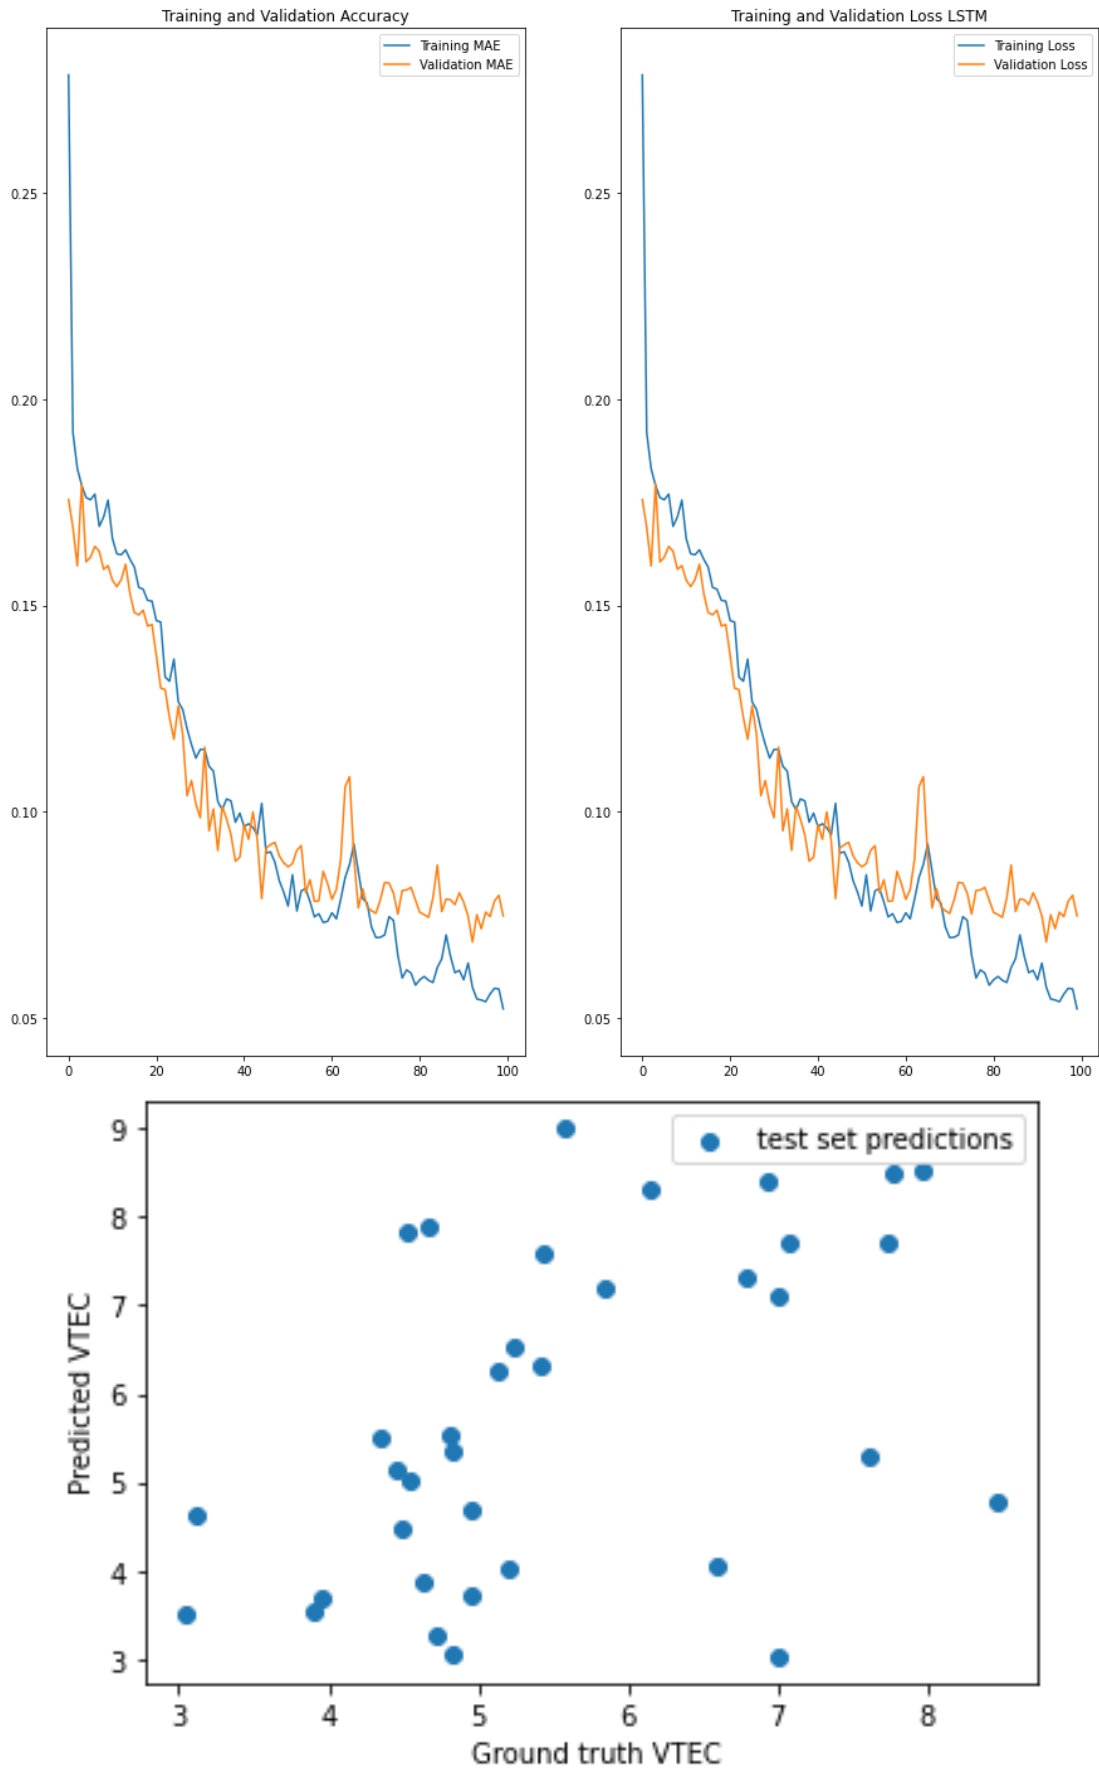




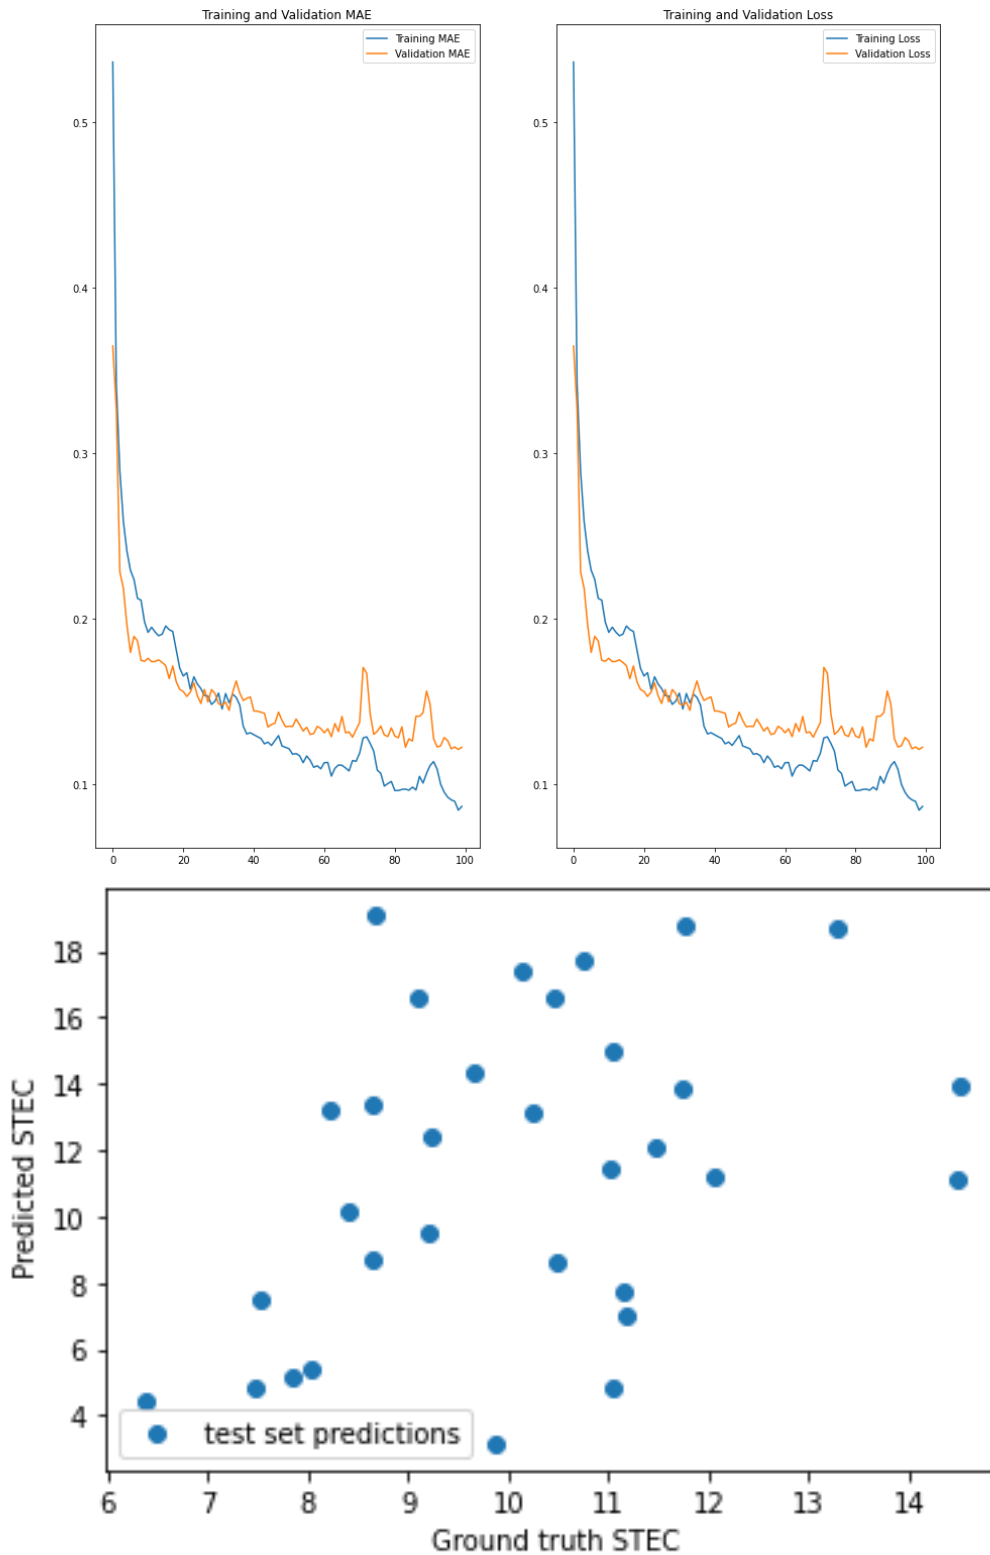







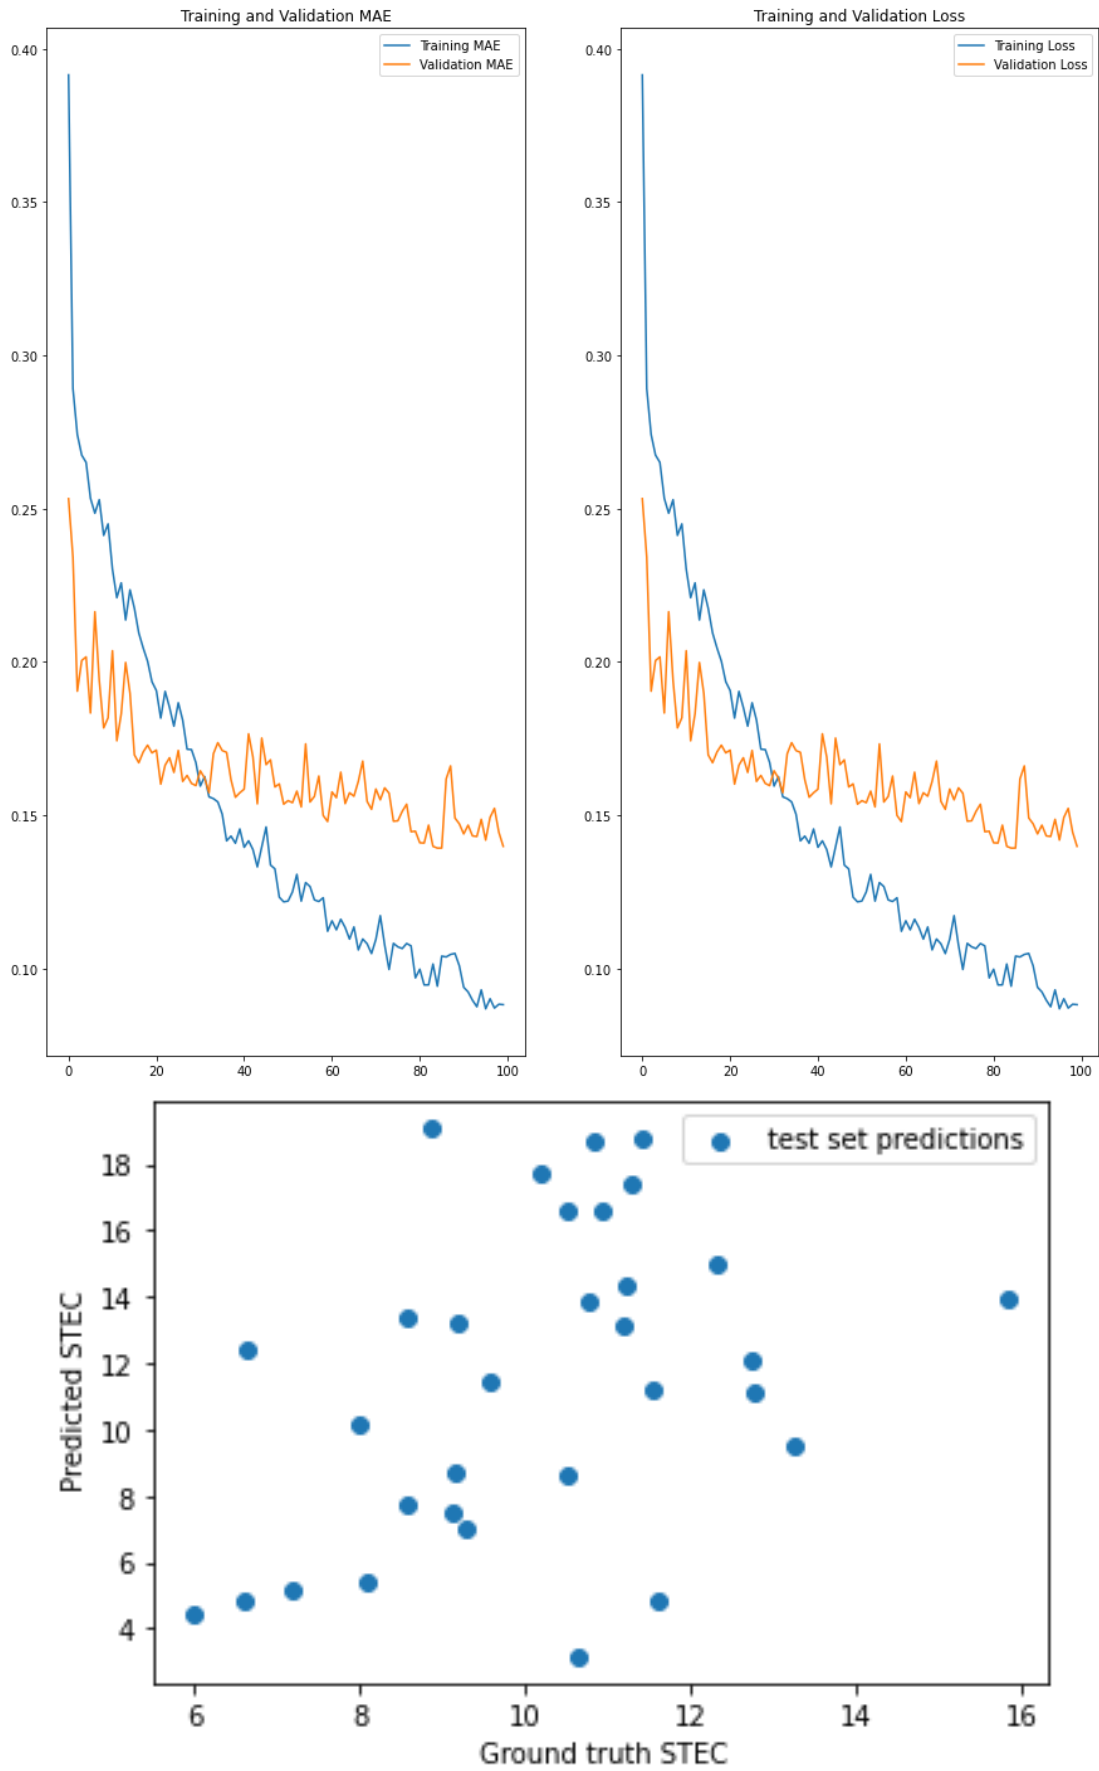










STEC ΦΕΒΡΟΥΑΡΙΟΥ







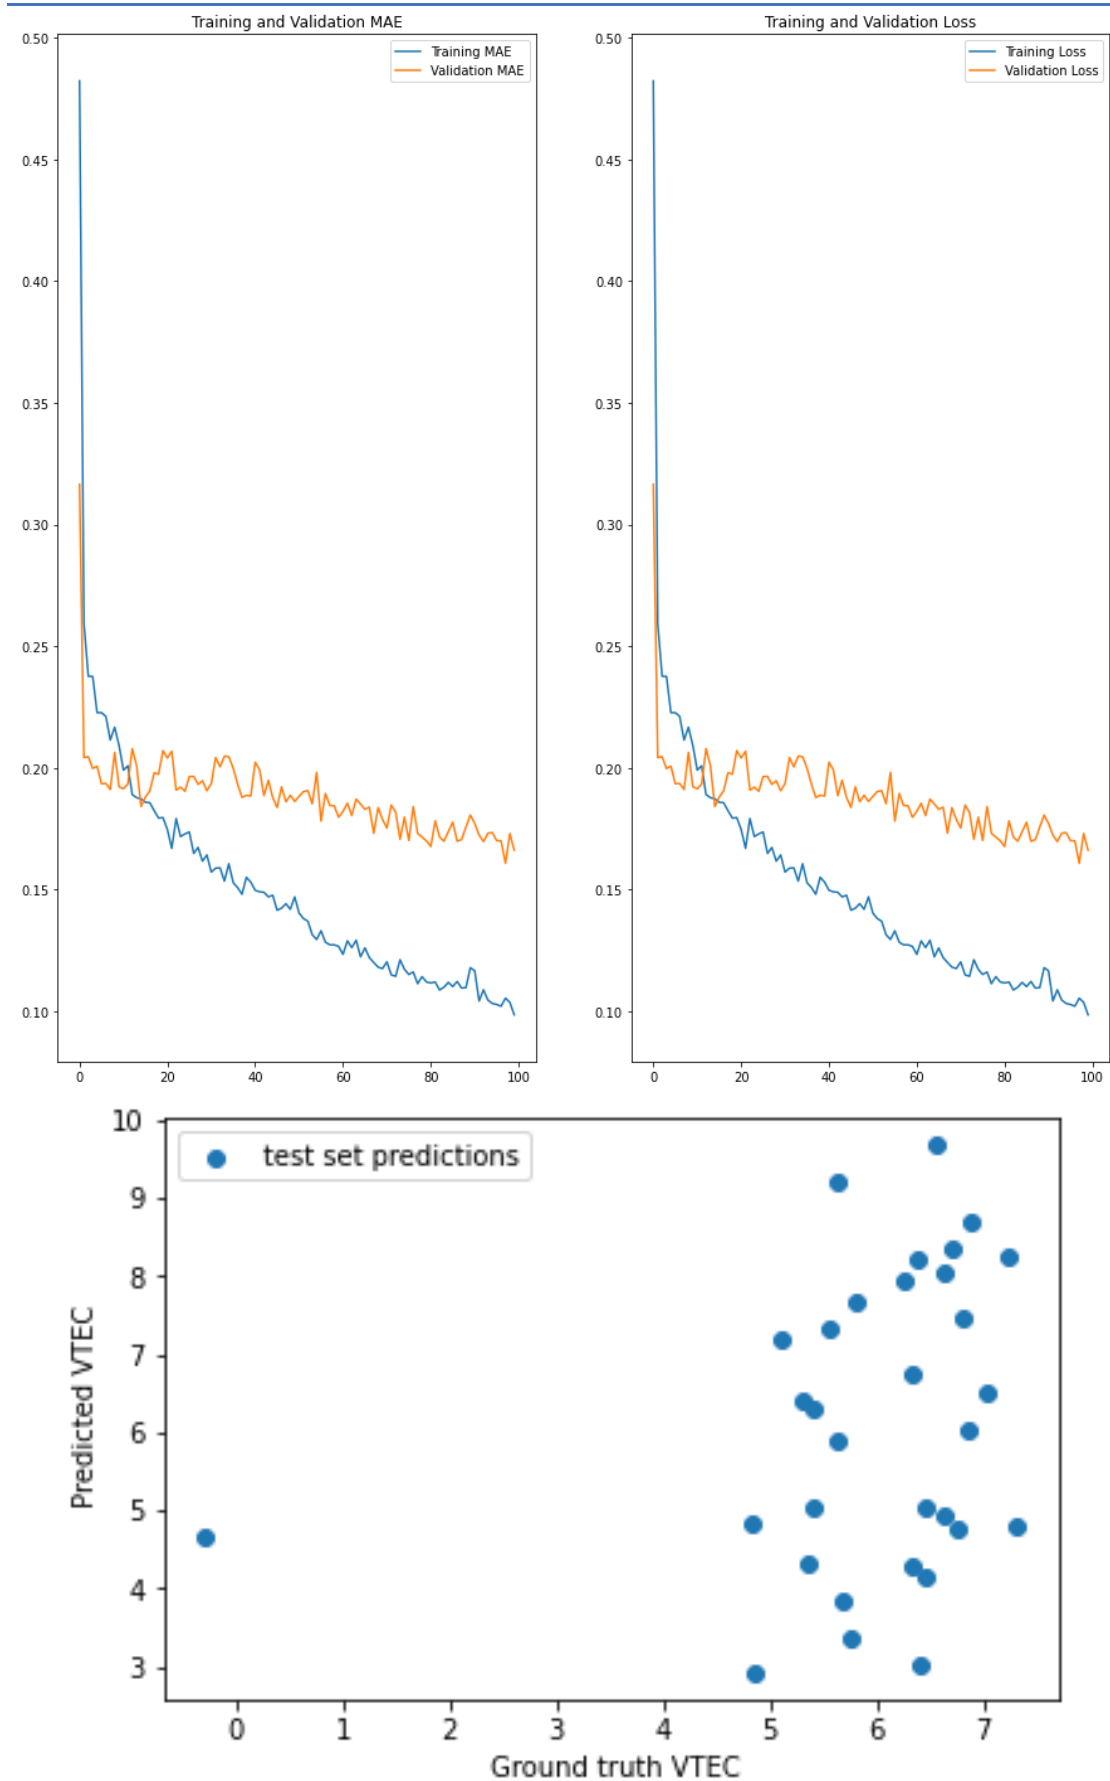







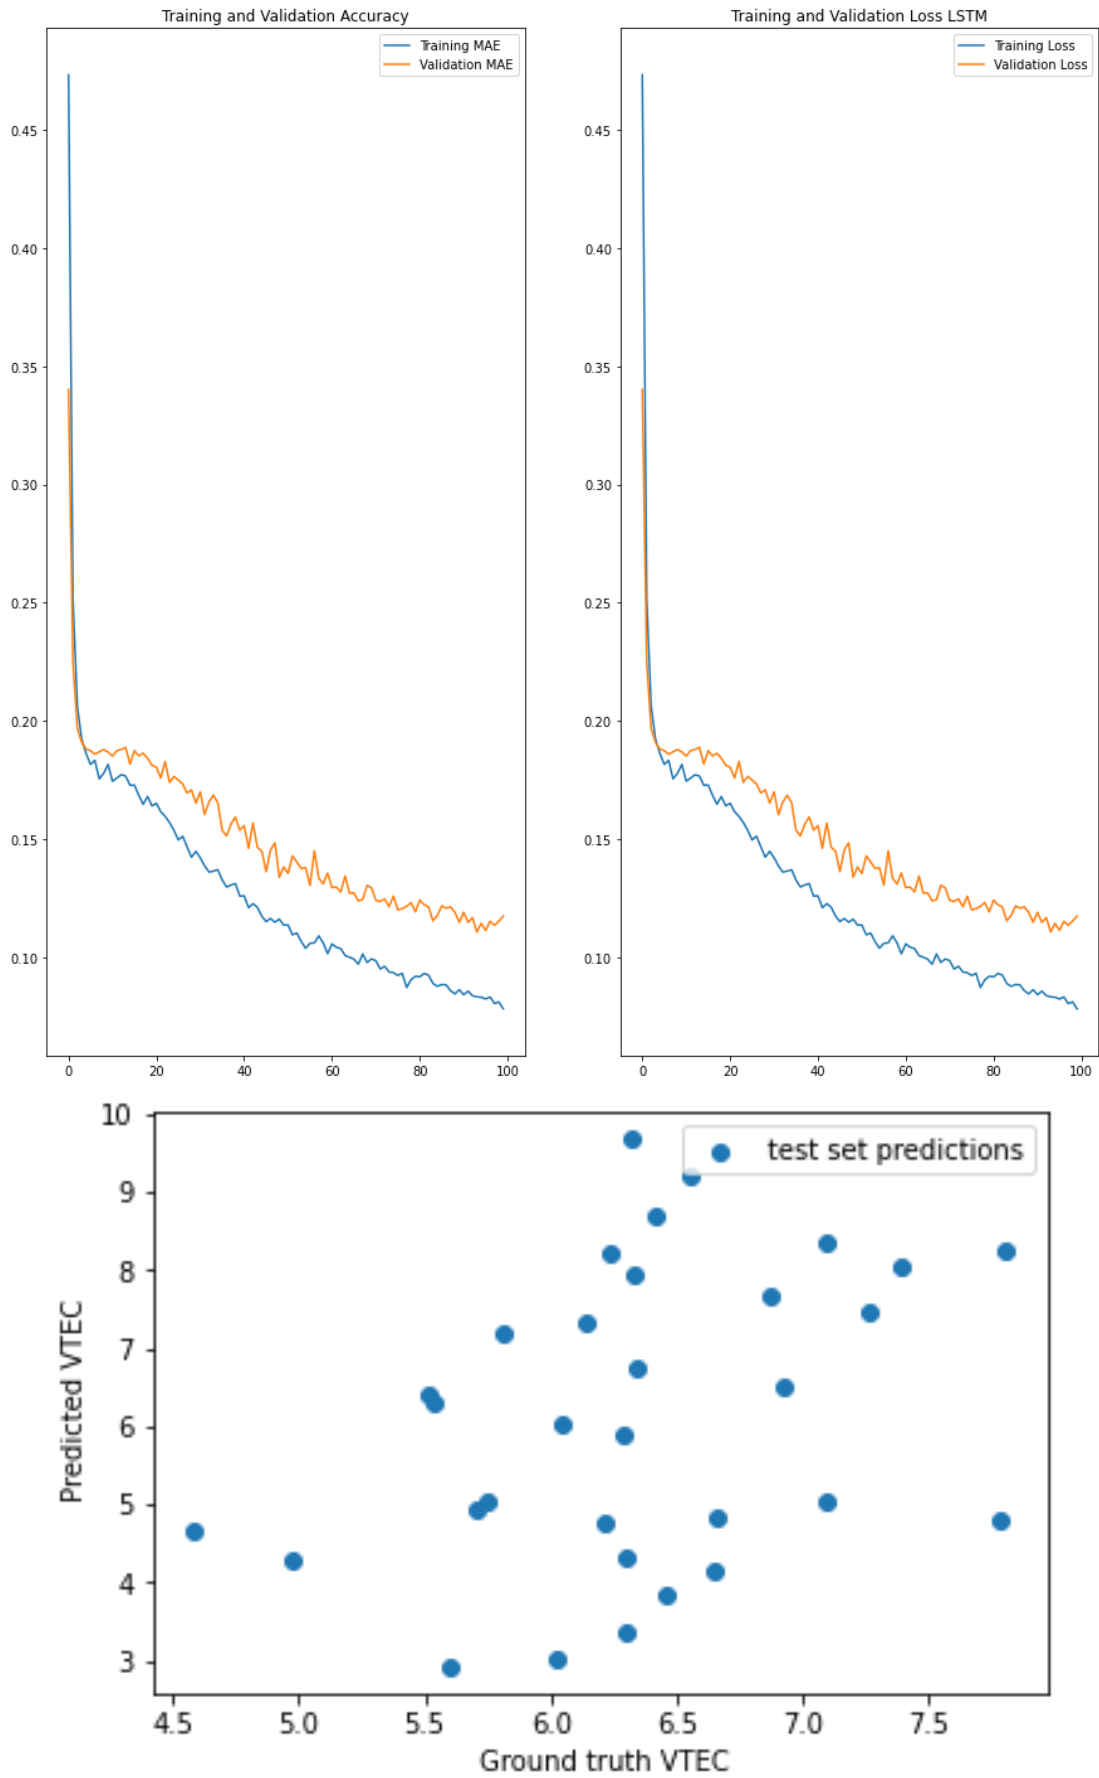










ΥΤΕC ΦΕΒΡΟΥΑΡΙΟΥ

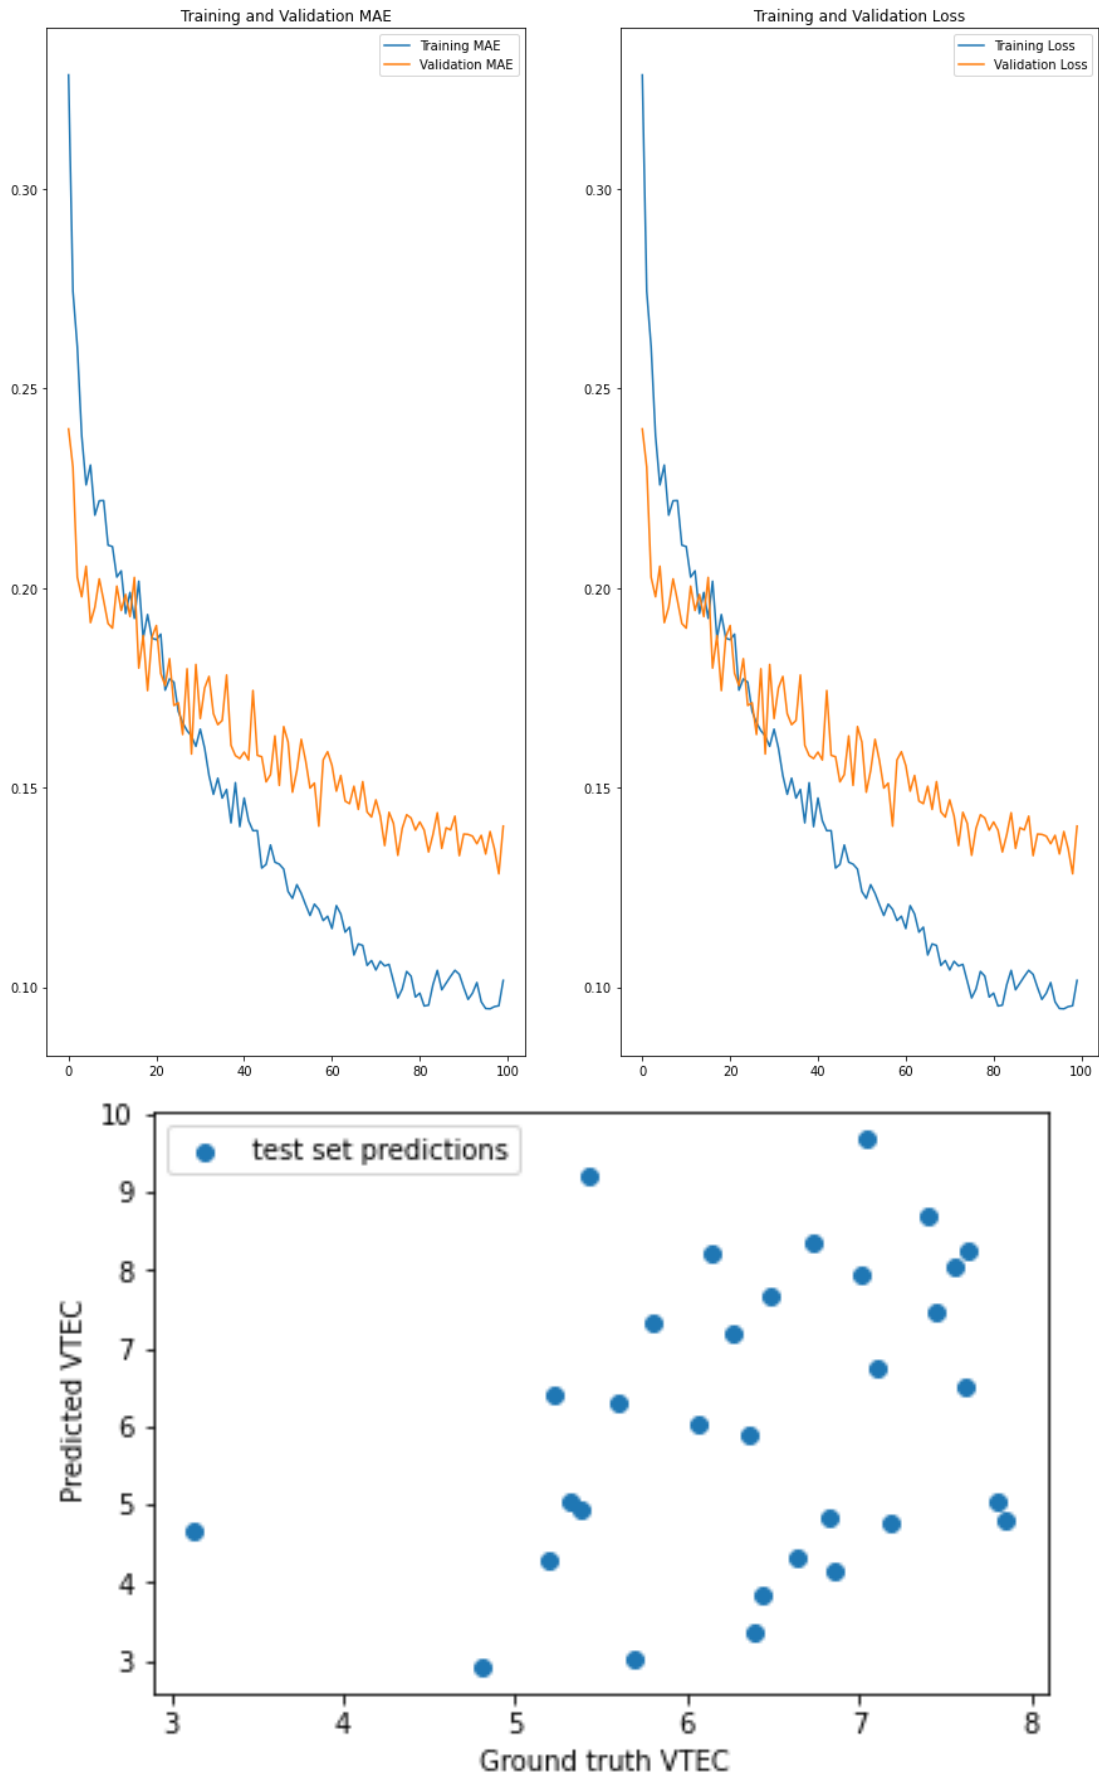




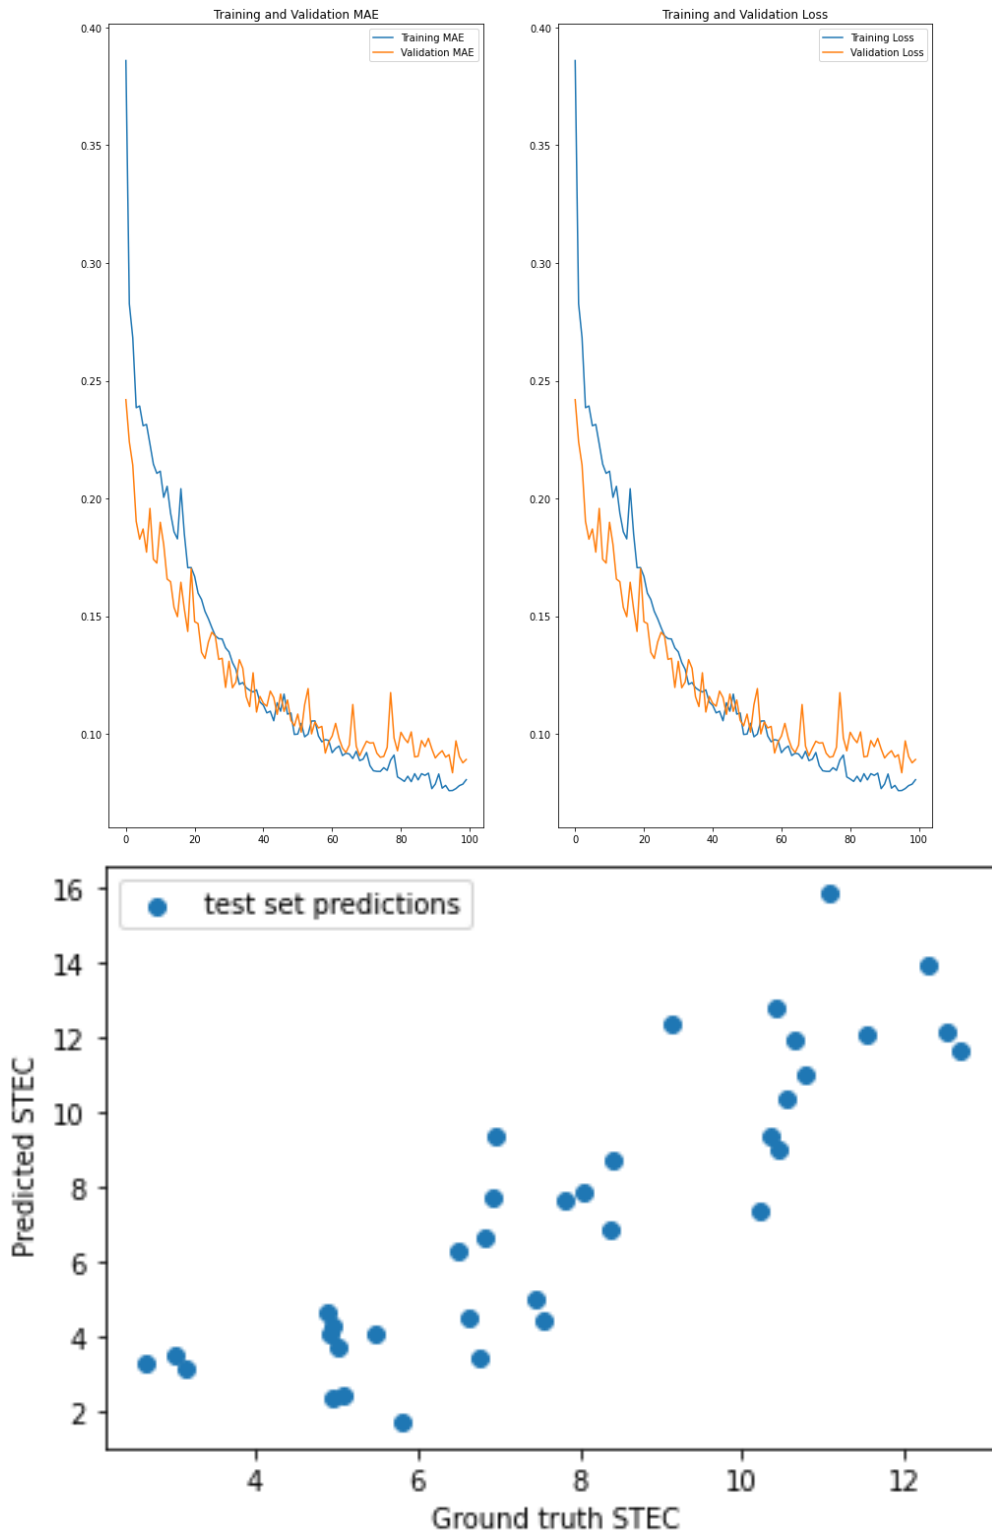



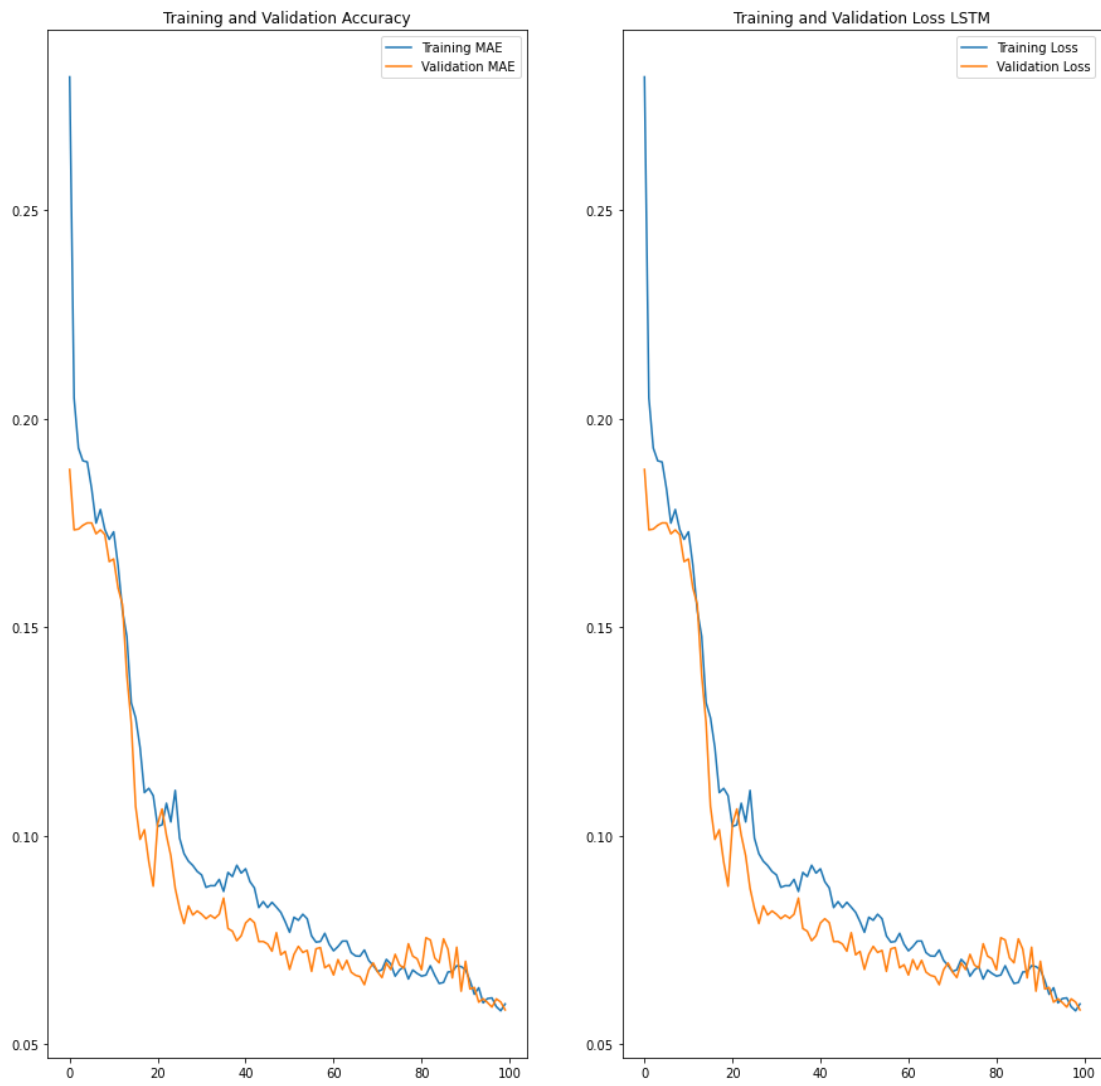



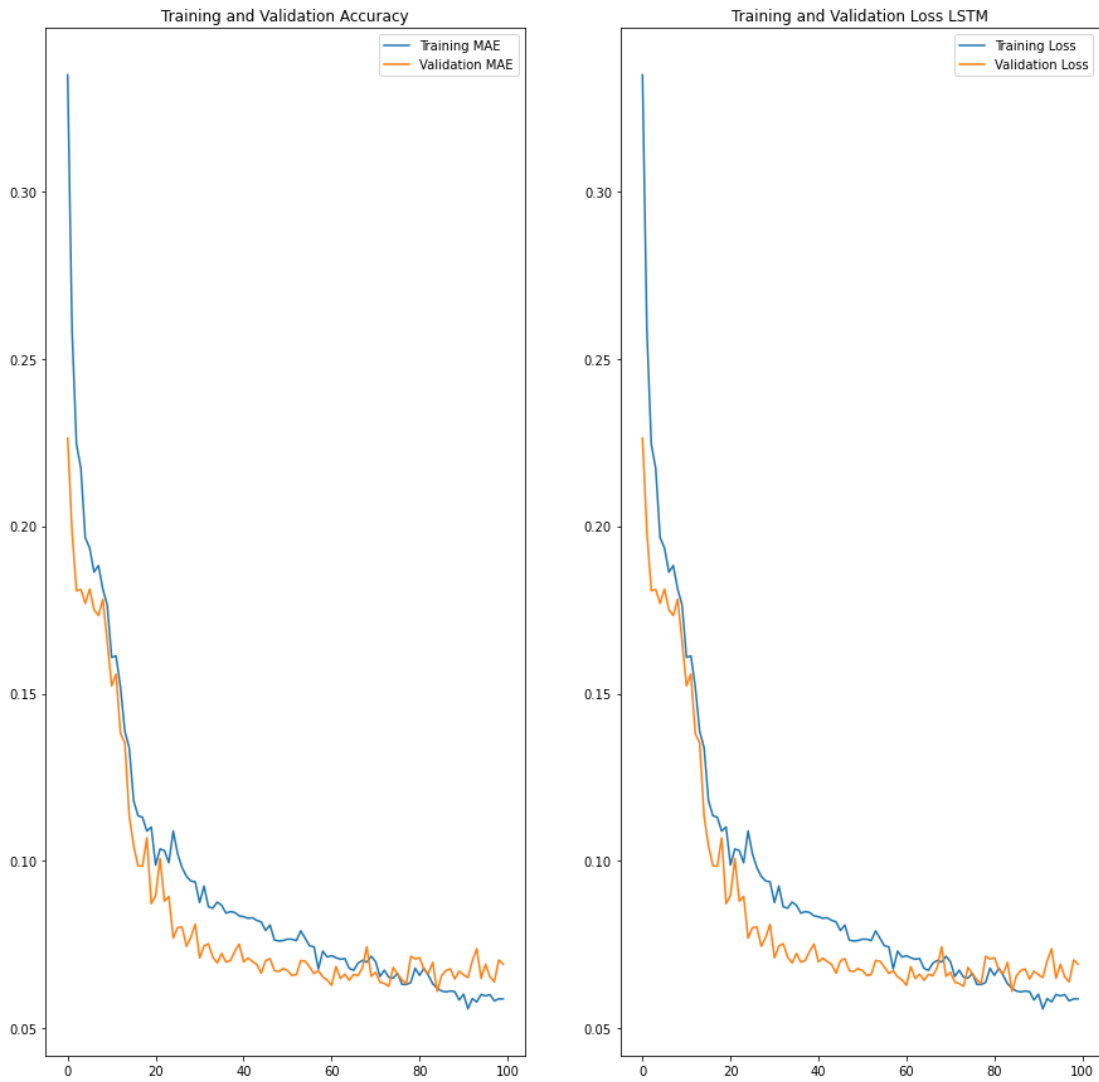


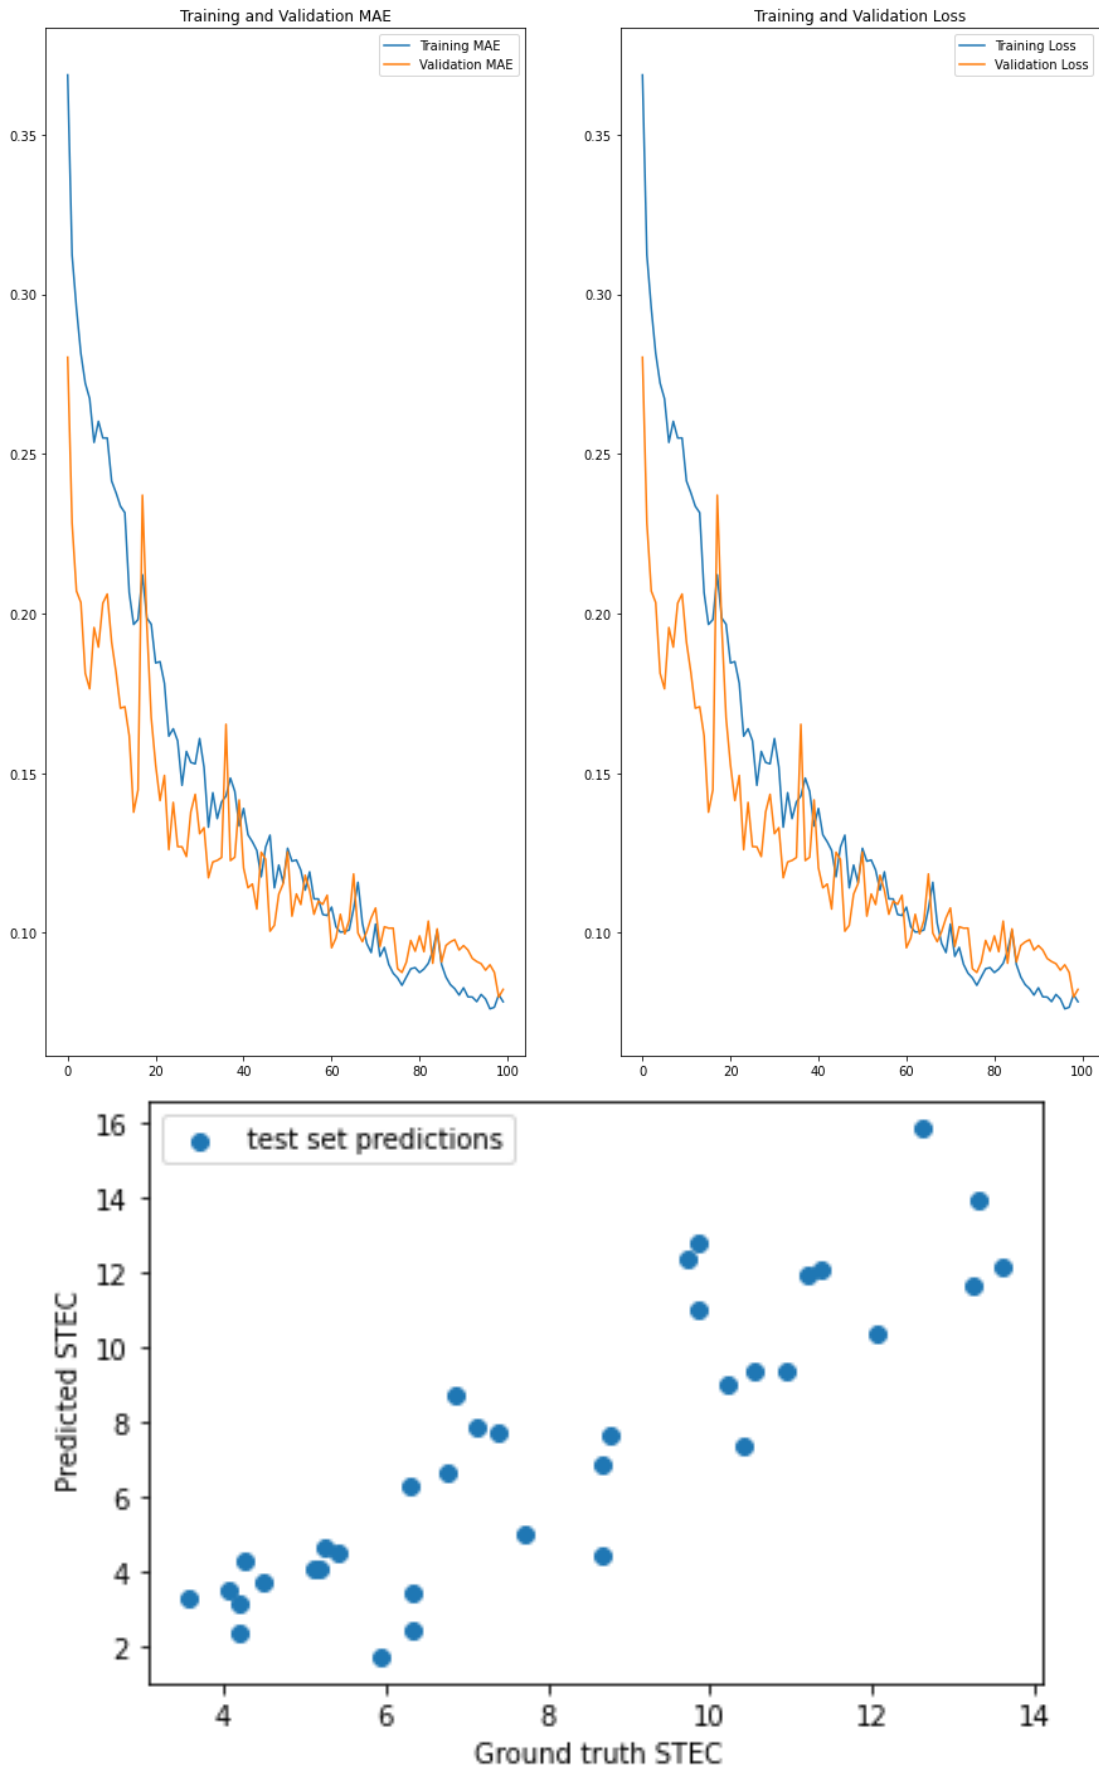





STEC ΜΑΡΤΙΟΥ








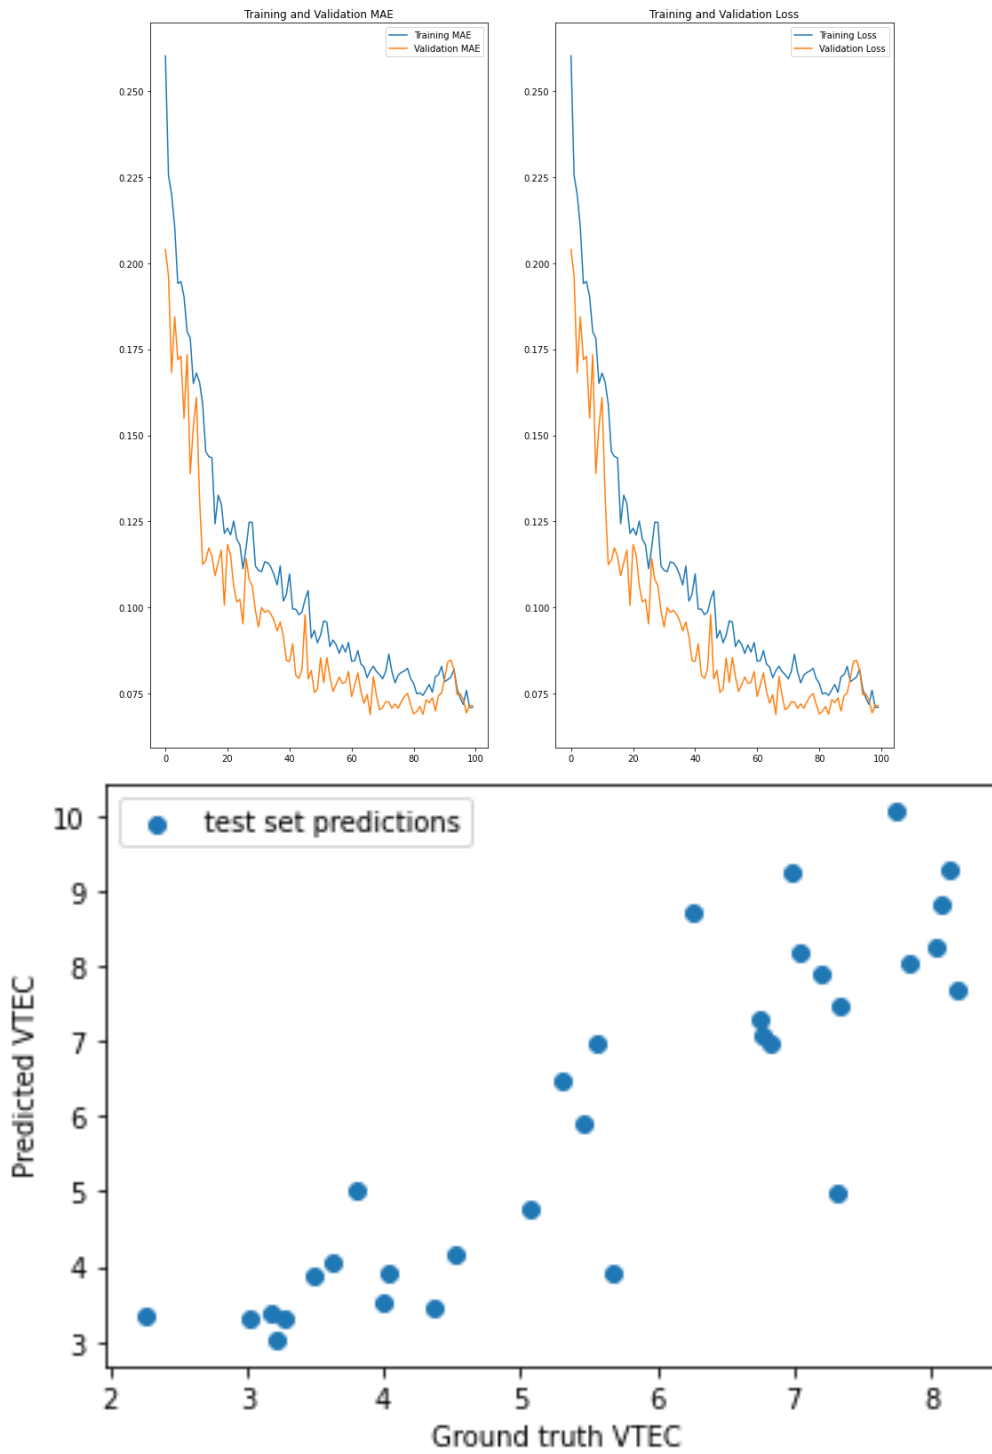

















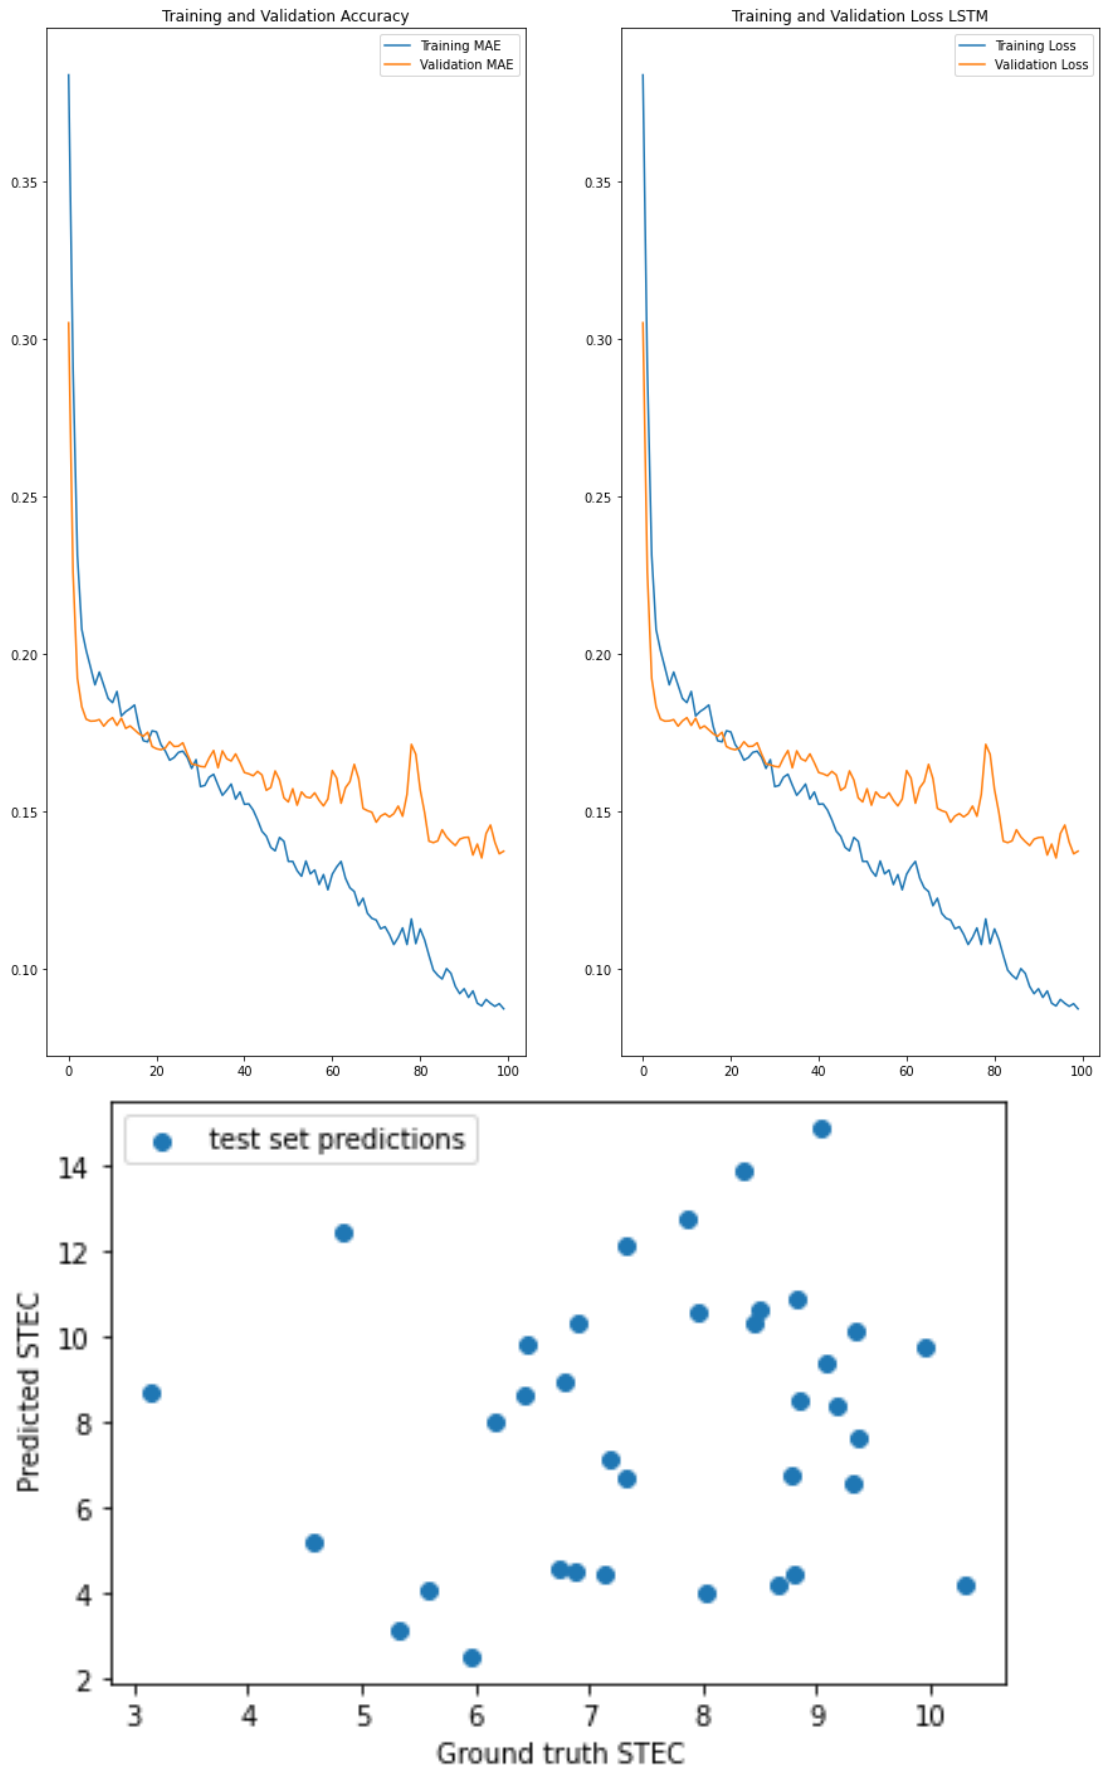
VTEC ΜΑΡΤΙΟΥ

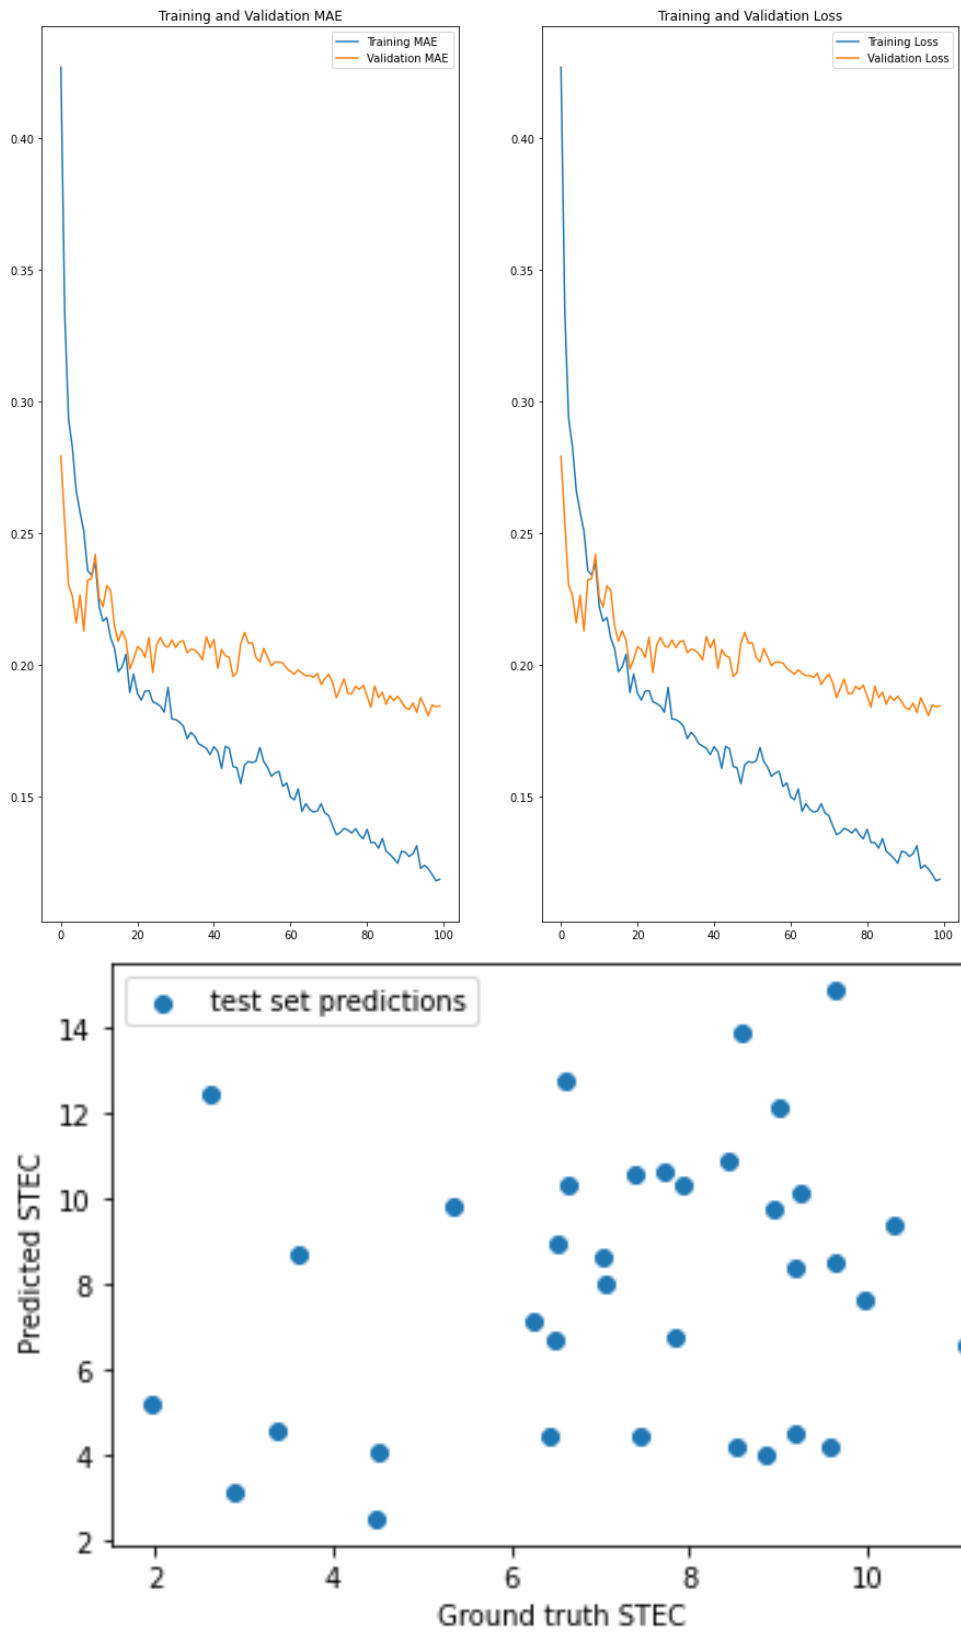


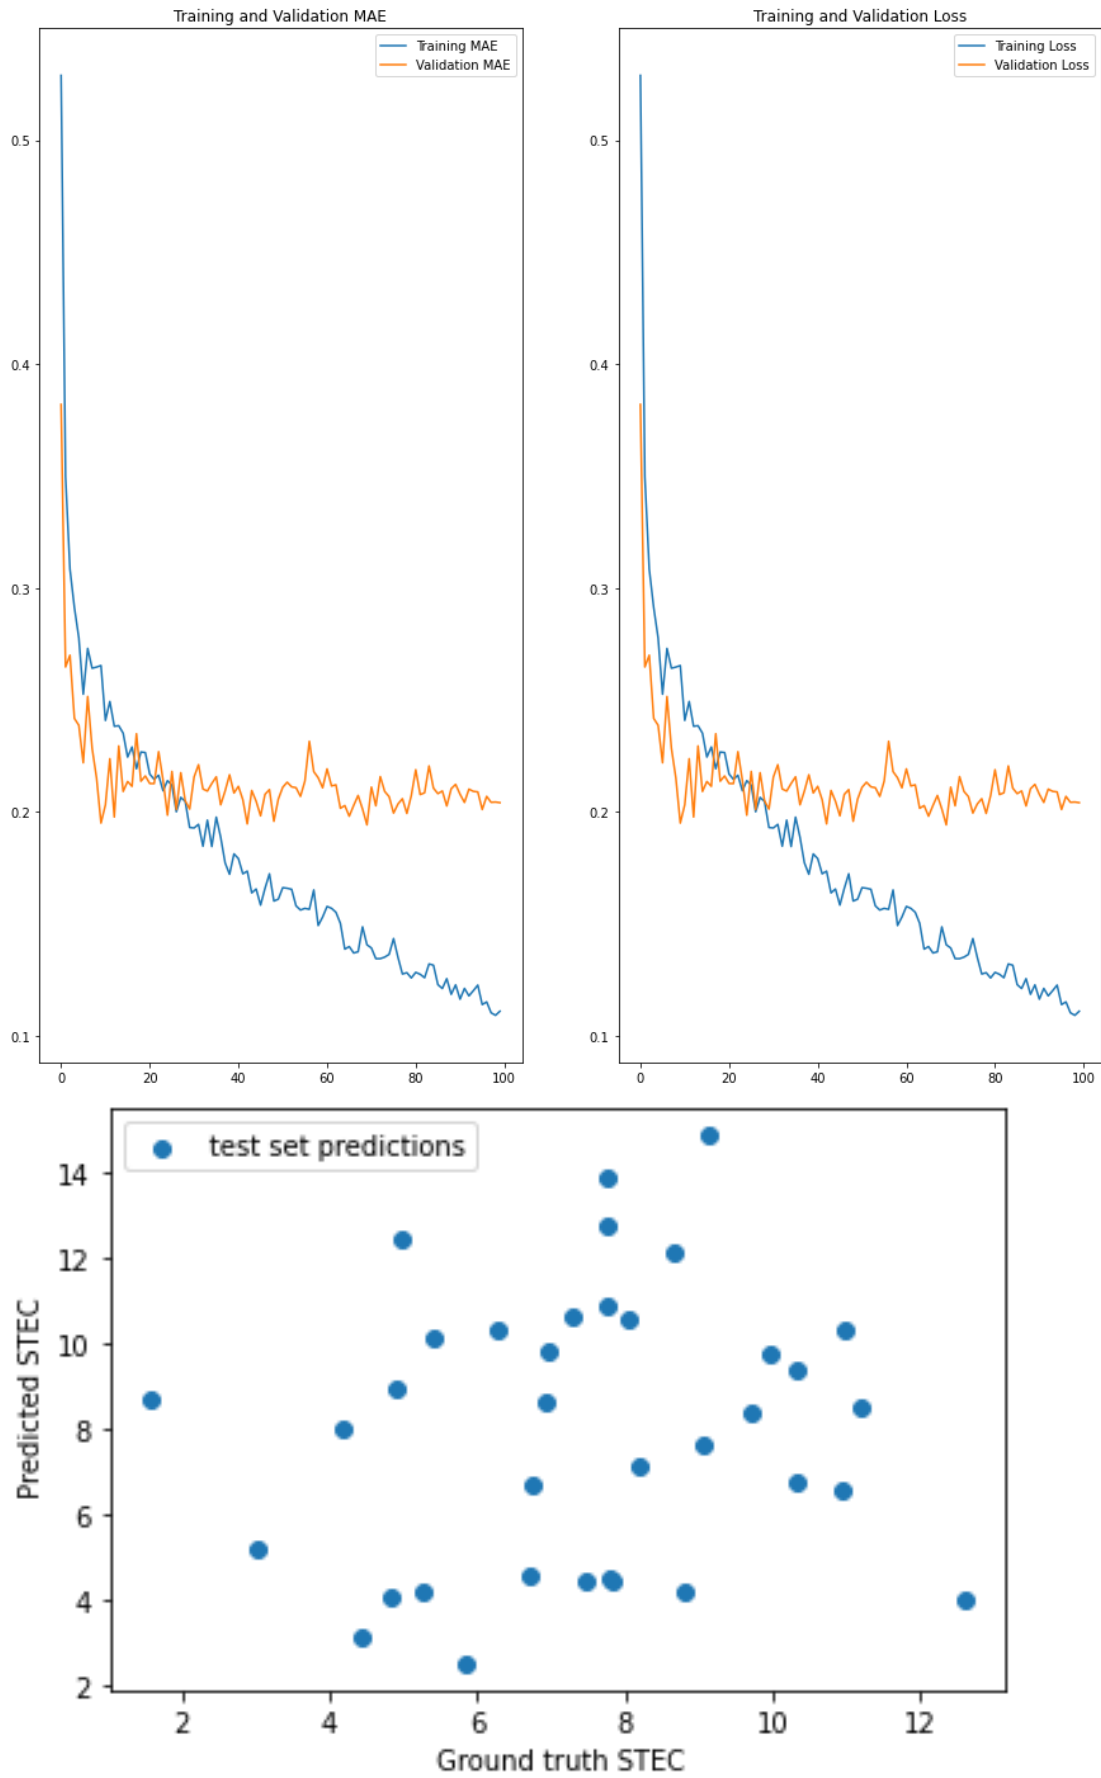






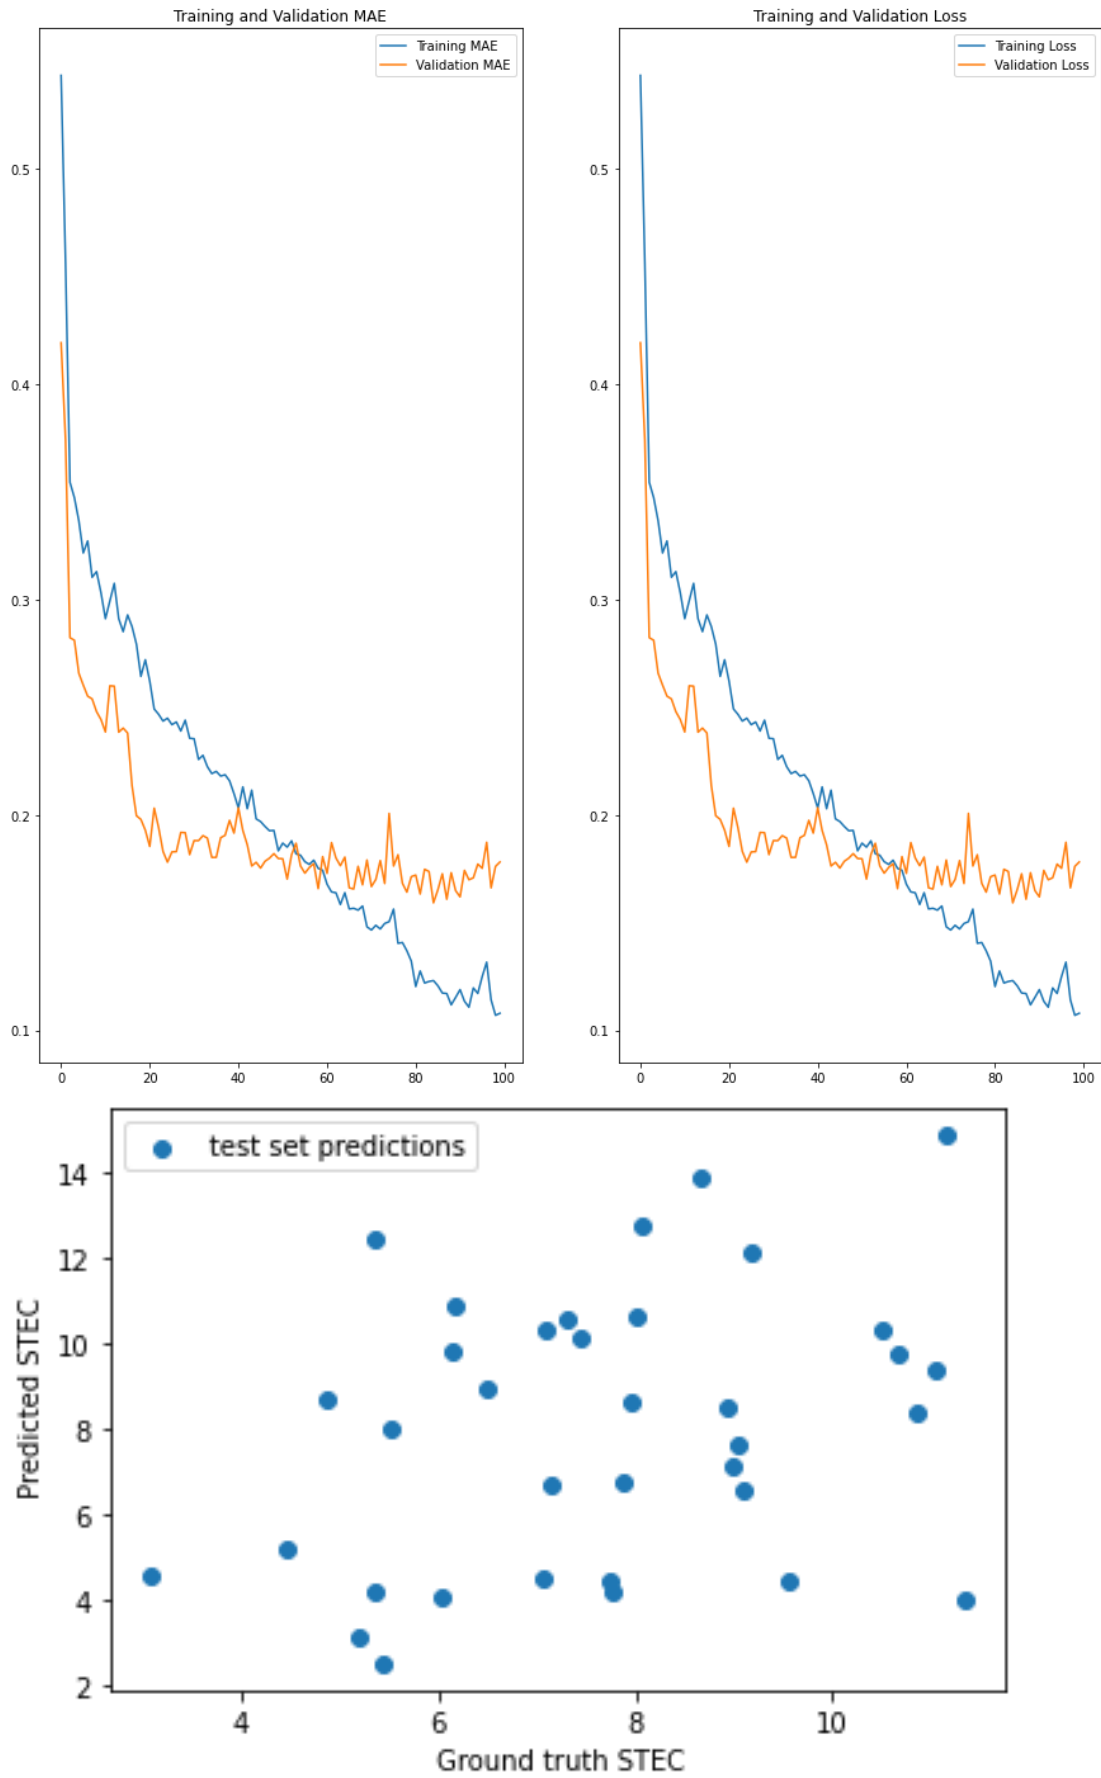


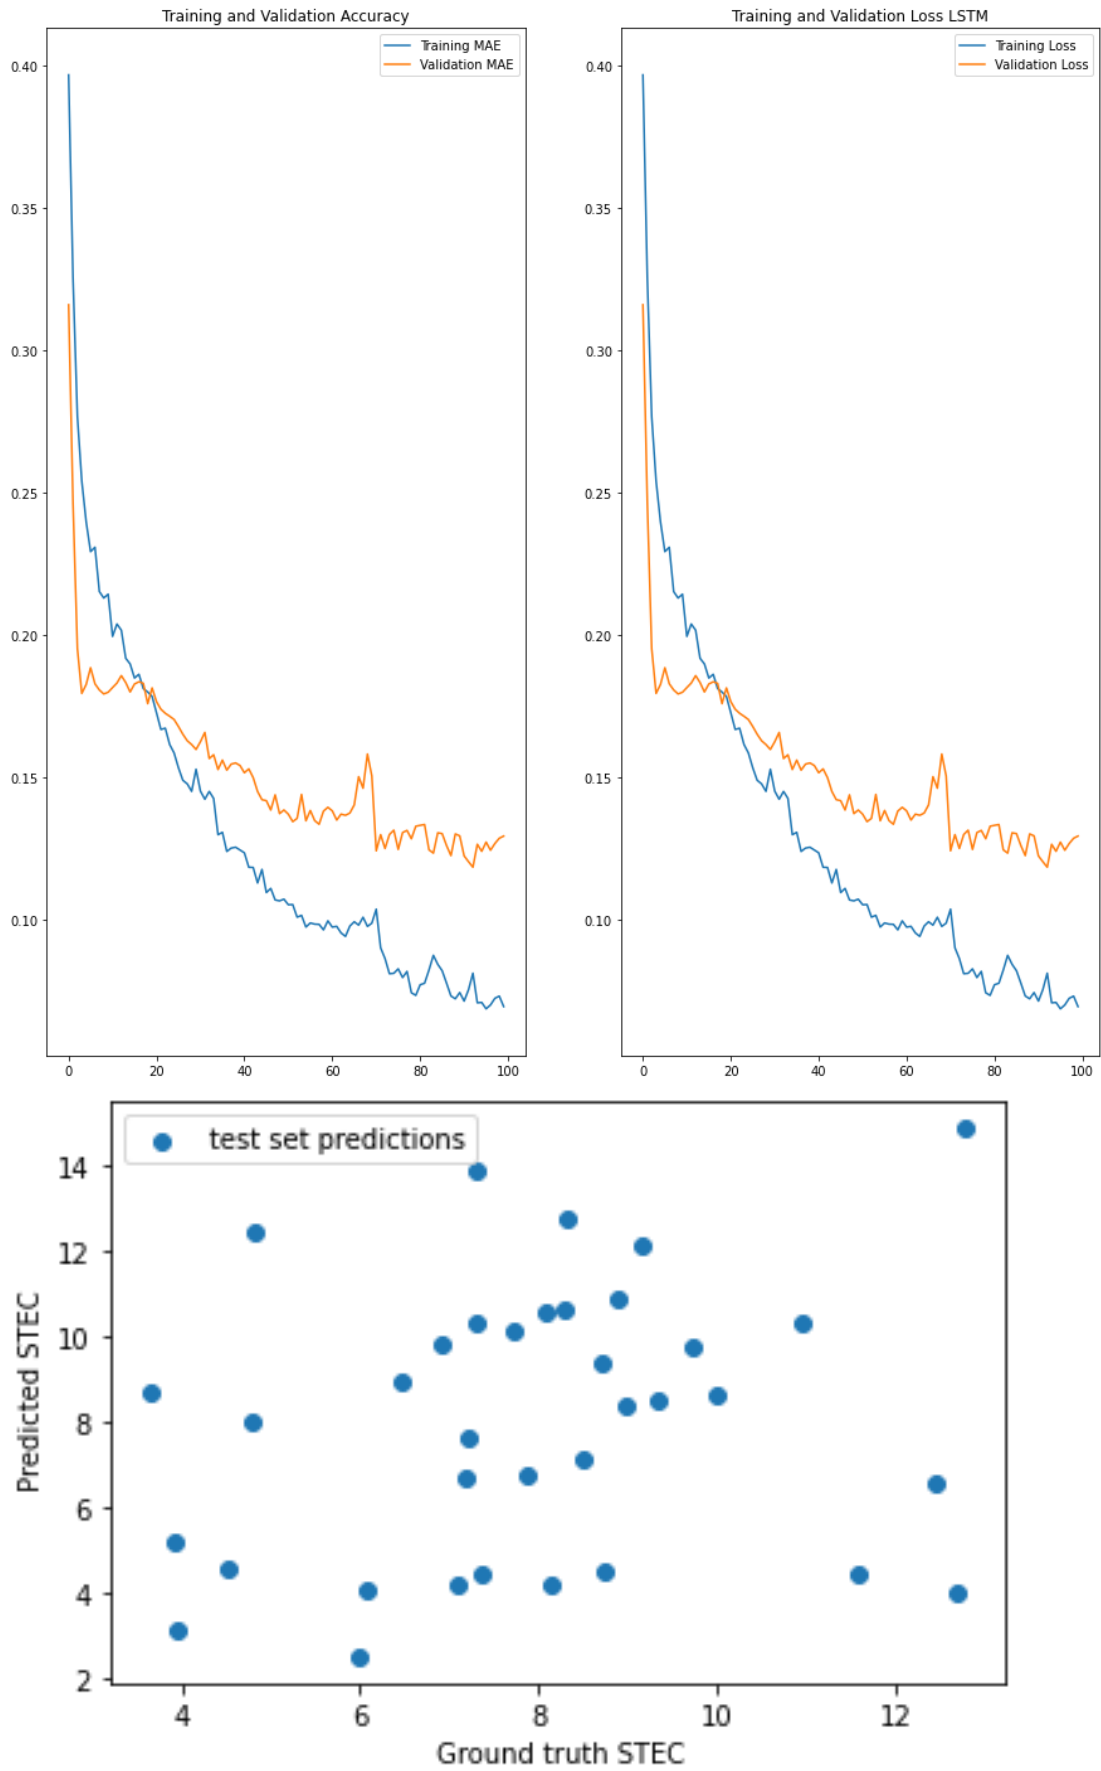












Παράρτημα Γ

ΚΩΔΙΚΑΣ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ RNN & LSTM

STEC

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

Importing Libraries

```
import pandas as pd
import numpy as np
from __future__ import print_function
from keras.models import Sequential
from keras.layers import Dense, Dropout, Flatten, InputLayer, Reshape
from keras.layers import LSTM, TimeDistributed, Bidirectional, Conv2D
import os
from datetime import date
import datetime
import matplotlib.pyplot as plt
from keras.utils.vis_utils import plot_model
```

Reading and scaling the data

```
path_for_excel = "/content/drive/MyDrive/dedomena/feb.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', 'fluxu',
# 'rsi', 'Daily_Total_Sunspot_Number', 'Daily_North_Sunspot_Number', 'D',
# 'aily_South_Sunspot_Number', 'Standard_Deviation_of_Raw_Daily_Total',
# '_Sunspot_Data', 'Standard_Deviation_of_Raw_Daily_North_Sunspot_Dat',
# 'a', 'Standard_Deviation_of_Raw_Daily_South_Sunspot_Data', 'Number_o',
# 'f_Observations_for_Daily_Total_Sunspot_Number', 'Number_of_Observa',
# 'tions_for_Daily_North_Sunspot_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', 'Angul
ar', 'Linear', '2nd-order_Speed_at_final_height', '2nd-
order_Speed_at_20_Rs', 'Accel_*', 'Mass_*', 'Kinetic_Energy_*', 'MPA'
]
Variables = Data.columns

#gia na mh xathoun oles oi parametroi
#InputDataFrame = Data[['A_(Daily)', 'Kp', 'ap', 'D', 'SML', 'SMU', 'fl
uxtime', 'fluxjulian', 'fluxcarrington', 'fluxobsflux', 'fluxadjflux'
, 'fluxursi', 'Daily_Total_Sunspot_Number', 'Daily_North_Sunspot_Num
ber', 'Daily_South_Sunspot_Number', 'Standard_Deviation_of_Raw_Dail
y_Total_Sunspot_Data', 'Standard_Deviation_of_Raw_Daily_North_Suns
pot_Data', 'Standard_Deviation_of_Raw_Daily_South_Sunspot_Data', 'N
umber_of_Observations_for_Daily_Total_Sunspot_Number', 'Number_of_
Observations_for_Daily_North_Sunspot_Number', 'Number_of_Observati
ons_for_Daily_South_Sunspot_Number', 'Definitive/Provisional_Indic
ator', 'GOES-15_Proton_FluEncE>1_MEV', 'GOES-
15_Proton_FluEncE>10_MEV', 'GOES-15_Proton_FluEncE>100_MEV', 'GOES-
15_ElElectron_FluEncE>0.8_MEV', 'GOES-
15_ElElectron_FluEncE>2_MEV', 'NEutron', 'Solar_Flares', 'Central_PA',
'Angular', 'Linear', '2nd-order_Speed_at_final_height', '2nd-
order_Speed_at_20_Rs', 'Accel_*', 'Mass_*', 'Kinetic_Energy_*', 'MPA'
]]

# Ceatea sud- dataframe that contains the inputs to the DL model
InputDataFrame = Data[[
    'a',
    'kp',
    'ap',
    'D', 'SML', 'SMU',

    'fluxtime', 'fluxjulian', 'fluxcarrington',
    'fluxobsflux', 'fluxadjflux', 'fluxursi',

    'dts', 'dns', 'dss', 'sddts',
    'sddns', 'sddss', 'obsdts', 'obsdns', 'obsdss', 'dpind',

    'one', 'ten',
    'hundred', 'zeroeight', 'two', 'nm'

    'sf',

    'pa', 'ang', 'lin', 'height',
    'speed', 'acc', 'mass', 'ke', 'mpa', 'msd', 'ked' ]]

```

```
InputVariables = InputDataFrame.columns

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

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

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

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

InputArrayNormalized = np.empty([InputArray.shape[0], InputArray.
shape[1]])
OutputArrayNormalized = np.empty([OutputArray.shape[0], OutputArr
ay.shape[1]])
for i in range(0,11):
    invar = InputVariables[i]
    InputArrayNormalized[:,i] = InputArray[:,i]/max_values[invar
]

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

IntermediateArrayNormalized = np.empty([(InputArray.shape[0]-
7), 7])
Input3DArrayNormalized = np.empty([(InputArray.shape[0]-7), 7])
for i in range(0,11):
    invar = InputVariables[i]
    for j in range(0,(InputArray.shape[0]-7)):
        IntermediateArrayNormalized[j,:] = InputArrayNormalized[
j:j+7,i]

    Input3DArrayNormalized =np.dstack((Input3DArrayNormalized, In
termediateArrayNormalized))

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], Output3DArrayNormalized.shape[1], 1) # (411, 7, 1)

```

```

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]

print(X_train.shape)

```

```

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

```

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((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/dedomena/
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_erro
r']

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))

import matplotlib.pyplot as plt

x = yh
y = yg
plt.scatter(x, y, label = "test set predictions")
plt.ylabel(" Predicted STEC")
plt.xlabel(" Ground truth STEC")
plt.legend()
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())

#saki anoikse to
plot_model(model_LSTM, to_file='/content/drive/MyDrive/dedomena/m
odel_plot_LSTM1.png', show_shapes=True, show_layer_names=True)

```

```
# 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))

import matplotlib.pyplot as plt

x = yh
y = yg
plt.scatter(x, y, label = "test set predictions")
plt.ylabel(" Predicted STEC")
plt.xlabel(" Ground truth STEC")
plt.legend()
plt.show()
```

VTEC

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

Importing Libraries

```
import pandas as pd
import numpy as np
from __future__ import print_function
from keras.models import Sequential
from keras.layers import Dense, Dropout, Flatten, InputLayer, Reshape
from keras.layers import LSTM, TimeDistributed, Bidirectional, Conv1D, SimpleRNN, GRU, Conv2D
import os
from datetime import date
import datetime
import matplotlib.pyplot as plt
from keras.utils.vis_utils import plot_model
```

Reading and scaling the data

```
path_for_excel = "/content/drive/MyDrive/dedomena/feb.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', 'fluxu',
# 'fluxursi', 'Daily_Total_Sunspot_Number', 'Daily_North_Sunspot_Number', 'D',
# 'Daily_South_Sunspot_Number', 'Standard_Deviation_of_Raw_Daily_Total',
# '_Sunspot_Data', 'Standard_Deviation_of_Raw_Daily_North_Sunspot_Dat',
# 'a', 'Standard_Deviation_of_Raw_Daily_South_Sunspot_Data', 'Number_o',
# 'f_Observations_for_Daily_Total_Sunspot_Number', 'Number_of_Observa',
# 'tions_for_Daily_North_Sunspot_Number', 'Number_of_Observations_for',
# '_Daily_South_Sunspot_Number', 'Definitive/Provisional_Indicator', '
# GOES-15_Proton_FluEncE', 'GOES-
# 15_ElEctron_FluEncE', 'NEutron', 'Solar_Flares', 'Central_PA', 'Angul',
# 'ar', 'Linear', '2nd-order_Speed_at_final_height', '2nd-
# order_Speed_at_20_Rs', 'Accel_*', 'Mass_*', 'Kinetic_Energy_*', 'MPA'
# ]
Variables = Data.columns

#gia na mh xathoun oles oi parametroi
#InputDataFrame = Data[['A_(Daily)', 'Kp', 'ap', 'D', 'SML', 'SMU', 'fl',
# 'uxtime', 'fluxjulian', 'fluxcarrington', 'fluxobsflux', 'fluxadjflux',
# ', 'fluxursi', 'Daily_Total_Sunspot_Number', 'Daily_North_Sunspot_Num',
# 'ber', 'Daily_South_Sunspot_Number', 'Standard_Deviation_of_Raw_Dail',
# 'y_Total_Sunspot_Data', 'Standard_Deviation_of_Raw_Daily_North_Suns',
# 'pot_Data', 'Standard_Deviation_of_Raw_Daily_South_Sunspot_Data', 'N',
# 'umber_of_Observations_for_Daily_Total_Sunspot_Number', 'Number_of_',
# 'Observations_for_Daily_North_Sunspot_Number', 'Number_of_Observati',
# 'ons_for_Daily_South_Sunspot_Number', 'Definitive/Provisional_Indic',
# 'ator', 'GOES-15_Proton_FluEncE>1_MEV', 'GOES-
# 15_Proton_FluEncE>10_MEV', 'GOES-15_Proton_FluEncE>100_MEV', 'GOES-
# 15_ElEctron_FluEncE>0.8_MEV', 'GOES-
# 15_ElEctron_FluEncE>2_MEV', 'NEutron', 'Solar_Flares', 'Central_PA',
# ', 'Angular', 'Linear', '2nd-order_Speed_at_final_height', '2nd-
# order_Speed_at_20_Rs', 'Accel_*', 'Mass_*', 'Kinetic_Energy_*', 'MPA'
# ]]

# Ceatea sud- dataframe that contains the inputs to the DL model
InputDataFrame = Data[[
    'a',
    'kp',
    'ap',
    'D', 'SML', 'SMU',

    'fluxtime', 'fluxjulian', 'fluxcarrington',
    'fluxobsflux', 'fluxadjflux', 'fluxursi',

    'dts', 'dns', 'dss', 'sddts',
    'sddns', 'sddss', 'obsdts', 'obsdns', 'obsdss', 'dpind',

```

```
'one', 'ten',
'hundred', 'zeroeight', 'two', 'nm'

'sf',

'pa', 'ang', 'lin', 'height',
'speed', 'acc', 'mass', 'ke', 'mpa', 'msd', 'ked' ]]
```

```
InputVariables = InputDataFrame.columns

OutputDataFrame = Data[['vtec']]
OutputVariables = OutputDataFrame.columns

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

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

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

InputArrayNormalized = np.empty([InputArray.shape[0], InputArray.
shape[1]])
OutputArrayNormalized = np.empty([OutputArray.shape[0], OutputArr
ay.shape[1]])
for i in range(0,11):
    invar = InputVariables[i]
    InputArrayNormalized[:,i] = InputArray[:,i]/max_values[invar
]

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

```
IntermediateArrayNormalized = np.empty([(InputArray.shape[0]-
7), 7])
```

```
Input3DArrayNormalized = np.empty([(InputArray.shape[0]-7), 7])
for i in range(0,11):
    invar = InputVariables[i]
    for j in range(0, (InputArray.shape[0]-7)):
        IntermediateArrayNormalized[j,:] = InputArrayNormalized[
j:j+7,i]

    Input3DArrayNormalized =np.dstack((Input3DArrayNormalized, In
termediateArrayNormalized))

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(OutputArrayNorma
lized[j:j + 7])
Y = Output3DArrayNormalized.reshape(Output3DArrayNormalized.shape
[0], Output3DArrayNormalized.shape[1], 1) # (411, 7, 1)

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]

print(X_train.shape)

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

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((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/dedomena/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))

import matplotlib.pyplot as plt

x = yh
y = yg
plt.scatter( x, y, label = "test set predictions")
plt.ylabel(" Predicted VTEC")
plt.xlabel(" Ground truth VTEC")
plt.legend()
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())

#save anoikse to
plot_model(model_LSTM, to_file='/content/drive/MyDrive/dedomena/model_plot_LSTM.png', show_shapes=True, show_layer_names=True)

# 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))

import matplotlib.pyplot as plt

x = yh
y = yg
plt.scatter(x, y, label = "test set predictions")
plt.ylabel(" Predicted VTEC")
plt.xlabel(" Ground truth VTEC")
plt.legend()
plt.show()
```
