



Τμήμα Ψηφιακών Συστημάτων

ΠΜΣ «Πληροφοριακά Συστήματα και Υπηρεσίες»

Κατεύθυνση «Μεγάλα Δεδομένα και Αναλυτική»

Μεταπτυχιακή Διατριβή

**Πρόβλεψη Περιβαλλοντικών Χρονοσειρών με Ακραίες
Τιμές με την χρήση Μεθόδων Βαθιάς Μάθησης και
Κλασικών Στατιστικών Μοντέλων**

Αντώνης Μαρίνος

Επιβλέπων: Μιχαήλ Φιλιππάκης, Καθηγητής

Πειραιάς, 2025

Περίληψη

Η παρούσα διπλωματική εργασία εστιάζει στην πρόβλεψη χρονοσειρών περιβαλλοντικών δεδομένων με τη χρήση παραδοσιακών στατιστικών μοντέλων και σύγχρονων τεχνικών βαθιάς μάθησης. Στόχος είναι η συγκριτική αξιολόγηση των μεθόδων ως προς την ικανότητά τους να αποτυπώνουν τα βασικά χαρακτηριστικά των χρονοσειρών (τάση, εποχικότητα, μεταβλητότητα) αλλά και να προβλέπουν ακραία γεγονότα, τα οποία αποτελούν κρίσιμο στοιχείο για περιβαλλοντικές εφαρμογές. Για τον σκοπό αυτό χρησιμοποιήθηκαν τρία διαφορετικά σύνολα δεδομένων: μέγιστες μηνιαίες θερμοκρασίες στο Χονγκ Κονγκ, μηνιαίες σεισμικές εντάσεις στην Καλιφόρνια και μηνιαίες βροχοπτώσεις στο Σίδνεϊ.

Στο πλαίσιο της μελέτης εφαρμόστηκαν παραδοσιακά μοντέλα (ARIMA, SARIMA), νευρωνικά δίκτυα (CNN, GRU), καθώς και πιο εξειδικευμένες προσεγγίσεις (DAN, Reweight-EVT, Reweight-META). Η απόδοση των μοντέλων αξιολογήθηκε με μετρικές σφάλματος (RMSE, MAE) αλλά και μέσω ποιοτικής ανάλυσης των προβλέψεων. Τα αποτελέσματα έδειξαν ότι τα γραμμικά μοντέλα αποδίδουν ικανοποιητικά σε σειρές με έντονη εποχικότητα, αλλά υστερούν σε δεδομένα με υψηλή μεταβλητότητα και ακραίες τιμές. Τα νευρωνικά δίκτυα υπερείχαν στη σύλληψη μη γραμμικών μοτίβων, με το CNN να αποδίδει καλύτερα τις κορυφές και το GRU να παρέχει πιο σταθερές προβλέψεις. Τα εξειδικευμένα μοντέλα βελτίωσαν περαιτέρω την απόδοση, με το Reweight-META να εμφανίζει την πιο προσαρμοστική συμπεριφορά στην πρόβλεψη ακραίων γεγονότων.

Συνολικά, η εργασία καταδεικνύει ότι η ενσωμάτωση τεχνικών βαθιάς μάθησης και ειδικότερα μεθόδων αναπροσδιορισμού βαρών μπορεί να ενισχύσει την ακρίβεια και τη χρησιμότητα των μοντέλων πρόβλεψης περιβαλλοντικών χρονοσειρών, προσφέροντας πολύτιμα εργαλεία για τη μελέτη και διαχείριση σπάνιων αλλά κρίσιμων φαινομένων.

Abstract

This thesis focuses on the forecasting of environmental time series using both traditional statistical models and modern deep learning techniques. The objective is the comparative evaluation of these methods in terms of their ability to capture the fundamental characteristics of time series (trend, seasonality, variability) as well as to predict extreme events, which are of critical importance for environmental applications. To this end, three different datasets were employed: maximum monthly temperatures in Hong Kong, monthly seismic intensities in California, and monthly rainfall in Sydney.

Within the scope of this study, traditional models (ARIMA, SARIMA), neural networks (CNN, GRU), and more specialized approaches (DAN, Reweight-EVT, Reweight-META) were applied. The performance of the models was assessed using error metrics (RMSE, MAE) as well as through qualitative analysis of the predictions. The results showed that linear models perform adequately in series with strong seasonality but fall short in datasets with high variability and extreme values. Neural networks proved superior in capturing non-linear patterns, with CNNs providing better accuracy in peak values and GRUs offering more stable forecasts. The specialized models further improved performance, with Reweight-META demonstrating the most adaptive behavior in predicting extreme events.

Overall, the study highlights that the integration of deep learning techniques, and particularly reweighting-based methods, can enhance the accuracy and practical utility of environmental time series forecasting models, offering valuable tools for the study and management of rare but critical phenomena.

Ευχαριστίες

Θα ήθελα να ευχαριστήσω θερμά τον καθηγητή κ. Μιχαήλ Φιλιππάκη του τμήματος Ψηφιακών Συστημάτων του Πανεπιστημίου Πειραιώς, τόσο για την επίβλεψη και την καθοδήγηση που μου παρείχε καθόλη την διάρκεια εκπόνησης της διπλωματικής εργασίας, όσο και για τη κατανόηση και την πολύτιμη βοήθεια του. Επίσης θα ήθελα να ευχαριστήσω την οικογένεια μου για την αμέριστη συμπαράσταση και στήριξη τους.

Περίληψη.....	2
Abstract.....	3
Ευχαριστίες.....	4
Κεφάλαιο 1: Εισαγωγή.....	7
Κεφάλαιο 2: Χρονοσειρές.....	10
2.1 Συνιστώσες Χρονοσειρών.....	11
2.1.1 Το προσθετικό μοντέλο.....	14
2.1.2 Το πολλαπλασιαστικό μοντέλο.....	15
2.2 Ακραίες Τιμές.....	15
2.3 Χαρακτηριστικά Χρονοσειρών.....	16
2.3.1 Στασιμότητα.....	17
2.3.2 Αιτιοκρατία και Στοχαστικότητα.....	18
2.3.3 Γραμμικότητα και Μη-Γραμμικότητα.....	19
2.4 Μετρικές Αξιολόγησης Χρονοσειρών.....	19
2.4.1 RMSE.....	19
2.4.2 MAE.....	20
Κεφάλαιο 3: Γραμμικά Μοντέλα Πρόβλεψης.....	21
3.1 Αυτοπαλίνδρομο Μοντέλο (Autoregressive Model - AR).....	21
3.2 Μοντέλο Κινούμενου Μέσου (Moving Average Model - MA).....	22
3.3 Μοντέλο Αυτοπαλίνδρου Κινούμενου Μέσου (AutoRegressive Moving Average Model - ARMA).....	23
3.4 Ολοκληρωμένο Μοντέλο Αυτοπαλίνδρου Κινούμενου Μέσου (AutoRegressive Integrated Moving Average Model - ARIMA).....	24
3.5 Εποχικό Ολοκληρωμένο Μοντέλο Αυτοπαλίνδρου Κινούμενου Μέσου (AutoRegressive Integrated Moving Average Model - SARIMA).....	25
3.6 Επιλογή Τάξης Μοντέλου - Κριτήριο Πληροφορίας του Akaike (AIC).....	26
3.7 Γραμμικά Μοντέλα Πρόβλεψης σε Χρονοσειρές.....	27
Κεφάλαιο 4: Μηχανική Μάθηση - Βαθιά Μάθηση.....	29
4.1 Μηχανική Μάθηση.....	29
4.1.1 Εποπτευόμενη Μάθηση.....	30
4.2 Βαθιά Μάθηση - Τεχνητά Νευρωνικά Δίκτυα.....	32
4.2.1 Μονο-επίπεδα Νευρωνικά Δίκτυα (Single-layer Perceptrons).....	34
4.2.2 Πολυ-επίπεδα Νευρωνικά Δίκτυα (Multi-layer Perceptrons).....	37
4.2.3 Convolutional Neural Networks (CNNs).....	38
4.2.4 Long-Short Term Memory Neural Networks (LSTMNs).....	39
4.2.5 Gated Recurrent Units (GRUs).....	43
4.3 Μοντέλα Βαθιάς Μάθησης στην Πρόβλεψη Χρονοσειρών.....	45
4.3.1 Μοντέλα Reweight_EVT και Reweight_META.....	48
4.3.2 Μοντέλο DAN (Distance-weighted Auto-regularized Neural network).....	51
Κεφάλαιο 5: Πειραματικό Μέρος.....	53

5.1 Δεδομένα.....	54
5.1.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ.....	54
5.1.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια.....	56
5.1.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ.....	59
5.2 Πειράματα - Αποτελέσματα.....	61
5.2.1 ARIMA.....	62
5.2.1.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ.....	62
5.2.1.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια.....	63
5.2.1.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ.....	65
5.2.2 SARIMA.....	67
5.2.2.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ.....	67
5.2.2.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια.....	69
5.2.2.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ.....	71
5.2.3 CNN.....	73
5.2.3.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ.....	75
5.2.3.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια.....	77
5.2.3.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ.....	80
5.2.4 GRU.....	83
5.2.4.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ.....	84
5.2.4.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια.....	88
5.2.4.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ.....	91
5.2.5 DAN.....	95
5.2.5.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ.....	96
5.2.5.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια.....	99
5.2.5.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ.....	102
5.2.6 Reweight-EVT.....	105
5.2.6.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ.....	107
5.2.6.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια.....	111
5.2.6.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ.....	115
5.2.7 Reweight-META.....	120
5.2.7.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ.....	121
5.2.7.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια.....	126
5.2.7.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ.....	132
Κεφάλαιο 6: Συμπεράσματα.....	140
Αναφορές.....	143

Κεφάλαιο 1: Εισαγωγή

Η πρόβλεψη χρονοσειρών αποτελεί έναν από τους σημαντικότερους τομείς της επιστήμης των δεδομένων, με εφαρμογές που εκτείνονται από την οικονομία και την υγεία μέχρι τις περιβαλλοντικές επιστήμες και την κλιματική έρευνα. Η κατανόηση και η ακριβής εκτίμηση μελλοντικών τιμών είναι κρίσιμη τόσο για την επιστημονική έρευνα όσο και για τη λήψη αποφάσεων σε πραγματικές συνθήκες. Τα περιβαλλοντικά δεδομένα, όπως η θερμοκρασία, οι βροχοπτώσεις και η σεισμική δραστηριότητα, παρουσιάζουν ιδιαίτερο ενδιαφέρον, καθώς συχνά χαρακτηρίζονται από έντονη εποχικότητα, υψηλή μεταβλητότητα και την παρουσία σπάνιων αλλά σημαντικών ακραίων γεγονότων.

Παραδοσιακές στατιστικές μέθοδοι, όπως τα μοντέλα ARIMA και SARIMA, έχουν χρησιμοποιηθεί εκτενώς για την πρόβλεψη χρονοσειρών και έχουν αποδείξει την αποτελεσματικότητά τους σε δεδομένα με σταθερά και επαναλαμβανόμενα μοτίβα. Ωστόσο, παρουσιάζουν περιορισμούς στην αποτύπωση πολύπλοκων μη γραμμικών σχέσεων, καθώς και στην πρόβλεψη ακραίων τιμών που παρεκκλίνουν από τα συνήθη πρότυπα.

Τα ακραία φαινόμενα π.χ. καταιγίδες, πλημμύρες, θερμοκρασίες στη μετεωρολογία, ισχυροί σεισμοί στη σεισμολογία, αιχμές ζήτησης στην ενέργεια, είναι σπάνια αλλά με δυσανάλογα μεγάλο κόστος για ανθρώπινες ζωές, υποδομές και οικονομία. Η έγκαιρη και αξιόπιστη πρόβλεψή τους επιτρέπει προληπτικά μέτρα, βελτιστοποίηση πόρων και ανθεκτικό σχεδιασμό. Επειδή βρίσκονται στις ουρές των κατανομών (λίγα δείγματα, υψηλή αβεβαιότητα), απαιτούν εξειδικευμένες μεθόδους μάθησης που δίνουν έμφαση στα άκρα και όχι μόνο στη μέση συμπεριφορά των δεδομένων.

Τα τελευταία χρόνια, η ραγδαία εξέλιξη των τεχνικών βαθιάς μάθησης έχει ανοίξει νέες προοπτικές στην πρόβλεψη χρονοσειρών. Μοντέλα όπως τα Συνελικτικά Νευρωνικά Δίκτυα (CNN) και οι Μονάδες Αναδρομικών Δικτύων με Πύλες (GRU) έχουν επιδείξει σημαντική ικανότητα στην ανίχνευση πολύπλοκων μοτίβων και στη σύλληψη τόσο τοπικών όσο και μακροπρόθεσμων εξαρτήσεων. Παράλληλα, πιο πρόσφατες προσεγγίσεις όπως το DAN (Distance-weighted Auto-regularized Neural Network) και οι μέθοδοι Reweight EVT και Reweight META στοχεύουν στη βελτίωση της απόδοσης σε σπάνια και ακραία γεγονότα, αξιοποιώντας τεχνικές αναπροσδιορισμού βαρών και θεωρίας ακραίων τιμών.

Η παρούσα διπλωματική εργασία εστιάζει στη μελέτη και σύγκριση των παραπάνω μοντέλων για την πρόβλεψη τριών διαφορετικών συνόλων περιβαλλοντικών δεδομένων:

1. Μέγιστες μηνιαίες θερμοκρασίες στην περιοχή του Χονγκ Κονγκ.
2. Μηνιαίες μέγιστες σεισμικές εντάσεις στην περιοχή της Καλιφόρνια.
3. Μηνιαία ύψη βροχόπτωσης στο Σίδνεϊ (σταθμός Observatory Hill).

Κεντρικός στόχος της εργασίας είναι η συγκριτική αξιολόγηση παραδοσιακών και σύγχρονων μεθόδων πρόβλεψης, με έμφαση στην ικανότητά τους να αποτυπώνουν τα ιδιαίτερα χαρακτηριστικά περιβαλλοντικών χρονοσειρών και να προβλέπουν με ακρίβεια τόσο τις τυπικές όσο και τις ακραίες τιμές, οι οποίες έχουν κρίσιμη σημασία για τις περιβαλλοντικές εφαρμογές. Η αξιολόγηση των μοντέλων πραγματοποιείται με τη χρήση καθιερωμένων μετρικών σφάλματος (RMSE, MAE) αλλά και μέσω ποιοτικής ανάλυσης της προσαρμογής τους στα δεδομένα, ώστε να εκτιμηθεί όχι μόνο η αριθμητική ακρίβεια αλλά και η ικανότητα των μοντέλων να συλλαμβάνουν τις δυναμικές των σειρών.

Με τον τρόπο αυτό, η εργασία φιλοδοξεί να αναδείξει τα πλεονεκτήματα και τους περιορισμούς κάθε μεθόδου, παρέχοντας μια ολοκληρωμένη εικόνα για τη δυνατότητα αξιοποίησης των τεχνικών βαθιάς μάθησης στην πρόβλεψη περιβαλλοντικών χρονοσειρών και ειδικά στη δύσκολη περίπτωση πρόβλεψης ακραίων γεγονότων.

Η εργασία οργανώνεται σε έξι κεφάλαια. Στο Κεφάλαιο 2 παρουσιάζεται το θεωρητικό υπόβαθρο που αφορά τις χρονοσειρές, τις βασικές τους συνιστώσες (τάση, εποχικότητα, θόρυβος) καθώς και τα κύρια χαρακτηριστικά που τις καθορίζουν. Επίσης περιγράφονται οι μετρικές αξιολόγησης που χρησιμοποιούνται για την εκτίμηση της απόδοσης των μοντέλων πρόβλεψης χρονοσειρών (RMSE, MAE).

Στο Κεφάλαιο 3 αναλύονται οι αρχές των κλασικών γραμμικών μοντέλων πρόβλεψης, όπως τα AR, MA, ARIMA και SARIMA και παρουσιάζεται το κριτήριο πληροφορίας του Akaike (AIC) ως βασικό εργαλείο επιλογής τάξης μοντέλου.

Το Κεφάλαιο 3 εισάγει τις βασικές έννοιες της βαθιάς μάθησης και τις αρχές λειτουργίας των νευρωνικών δικτύων που χρησιμοποιούνται για την πρόβλεψη χρονοσειρών, με ιδιαίτερη έμφαση στα μοντέλα που εφαρμόζονται στο πλαίσιο της παρούσας μελέτης.

Το Κεφάλαιο 4 αποτελεί το πειραματικό μέρος της εργασίας. Σε αυτό παρουσιάζονται τα σύνολα δεδομένων που χρησιμοποιήθηκαν, η διαδικασία προεπεξεργασίας, οι παράμετροι των μοντέλων, καθώς και τα αποτελέσματα των πειραμάτων. Επιπλέον, γίνεται σχολιασμός και συγκριτική ανάλυση των αποτελεσμάτων μεταξύ των διαφορετικών μεθόδων πρόβλεψης.

Τέλος, στο Κεφάλαιο 5 συνοψίζονται τα βασικά συμπεράσματα της εργασίας και διατυπώνονται προτάσεις για πιθανές μελλοντικές κατευθύνσεις έρευνας και βελτίωσης.

Κεφάλαιο 2: Χρονοσειρές

Οι χρονοσειρές (time series) είναι ακολουθίες δεδομένων που παρατηρούνται σε διαδοχικά συνήθως ίσα μεταξύ τους χρονικά διαστήματα (π.χ., ημερήσια, εβδομαδιαία, μηνιαία, ετήσια). Τα δεδομένα αυτά αποτυπώνουν την εξέλιξη μιας μεταβλητής στο χρόνο και χρησιμοποιούνται για την κατανόηση μοτίβων, την αναγνώριση τάσεων, την ανάλυση εποχικότητας και την πρόβλεψη μελλοντικών τιμών. Οι χρονοσειρές βρίσκουν εφαρμογή σε διάφορους τομείς, όπως η οικονομία (π.χ., τιμές μετοχών, ΑΕΠ), η μετεωρολογία (π.χ., θερμοκρασία, βροχόπτωση), η βιομηχανία (π.χ., ζήτηση προϊόντων), η σεισμολογία (π.χ. σεισμικά κύματα, σεισμική δραστηριότητα μιας περιοχής) και πολλές άλλες επιστήμες.

Στα μαθηματικά οι παρατηρήσεις μιας χρονοσειράς αποτελούν μια συνάρτηση $X_t, t \in T$ με τον δείκτη t στο σύνολο T που υποδηλώνει χρόνο και μπορούμε να θεωρήσουμε ότι $T = \mathbb{N} = \{0, 1, 2, \dots\}$ ή $\mathbb{Z} = \{\dots, -2, -1, 0, 1, 2, \dots\}$ όπου οι τυχαίες μεταβλητές $X_0, X_1, X_2, \dots$ αντιστοιχούν σε κάποια ισαπέχοντα χρονικά σημεία π.χ. $t_0, t_0 + h, t_0 + 2h, \dots$ για συγκεκριμένο $h > 0$ (Μπούτσικας, 2020).

Μπορούν να διακριθούν δύο τύποι χρονοσειρών ως προς την μορφή του συνόλου T , οι συνεχείς (continuous time series) και διακριτές (discrete time series). Συνεχείς είναι οι χρονοσειρές των οποίων παρατηρήσεις μπορούν να ληφθούν θεωρητικά συνεχώς και οποιαδήποτε χρονική στιγμή, δηλαδή όταν $T = [a, b]$, με $a, b \in \mathbb{R}$. Παράδειγμα φυσικού μεγέθους που μπορεί να δώσει συνεχείς χρονοσειρές είναι η θερμοκρασία, η οποία μεταβάλλεται συνεχώς και η μέτρηση της μπορεί να γίνει οποιαδήποτε στιγμή. Διακριτές ονομάζονται οι χρονοσειρές των οποίων οι παρατηρήσεις αναφέρονται σε συγκεκριμένα χρονικά διαστήματα, δηλαδή $T \in \mathbb{Z} = \{\dots, -2, -1, 0, 1, 2, \dots\}$. Παράδειγμα διακριτής χρονοσειράς θα μπορούσε να είναι η καταγραφή του μεγίστου ετήσιου σεισμικού μεγέθους σε μια περιοχή. Η τιμή των χρονικών διαστημάτων αυτών, που ονομάζονται δειγματοληψία, ορίζονται από τον αναλυτή ανάλογα με την εκάστοτε εφαρμογή και τις εκάστοτε ανάγκες.

Μια διαφορετική μέθοδος κατηγοριοποίησης βασίζεται στον αριθμό των μεταβλητών που υπόκεινται σε ανάλυση. Σύμφωνα με αυτή την προσέγγιση, οι αναλύσεις μπορούν να διακριθούν σε δύο κύριες κατηγορίες, τις μονοδιάστατες αναλύσεις (Univariate Analysis) όπου περιλαμβάνουν την εξέταση μιας μόνο μεταβλητής κάθε φορά, χωρίς να λαμβάνεται υπόψη η σχέση της με άλλες μεταβλητές και τις πολυδιάστατες αναλύσεις (Multivariate Analysis) που αφορούν τη μελέτη πολλαπλών μεταβλητών ταυτόχρονα, διερευνώντας τις μεταξύ τους σχέσεις και αλληλεπιδράσεις. Η επιλογή μεταξύ μονοδιάστατης ή

πολυδιάστατης ανάλυσης εξαρτάται από τη φύση των δεδομένων, τον σκοπό της μελέτης και τα επιθυμητά συμπεράσματα που επιδιώκεται να εξαχθούν.

Παράδειγμα μονοδιάστατης χρονοσειράς (Univariate Time Series) θα μπορούσε να είναι η καταγραφή των εδαφικών ταλαντώσεων στον χρόνο από έναν σειсмоγράφο ενώ παράδειγμα πολυδιάστατης χρονοσειράς (Multivariate Time Series) θα μπορούσε να είναι η ταυτοχρονή καταγραφή της θερμοκρασίας του αέρα, της σχετικής υγρασίας, της ταχύτητας του ανέμου και της ηλιοφάνειας για την πρόβλεψη πιθανότητας εκδήλωσης πυρκαγιάς σε μια περιοχή.

Όταν ένα φαινόμενο θα μπορούσε να καταγράφεται συνεχώς, αλλά η δειγματοληψία του πραγματοποιείται σε διακριτές χρονικές στιγμές (π.χ. θερμοκρασία), τότε η αντίστοιχη χρονοσειρά χαρακτηρίζεται ως στιγμιαία καταγεγραμμένη διακριτή χρονοσειρά. Αντίθετα, όταν η μέτρηση του φαινομένου δεν είναι εφικτή για κάθε χρονική στιγμή, καθώς προκύπτει από το αθροιστικό σύνολο μιας ποσότητας σε μια χρονική περίοδο (όπως οι εκπομπές διοξειδίου του άνθρακα σε μια περιοχή), η χρονοσειρά αυτή ονομάζεται συσσωρευμένη διακριτή χρονοσειρά.

2.1 Συνιστώσες Χρονοσειρών


Για την καλύτερη κατανόηση και μοντελοποίηση των χρονοσειρών, αυτές διαχωρίζονται σε επιμέρους συνιστώσες που αποτελούν τα βασικά δομικά στοιχεία των χρονοσειρών και αντανακλούν διαφορετικές πτυχές της συμπεριφοράς τους περιγράφουν τις μεταβολές και την εξέλιξη της εξεταζόμενης τιμής.

Οι κύριες συνιστώσες μιας χρονοσειράς είναι:

1. Η Τάση (Trend): Εκφράζει τη γενική κατεύθυνση των δεδομένων της χρονοσειράς μακροπρόθεσμα. Η τάση μπορεί να είναι ανοδική (όταν οι τιμές αυξάνονται με την πάροδο του χρόνου, π.χ. η παγκόσμια θερμοκρασία λόγω κλιματικής αλλαγής) καθοδική (όταν οι τιμές μειώνονται, π.χ. η μείωση του πληθυσμού μιας απειλούμενης ζωικής κοινότητας) ή σταθερή (όταν δεν υπάρχει σαφής μεταβολή σε βάθος χρόνου). Η τάση μπορεί να εντοπιστεί μέσω στατιστικών μεθόδων, όπως οι κινητοί μέσοι όροι (moving averages) και η παλινδρόμηση (regression analysis).
2. Η Εποχικότητα (Seasonality): Η εποχικότητα αναφέρεται σε μοτίβα που επαναλαμβάνονται σε τακτά χρονικά διαστήματα λόγω περιοδικών επιδράσεων και εποχικών παραγόντων. Παραδείγματα εποχικότητας περιλαμβάνουν οι ετήσιες διακυμάνσεις της βροχόπτωσης σε μια περιοχή ή η ηλιοφάνεια σε μια περιοχή κατά τη διάρκεια του έτους. Η εποχικότητα συνήθως έχει σταθερή περίοδο (π.χ. ημερήσια, μηνιαία, ετήσια), αλλά μπορεί να επηρεάζεται από εξωτερικούς παράγοντες.

3. Κυκλικότητα (Cyclicality): Η κυκλικότητα αναφέρεται σε μεγάλες διακυμάνσεις που δεν εμφανίζονται με σταθερή περιοδικότητα, αλλά ακολουθούν οικονομικούς, κοινωνικούς ή φυσικούς κύκλους. Παραδείγματα κυκλικών μοτίβων περιλαμβάνουν οικονομικούς κύκλους ύφεσης και ανάπτυξης, μακροχρόνιες αλλαγές στο κλίμα (π.χ. φαινόμενο El Niño και La Niña) ή μεταβολές στη σεισμική δραστηριότητα λόγω συσσωρευμένης τάσης στις τεκτονικές πλάκες. Οι κυκλικές συνιστώσες είναι πιο δύσκολο να αναγνωριστούν σε σύγκριση με την εποχικότητα, καθώς η περίοδός τους δεν είναι σταθερή.
4. Η Ακανόνιστες Διακυμάνσεις ή Θόρυβος (Irregular Component or Noise): Η τυχαία συνιστώσα αφορά μη προβλέψιμες και μη συστηματικές διακυμάνσεις στη χρονοσειρά, οι οποίες μπορεί να προκύπτουν από εξωτερικούς παράγοντες ή τυχαία γεγονότα. Παραδείγματα περιλαμβάνουν τυχαία σφάλματα στη μέτρηση αισθητήρων, ακραία γεγονότα, όπως π.χ. η απότομη κατάρρευση χρηματιστηρίων. Η ακανόνιστη διακύμανση δεν ακολουθεί κάποιο μοτίβο και συνήθως αντιμετωπίζεται με στατιστικά φίλτρα ή μεθόδους εξομάλυνσης (smoothing techniques).

Ως παράδειγμα της παρουσίας των συνιστωσών χρονοσειρών, το παρακάτω σχήμα δείχνει τέσσερα παραδείγματα χρονοσειρών. Η πάνω αριστερή χρονοσειρά δείχνει τη ζήτηση ηλεκτρικής ενέργειας μισής ώρας σε μεγαβάτ στην Αγγλία και την Ουαλία από τις 5 έως τις 10 Ιουνίου 2000. Η ζήτηση ηλεκτρικής ενέργειας παρουσιάζει έντονη εποχικότητα και καθόλου τάση ή κυκλικότητα (Bee & Bianconcini, 2016). Η χρονοσειρά στην πάνω δεξιά γωνία αντικατοπτρίζουν τους ετήσιους αριθμούς παγίδων λύγκας από το 1821 έως το 1934 στον Καναδά. Αν και ο πληθυσμός του λύγκα φαίνεται να είναι εποχιακός, αυτή η χρονοσειρά είναι κυκλική καθώς το πλάτος και το μέγεθος των κορυφών ποικίλλουν με την πάροδο του χρόνου. Η χρονοσειρά στην κάτω αριστερή γωνία αντιπροσωπεύει τις μηνιαίες ατμοσφαιρικές συγκεντρώσεις CO₂ μέρη ανά εκατομμύριο από το 1959 έως το 1997. Οι συγκεντρώσεις CO₂ παρουσιάζουν τόσο ισχυρή τάση όσο και εποχικότητα. Η κάτω δεξιά χρονοσειρά απεικονίζει τις μεταβολές των τιμών κλεισίματος των μετοχών της GOOGLE από το χρηματιστήριο NASDAQ από τις 26 Φεβρουαρίου έως τις 22 Δεκεμβρίου 2013 και σε αντίθεση με τις άλλες χρονοσειρές, αυτή η χρονοσειρά είναι ακανόνιστη (έχει θόρυβο) και δεν παρουσιάζει τάση, εποχιακή, ούτε κυκλική συνιστώσα.



Εικόνα 1: Παραδείγματα χρονοσειρών με διάφορες συνιστώσες (Bee & Bianconcini, 2016).

Η ανάλυση των συνιστωσών μιας χρονοσειράς επιτρέπει την καλύτερη κατανόηση της συμπεριφοράς των δεδομένων και τη βελτίωση της πρόβλεψης μελλοντικών τιμών. Για τις ανάγκες της ανάλυσης μιας χρονοσειράς μπορούν να δημιουργηθούν γραφικές απεικονίσεις καθώς και να υπολογιστούν χρήσιμα στατιστικά μεγέθη. Με τη χρήση τεχνικών αποσύνθεσης (decomposition techniques), όπως η μέθοδος του προσθετικού μοντέλου (Additive Model) (όταν οι συνιστώσες έχουν σταθερό μέγεθος) και του πολλαπλασιαστικού μοντέλου (Multiplicative Model) (όταν οι διακυμάνσεις είναι σχετικές ως προς το μέγεθος της χρονοσειράς), μπορούμε να αναλύσουμε τη δομή των δεδομένων και να εντοπίσουμε σημαντικά μοτίβα για καλύτερη λήψη αποφάσεων. Ουσιαστικά μέσω της διαδικασίας της αποσύνθεσης, η χρονοσειρά αποσυντίθεται στα βασικά της στοιχεία (τάση, κυκλικότητα, εποχικότητα, θόρυβος).


2.1.1 Το προσθετικό μοντέλο

Το προσθετικό μοντέλο χρησιμοποιείται για την ανάλυση εάν το μέγεθος των εποχιακών αυξομειώσεων ή της διακύμανσης γύρω από την τάση-κυκλικότητα, δεν μεταβάλλεται ανάλογα με το επίπεδο των χρονοσειρών (Hyndman & Athanasopoulos, 2022).

το προσθετικό μοντέλο μπορεί να αναπαρασταθεί ως,

$$y_t = S_t + T_t + I_t, \quad (2.1)$$

όπου y_t είναι τα δεδομένα, S_t είναι η συνιστώσα της εποχικότητας, T_t είναι η συνιστώσα της τάσης-κυκλικότητας και I_t η συνιστώσα των υπολοίπων, όλα σε μια χρονική περίοδο t .



Εικόνα 2: Γραφήματα αποσύνθεσης για μια συγκεκριμένη χρονοσειρά (Bauer, 2021).

2.1.2 Το πολλαπλασιαστικό μοντέλο

Όταν η διακύμανση στο μοτίβο της εποχικότητας, ή όταν η διακύμανση γύρω από την τάση-κυκλικότητα, φαίνεται να είναι ανάλογη με το επίπεδο των χρονοσειρών, τότε η πολλαπλασιαστική ανάλυση είναι καταλληλότερη. Η πολλαπλασιαστική ανάλυση συνηθίζεται σε οικονομικές χρονοσειρές (Hyndman & Athanasopoulos, 2022)

το πολλαπλασιαστικό μοντέλο μπορεί να αναπαρασταθεί ως,

$$y_t = S_t \times T_t \times I_t, \quad (2.2)$$

Μια άλλη προσέγγιση αντί της πολλαπλασιαστικής ανάλυσης είναι ο εκ των προτέρων μετασχηματισμός των δεδομένων, ώστε η διακύμανση της χρονοσειράς να εμφανίζεται σταθερή με την πάροδο του χρόνου. Στη συνέχεια, μπορεί να εφαρμοστεί η προσθετική ανάλυση. Ο λογαριθμικός μετασχηματισμός, στην ουσία, αντιστοιχεί στην εφαρμογή μιας πολλαπλασιαστικής ανάλυσης διότι

$$y_t = S_t \times T_t \times I_t \text{ ισοδυναμεί με } \log y_t = \log S_t + \log T_t + \log I_t \quad (2.3)$$

2.2 Ακραίες Τιμές

Στις χρονοσειρές, οι ακραίες τιμές (outliers) είναι παρατηρήσεις που αποκλίνουν σημαντικά από την υπόλοιπη κατανομή των δεδομένων. Αυτές μπορεί να οφείλονται σε σπάνια γεγονότα, σφάλματα καταγραφής ή αλλαγές στις υποκείμενες τάσεις της σειράς. Υπάρχουν διάφοροι τύποι ακραίων τιμών, όπως οι μεμονωμένες ακραίες τιμές (point outliers) όπου μια μεμονωμένη καταγραφή μπορεί να θεωρηθεί ανώμαλη σε σχέση με τα υπόλοιπα δεδομένα, οι ακραίες τιμές με βάση το πλαίσιο (contextual Outliers) όπου μια καταγραφή θεωρείται ανώμαλη με βάση το χρονικό πλαίσιο στο οποίο εμφανίζεται, δηλαδή σε διαφορετική χρονική στιγμή θα μπορούσε να είναι και αναμενόμενη και τέλος οι συλλογικές ακραίες τιμές (collective outliers), όπου συλλογή καταγραφών είναι ανώμαλη σε σχέση με το υπόλοιπο σύνολο δεδομένων. Οι συλλογικές ακραίες τιμές μπορεί να μην είναι από μόνες τους ακραίες τιμές αλλά η εμφάνισή τους ως σύνολο αποτελεί μια ανωμαλία. Οι συλλογικές ακραίες τιμές μπορούν να εμφανιστούν μόνο σε σύνολα δεδομένων των οποίων οι

καταγραφές είναι σχετιζόμενες (Divya & Babu, 2016). Ο εντοπισμός και η διαχείριση αυτών είναι κρίσιμοι για την ακριβή μοντελοποίηση και πρόβλεψη της χρονοσειράς.

Η ανίχνευση ακραίων τιμών μπορεί να γίνει με διάφορες μεθόδους, όπως οι στατιστικές προσεγγίσεις (π.χ. Z-score, IQR), η Ανάλυση Συνιστωσών (PCA) ή τα μοντέλα μηχανικής μάθησης (π.χ. Isolation Forest, DBSCAN). Στα μοντέλα ARIMA και άλλες μεθόδους χρονοσειρών, οι ακραίες τιμές μπορεί να προκαλέσουν αστάθεια στις παραμέτρους και να επηρεάσουν τις μελλοντικές προβλέψεις. Για αυτόν τον λόγο, χρησιμοποιούνται τεχνικές όπως η αντικατάσταση των ακραίων τιμών με στατιστικά πιο συνεπείς τιμές, η χρήση ανθεκτικών μοντέλων ή η πλήρης αφαίρεση αυτών των σημείων εφόσον θεωρούνται μη αντιπροσωπευτικά.

Οι ακραίες τιμές σε χρονοσειρές αποτελούν παρατηρήσεις που μπορούν να έχουν δύο διαφορετικές έννοιες και η σημασιολογική διάκριση μεταξύ τους βασίζεται κυρίως στο ενδιαφέρον του αναλυτή ή στο συγκεκριμένο σενάριο που εξετάζεται. Αυτές οι παρατηρήσεις σχετίζονται με τον θόρυβο, λανθασμένα ή ανεπιθύμητα δεδομένα, τα οποία από μόνα τους δεν είναι ενδιαφέρον για τον αναλυτή (Aggarwal, 2016). Σε αυτές τις περιπτώσεις, οι αποκλίσεις πρέπει να διαγραφούν ή να διορθωθούν για να βελτιωθεί η ποιότητα των δεδομένων και να δημιουργηθεί ένα καθαρότερο σύνολο δεδομένων που μπορεί να χρησιμοποιηθεί από άλλους αλγόριθμους εξόρυξης δεδομένων. Για παράδειγμα, τα σφάλματα μετάδοσης αισθητήρων εξαλείφονται για να ληφθούν ακριβέστερες προβλέψεις επειδή ο κύριος στόχος είναι να γίνουν προβλέψεις. Παρ' όλα αυτά, τα τελευταία χρόνια και, ειδικά στον τομέα των δεδομένων χρονοσειρών, πολλοί ερευνητές έχουν ως στόχο να εντοπίσουν και να αναλύσουν ασυνήθιστα αλλά ενδιαφέροντα φαινόμενα. Η ανίχνευση απάτης είναι ένα παράδειγμα, επειδή ο κύριος στόχος είναι να ανιχνευθεί και να αναλυθεί η ίδια η ακραία τιμή (Aggarwal, 2016).


2.3 Χαρακτηριστικά Χρονοσειρών

Η ανάλυση χρονοσειρών επικεντρώνεται σε δύο κύριες προκλήσεις: την κατανόηση του μηχανισμού που δημιουργεί τη χρονοσειρά και την πρόβλεψη των μελλοντικών τιμών της παρατηρούμενης ποσότητας. Για να είναι ουσιαστική η ανάλυση, πρέπει πρώτα να αποκλείσουμε την πιθανότητα ότι οι διακυμάνσεις στις τιμές είναι τυχαίες, δηλαδή ότι το υπό εξέταση σύστημα αντιστοιχεί σε λευκό θόρυβο. Αν οι τιμές της χρονοσειράς δεν είναι ανεξάρτητες μεταξύ τους, τότε μπορούμε να εξάγουμε πληροφορία εντοπίζοντας πιθανά μοτίβα στα δεδομένα. Επομένως, πριν εφαρμόσουμε ένα μοντέλο στη χρονοσειρά, είναι απαραίτητο να μελετήσουμε κάποια θεμελιώδη χαρακτηριστικά: αν η σειρά είναι στάσιμη, αν διέπεται από αιτιοκρατικούς ή στοχαστικούς κανόνες και αν παρουσιάζει γραμμική ή μη γραμμική συμπεριφορά.

2.3.1 Στασιμότητα

Η στασιμότητα (stationarity) είναι ένα από τα πιο βασικά χαρακτηριστικά που πρέπει να εξεταστούν σε μια χρονοσειρά πριν από την ανάλυση ή τη μοντελοποίηση της. Μια χρονοσειρά θεωρείται στάσιμη όταν οι στατιστικές της ιδιότητες (όπως η μέση τιμή, η διακύμανση και η αυτοσυσχέτιση) παραμένουν σταθερές στο χρόνο. Αυτό σημαίνει ότι η χρονοσειρά δεν παρουσιάζει τάση, εποχικότητα ή άλλες δομές που μεταβάλλονται με την πάροδο του χρόνου (Rana et al., 2023). Οι χρονοσειρές που είναι στάσιμες μπορούν να μοντελοποιηθούν και να προβλεφθούν πιο εύκολα, καθώς η συμπεριφορά τους παραμένει σταθερή στον χρόνο, επιτρέποντας την αποδοτική χρήση στατιστικών μεθόδων ανάλυσης.

Για να προσδιοριστεί αν μια χρονοσειρά είναι στάσιμη ή όχι, μπορεί να χρησιμοποιηθεί μια διαγραμματική απεικόνιση, ή η ανάλυση των διαγραμμάτων αυτοσυσχέτισης. Στην περίπτωση μιας στάσιμης χρονοσειράς, οι τιμές της αυτοσυσχέτισης μειώνονται γρήγορα προς το μηδέν καθώς αυξάνονται τα χρονικά διαστήματα (lags), ενώ σε μια μη στάσιμη χρονοσειρά η μείωση αυτή είναι πιο αργή.



Εικόνα 3: Πάνω φαίνεται η μη-στάσιμη χρονοσειρά και το αντίστοιχο διάγραμμα αυτοσυσχέτισης. Κάτω δίνονται τα αντίστοιχα διαγράμματα όταν η χρονοσειρά έχει γίνει στάσιμη εφαρμόζοντας τις πρώτες διαφορές (Rasmussen et al., 2018).

Η μη στασιμότητα αποτελεί μία από τις βασικές προκλήσεις στην ανάλυση χρονοσειρών και πρέπει να αντιμετωπιστεί άμεσα. Οι περισσότερες χρονοσειρές παρουσιάζουν μη στασιμότητα, καθώς περιλαμβάνουν τάσεις, εποχικές διακυμάνσεις και κυκλικά μοτίβα. Αυτή η ιδιότητα καθιστά πιο περίπλοκη τόσο την ανάλυσή τους όσο και τη διαδικασία πρόβλεψης. Παρόλα αυτά, με τη χρήση κατάλληλων μαθηματικών εργαλείων και μεθόδων, μπορούν να υποστούν μετασχηματισμούς που τις καθιστούν στάσιμες, διευκολύνοντας έτσι την περαιτέρω μελέτη τους.

2.3.2 Αιτιοκρατία και Στοχαστικότητα

Στην ανάλυση χρονοσειρών, ένας βασικός διαχωρισμός αφορά το αν η χρονοσειρά είναι αιτιοκρατική ή στοχαστική. Αυτές οι δύο έννοιες περιγράφουν τον τρόπο με τον οποίο εξελίσσονται οι τιμές μιας χρονοσειράς. Μια χρονοσειρά είναι αιτιοκρατική όταν οι τιμές της καθορίζονται από μια συγκεκριμένη μαθηματική σχέση ή έναν γνωστό μηχανισμό, χωρίς την επίδραση τυχαίων παραγόντων ενώ μια χρονοσειρά είναι στοχαστική όταν η εξέλιξή της περιλαμβάνει ένα στοιχείο τυχαιότητας. Δηλαδή οι μελλοντικές της τιμές δεν καθορίζονται πλήρως από μια συγκεκριμένη μαθηματική σχέση, αλλά επηρεάζονται από τυχαίες διακυμάνσεις, καθιστώντας αδύνατη την πρόβλεψη μελλοντικών τιμών με απόλυτη βεβαιότητα. Στον πραγματικό κόσμο, σχεδόν όλες οι χρονοσειρές των μεγεθών παρουσιάζουν κάποιο ποσοστό θορύβου, συνεπώς μπορούν να θεωρηθούν όλες στοχαστικές.

Παράδειγμα αιτιοκρατικής χρονοσειράς είναι μια απλή αρμονική ταλάντωση, η οποία περιγράφεται με μια αναλυτική συνάρτηση, και η πρόβλεψη των μελλοντικών τιμών της είναι ακριβής. Αν υπάρχουν αιτιοκρατικά μοτίβα, όπως τάσεις ή περιοδικότητες, μπορούμε να τα αφαιρέσουμε για να εξετάσουμε το στοχαστικό μέρος της χρονοσειράς. Παράδειγμα στοχαστικής χρονοσειράς είναι οι θερμοκρασιακές διακυμάνσεις, η πρόβλεψη των οποίων είναι πιθανοτική και όχι σε απόλυτες τιμές. Οι στοχαστικές διαδικασίες αποτελούν τη βάση των περισσότερων μοντέλων πρόβλεψης χρονοσειρών, όπως τα ARIMA, GARCH και VAR.

2.3.3 Γραμμικότητα και Μη-Γραμμικότητα

Ένας ακόμα σημαντικός διαχωρισμός των χρονοσειρών αφορά το αν η σχέση μεταξύ των παρελθοντικών και των μελλοντικών τιμών είναι γραμμική ή μη-γραμμική. Αυτή η διάκριση επηρεάζει τη μοντελοποίηση και την πρόβλεψη των δεδομένων, καθώς τα γραμμικά και μη-γραμμικά μοντέλα έχουν διαφορετικές ιδιότητες και απαιτήσεις. Μια χρονοσειρά χαρακτηρίζεται ως γραμμική εάν οι τιμές της μπορούν να περιγραφούν ως μια γραμμική συνάρτηση των προηγούμενων τιμών της. Μια χρονοσειρά θεωρείται μη-γραμμική όταν η σχέση μεταξύ των προηγούμενων και των μελλοντικών τιμών δεν μπορεί να περιγραφεί με μια απλή γραμμική συνάρτηση. Αντίθετα, περιλαμβάνει πιο σύνθετες αλληλεπιδράσεις ή μη-γραμμικούς μετασχηματισμούς.

2.4 Μετρικές Αξιολόγησης Χρονοσειρών

Οι μετρικές αξιολόγησης που χρησιμοποιούνται στην πρόβλεψη χρονοσειρών διαδραματίζουν κρίσιμο ρόλο στην αντικειμενική σύγκριση και αξιολόγηση της απόδοσης των μοντέλων. Τα ξεχωριστά χαρακτηριστικά των δεδομένων χρονοσειρών απαιτούν τη χρήση διαφορετικών μετρικών για την πρόβλεψη χρονοσειρών. Κάθε μετρική αξιολογεί διαφορετικά χαρακτηριστικά του μοντέλου, συμβάλλοντας στην ολοκληρωμένη κατανόηση της απόδοσης του μοντέλου σε διάφορα σενάρια. Επίσης είναι απαραίτητο να εκτιμηθεί όχι μόνο το μέγεθος των σφαλμάτων αλλά και πόσο καλά το μοντέλο μαθαίνει τα χρονικά πρότυπα και τα διάφορα χαρακτηριστικά των δεδομένων χρονοσειρών (Kim et al., 2024).

2.4.1 RMSE

Η συνεχής και ακανόνιστη φύση των δεδομένων χρονοσειρών μπορεί να σημαίνει ότι τα μεγάλα σφάλματα μπορεί να εμφανιστούν σε ορισμένα σημεία και οι μετρικές όπως το ριζικό μέσο τετραγωνικό σφάλμα (Root Mean Squared Error - RMSE) είναι ευαίσθητα σε μεγάλα σφάλματα, επιτρέποντας την αξιολόγηση της ικανότητας του μοντέλου να χειρίζεται σημαντικά λάθη. Συνεπώς, το ριζικό μέσο τετραγωνικό σφάλμα δίνει μεγαλύτερο βάρος στα μεγαλύτερα σφάλματα. Η σχέση που δίνει την μετρική αυτή είναι η εξής:

$$\sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}, \quad (2.4)$$

Όπου, το y_t είναι η πραγματική τιμή, το $\hat{y}_t$ είναι η εκτιμώμενη τιμή (πρόβλεψη) στο σημείο δεδομένων και το n είναι ο συνολικός αριθμός σημείων δεδομένων.

2.4.2 MAE

Η μετρική MAE (Mean Absolute Error) είναι το μέσο τετράγωνο σφάλμα και μετρά τη μέση απόλυτη απόκλιση των τιμών πρόβλεψης από τα πραγματικά δεδομένα σε ολόκληρο το σύνολο των προβλέψεων, συνεπώς δεν λαμβάνει υπόψη την κατεύθυνση των αποκλίσεων. Η σχέση που δίνει την μετρική αυτή είναι η εξής:

$$\frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (2.5)$$

Και οι δύο μετρικές έχουν τις ίδιες μονάδες με τη μεταβλητή-στόχο (π.χ. °C, mm). Συνοψίζοντας, η MAE είναι η μέση απόλυτη απόσταση, η οποία τιμωρεί γραμμικά τα σφάλματα και είναι ανθεκτικότερη σε ακραίες τιμές ενώ η RMSE υψώνει τα σφάλματα στο τετράγωνο πριν τον μέσο και τη ρίζα και τιμωρεί πολύ πιο έντονα τα μεγάλα λάθη και είναι ευαίσθητη στις ακραίες τιμές (Hodson, (2022)).

Κεφάλαιο 3: Γραμμικά Μοντέλα Πρόβλεψης

Πριν από τη μηχανική μάθηση και τη βαθιά μάθηση, τα παραδοσιακά στατιστικά μοντέλα, τα οποία έθεσαν τα θεμέλια για την ανάλυση διαδοχικών δεδομένων, χρησιμοποιήθηκαν συνήθως για πρόβλεψη χρονοσειρών. Για την ανάλυση και την πρόβλεψη χρονοσειρών, δύο από τα πιο διαδεδομένα στατιστικά μοντέλα είναι το Autoregressive (AR - Αυτοπαλίνδρομο) και το Moving Average (MA - Κινητού Μέσου Όρου). Ο συνδυασμός αυτών των δύο προσεγγίσεων οδήγησε στη δημιουργία του Autoregressive Moving Average (ARMA) και της επεκτάσιμης εκδοχής του, Autoregressive Integrated Moving Average (ARIMA). Όταν τα δεδομένα παρουσιάζουν εποχιακή συμπεριφορά, χρησιμοποιείται μια τροποποιημένη εκδοχή του ARIMA, γνωστή ως Seasonal ARIMA (SARIMA).

Τα μοντέλα ARIMA και οι διάφορες παραλλαγές τους βασίζονται στη μεθοδολογία Box-Jenkins, η οποία έχει καθιερωθεί στην ανάλυση χρονοσειρών. Ο βασικός λόγος για τη δημοφιλία αυτών των μοντέλων είναι η απλότητά τους στην ερμηνεία και στην εφαρμογή. Ωστόσο, δεδομένου ότι είναι γραμμικά μοντέλα, παρουσιάζουν περιορισμούς στην πρόβλεψη μη γραμμικών χρονοσειρών, οι οποίες αποτελούν το μεγαλύτερο μέρος των πραγματικών δεδομένων (Kim et al., 2024).

Η εμφάνιση και εξέλιξη των Νευρωνικών Δικτύων και της Τεχνητής Νοημοσύνης έδωσε λύση σε αυτό το πρόβλημα. Χάρη στη μη γραμμική δομή τους, τα Νευρωνικά Δίκτυα μπορούν να ανιχνεύουν τόσο γραμμικές όσο και μη γραμμικές σχέσεις στα δεδομένα, επιτρέποντας πιο ακριβείς προβλέψεις. Έτσι, η χρήση τους γίνεται ολοένα και πιο διαδεδομένη στην ανάλυση χρονοσειρών, ξεπερνώντας τους περιορισμούς των κλασικών γραμμικών μοντέλων.

3.1 Αυτοπαλίνδρομο Μοντέλο (Autoregressive Model - AR)

Το αυτοπαλίνδρομο μοντέλο είναι ένα από τα βασικά γραμμικά μοντέλα χρονοσειρών που χρησιμοποιούνται για την ανάλυση και την πρόβλεψη δεδομένων χρονοσειρών. Αποτελεί μοντέλο παλινδρόμησης που εφαρμόζεται σε σειρές υστερήσεων (lag) που δημιουργείται χρησιμοποιώντας τις αρχικές χρονοσειρές. Στην περίπτωση των αυτοπαλινδρομων μοντέλων, η έξοδος είναι το μελλοντικό σημείο δεδομένων και μπορεί να εκφραστεί ως γραμμικός συνδυασμός των προηγούμενων p σημείων δεδομένων. Το p είναι το παράθυρο υστέρησης. Το αυτοπαλίνδρομο μοντέλο μπορεί να εκφραστεί ως η εξίσωση:

$$y_t = l + a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} + e \quad (3.1)$$

όπου, y_t είναι η τιμή της χρονοσειράς σε χρονική στιγμή t , το l είναι η σταθερή τιμή στο σύνολο δεδομένων και το e είναι ο θόρυβος. a είναι οι συντελεστές που πρέπει να μάθουν από τα δεδομένα και αντιπροσωπεύουν τα βάρη των τιμών με χρονική υστέρηση. Αυτό μπορεί να αναφέρεται ως ένα αυτοπαλινδρόμο μοντέλο με καθυστερήσεις p ή μοντέλο AR(p). Σε ένα μοντέλο AR(p), η σειρά lag είναι ένας νέος προγνωστικός παράγοντας που χρησιμοποιείται για να ταιριάζει με την εξαρτημένη μεταβλητή, η οποία εξακολουθεί να είναι η τιμή της αρχικής σειράς, Y_t (Kotu & Deshpande, 2019).

Για παράδειγμα, το πρώτης τάξης μοντέλο αυτοπαλινδρόμησης AR(1) γράφεται:

$$y_t = l + a_1 y_{t-1} + e \quad (3.2)$$

Το μοντέλο AR μπορεί να χρησιμοποιηθεί όταν η χρονοσειρά είναι στάσιμη, δηλαδή οι στατιστικές της ιδιότητες (μέσος όρος, διακύμανση, αυτοσυσχέτιση) δεν μεταβάλλονται με την πάροδο του χρόνου.

Ο προσδιορισμός της τάξης p ενός μοντέλου πραγματοποιείται μέσω των διαγραμμάτων αυτοσυσχέτισης (ACF) και μερικής αυτοσυσχέτισης (PACF). Στην περίπτωση ενός μοντέλου AR(p), η συνάρτηση αυτοσυσχέτισης (ACF) εμφανίζει σημαντική συσχέτιση έως την υστέρηση p και στη συνέχεια μειώνεται σταδιακά προς το μηδέν. Αντίστοιχα, η συνάρτηση μερικής αυτοσυσχέτισης (PACF) παρουσιάζει απότομη πτώση μετά την υστέρηση p , υποδεικνύοντας ότι μόνο οι πρώτες p υστερήσεις έχουν ουσιαστική επίδραση στην τρέχουσα τιμή της χρονοσειράς.

3.2 Μοντέλο Κινούμενου Μέσου (Moving Average Model - MA)

Εκτός από τη δημιουργία μιας παλινδρόμησης των πραγματικών προηγούμενων τιμών p όπως φαίνεται στην εξίσωση (1.4), μπορεί επίσης να δημιουργηθεί μια εξίσωση παλινδρόμησης που περιλαμβάνει σφάλματα πρόβλεψης των προηγούμενων δεδομένων και να το χρησιμοποιήσει για πρόβλεψη μελλοντικών τιμών (Kotu & Deshpande, 2019). Ένα μοντέλο κινητού μέσου τάξης q μπορεί να εκφραστεί ως η εξίσωση:

$$y_t = l + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (3.3)$$

όπου το e_t είναι το σφάλμα πρόβλεψης του σημείου δεδομένων t . Αυτό έχει νόημα για τα προηγούμενα σημεία δεδομένων, αλλά όχι για το σημείο δεδομένων t , επειδή εξακολουθεί να προβλέπεται. Ως εκ τούτου, το e_t θεωρείται λευκός θόρυβος και θ είναι οι συντελεστές που αντιπροσωπεύουν τα βάρη του παρελθοντικών όρων σφάλματος. Η εξίσωση παλινδρόμησης για το y_t μπορεί να γίνει κατανοητή ως ο σταθμισμένος (θ) κινούμενος μέσος όρος των παρελθόντων q σφαλμάτων πρόβλεψης. Αυτό ονομάζεται μοντέλο κινητού μέσου όρου με q lags ή αλλιώς MA(q). Για να είναι έγκυρο το μοντέλο MA, η χρονοσειρά πρέπει να είναι στάσιμη.

Για παράδειγμα, το πρώτης τάξης μοντέλο αυτοπαλινδρόμησης MA(1) γράφεται:

$$y_t = l + e_t + \theta_1 e_{t-1} \quad (3.4)$$

όπου η τιμή y_t είναι συνάρτηση του σταθερού όρου l , του τρέχοντος σφάλματος e_t , του σφάλματος της προηγούμενης περιόδου e_{t-1} και του συντελεστή θ_1 ο οποίος εκφράζει την ένταση της συσχέτισης και δείχνει πόσο (ισχύ) και πως (κατεύθυνση) επηρεάζει το παρελθοντικό σφάλμα e_{t-1} την τρέχουσα τιμή y_t .

3.3 Μοντέλο Αυτοπαλινδρόμου Κινούμενου Μέσου (AutoRegressive Moving Average Model - ARMA)

Τα μοντέλα αυτόματης κινητικής μέσης μέσης (ARMA) διαδραματίζουν βασικό ρόλο στη μοντελοποίηση των χρονοσειρών. Η γραμμική δομή των διαδικασιών ARMA οδηγεί επίσης σε μια σημαντική απλούστευση της γραμμικής πρόβλεψης. Σε σύγκριση με τα καθαρά μοντέλα αυτοπαλινδρόμησης (AR) ή κινούμενου μέσου όρου (MA), τα μοντέλα ARMA παρέχουν το πιο αποτελεσματικό γραμμικό μοντέλο στάσιμων χρονοσειρών, δεδομένου ότι είναι ικανά να μοντελοποιήσουν με τον ελάχιστο αριθμό παραμέτρων (Zhang & Moore, 2015).

Το μοντέλο ARMA ορίζεται από δύο παραμέτρους. το p που είναι η τάξη του αυτοπαλίνδρομου μέρους και το q είναι η τάξη του κινητού μέσου όρου. Το p αντιπροσωπεύει την τάξη του αυτοπαλίνδρομου μέρους και το q την τάξη του κινητού μέσου όρου. Το μοντέλο ARMA(p,q) μπορεί να μαθηματικά να εκφραστεί ως εξής:

$$y_t = l + a_1 y_{t-1} + \theta_1 e_{t-1} + a_2 y_{t-2} + \theta_2 e_{t-2} + \dots + a_p y_{t-p} + \theta_p e_{t-q} + e_t \quad (3.5)$$

όπου a_i και θ_i είναι οι συντελεστές του μοντέλου AR και MA αντίστοιχα.

Το αυτοπαλίνδρομο (AR) τμήμα του μοντέλου βασίζεται σε προηγούμενες τιμές της χρονοσειράς για να εκτιμήσει τις μελλοντικές τιμές, καταγράφοντας έτσι τη συσχέτιση μεταξύ της τρέχουσας και των παρελθοντικών τιμών.

Από την άλλη, το κινούμενου μέσου (MA) τμήμα χρησιμοποιεί προηγούμενα σφάλματα πρόβλεψης για την εκτίμηση μελλοντικών τιμών, λαμβάνοντας υπόψη τις τυχαίες διακυμάνσεις που επηρεάζουν τη χρονοσειρά.

Για να εφαρμοστεί το μοντέλο ARMA, η χρονοσειρά πρέπει να είναι στάσιμη.

3.4 Ολοκληρωμένο Μοντέλο Αυτοπαλίνδρομου Κινούμενου Μέσου (AutoRegressive Integrated Moving Average Model - ARIMA)

Το Ολοκληρωμένο Μοντέλο Αυτοπαλίνδρομου Κινούμενου Μέσου (ARIMA) είναι ένας συνδυασμός του διαφορικού αυτοπαλίνδρομου μοντέλου με το μοντέλο κινούμενου μέσου όρου. Μαθηματικά εκφράζεται ως εξής:

$$y'_t = l + a_1 y'_{t-1} + a_2 y'_{t-2} + \dots + a_p y'_{t-p} + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (3.6)$$

όπου οι παράγοντες πρόβλεψης είναι τα σημεία δεδομένων με υστέρηση p για το αυτοπαλίνδρομο τμήμα και τα σφάλματα υστέρηση q είναι για το τμήμα του κινούμενου μέσου όρου, τα οποία είναι όλα διαφορικά. Η πρόβλεψη είναι το διαφορικό y'_t , d -οστής τάξης. Αυτό είναι που ονομάζεται μοντέλο ARIMA(p, d, q). Αυτό που ουσιαστικά κάνει το μοντέλο ARIMA είναι ο υπολογισμός των συντελεστών a και θ για δεδομένα p, d, q από τα δεδομένα εκπαίδευσης της χρονοσειράς. Ο καθορισμός των κατάλληλων p, d, q μπορεί να

είναι δύσκολος (ένας βασικός περιορισμός), αλλά μπορεί κανείς να δοκιμάζει διαφορετικούς συνδυασμούς και να αξιολογήσει την απόδοση του μοντέλου. Μόλις οριστεί το μοντέλο ARIMA με τις τιμές των p , d , q , πρέπει να εκτιμηθούν οι συντελεστές της εξίσωσης. Ο πιο συνηθισμένος τρόπος εκτίμησης είναι μέσω της εκτίμησης της μέγιστης πιθανοφάνειας. Είναι παρόμοιο με την εκτίμησης ελαχίστων τετραγώνων για την εξίσωση παλινδρόμησης, μόνο που η εκτίμηση μέγιστης πιθανοφάνειας βρίσκει τους συντελεστές του μοντέλου με τέτοιο τρόπο ώστε να μεγιστοποιεί τις πιθανότητες εύρεσης των πραγματικών δεδομένων (Kotu & Deshpande, 2019).

Το τμήμα AR της ARIMA δείχνει ότι η χρονοσειρά παλινδρομείται με τα δικά της δεδομένα, δηλαδή υπάρχει εξαρτημένη σχέση μεταξύ μιας παρατήρησης και των προηγούμενων (ή αλλιώς καθυστερημένων) παρατηρήσεων της σειράς. Το τμήμα I της ARIMA δείχνει ότι οι τιμές των δεδομένων έχουν αντικατασταθεί με διαφορικές τιμές d τάξης για να ληφθούν στάσιμα δεδομένα, που είναι η απαίτηση της προσέγγισης μοντέλου ARIMA. Με άλλα λόγια, προκειμένου να γίνει στάσιμη η χρονοσειρά, γίνεται αφαίρεση μιας παρατήρησης από την προηγούμενη. Για παράδειγμα, η πρώτη τάξης διαφορά προκύπτει ως εξής: $y'_t = y_t - y_{t-1}$. Το τμήμα MA του ARIMA υποδεικνύει ότι το σφάλμα πρόβλεψης είναι ένας γραμμικός συνδυασμός παρελθοντικών αντίστοιχων σφαλμάτων (Kotu & Deshpande, 2019).

Το ARIMA είναι ένα γενικευμένο μοντέλο. Μερικά από τις ειδικές περιπτώσεις μοντέλου ARIMA είναι:

- ARIMA(0,1,0) εκφράζεται ως $y_t = y_{t-1} + e$. Είναι το μοντέλο *random walk* με σφάλμα, το οποίο ονομάζεται Τυχαίος Περίπατος (Random Walk Model).
- ARIMA(0,1,0) εκφράζεται ως $y_t = y_{t-1} + e + c$. Είναι ένα μοντέλο Τυχαίου Περίπατου με σταθερή τάση. Ονομάζεται Τυχαίος Περίπατος με Περιπλάνηση.
- ARIMA(0,0,0) εκφράζεται ως $y_t = e$ και ονομάζεται λευκός θόρυβος.
- ARIMA(p ,0,0) είναι το αυτοπαλίνδρομο μοντέλο.
- ARIMA(0,0, q) είναι το μοντέλο κινούμενου μέσου όρου.

3.5 Εποχικό Ολοκληρωμένο Μοντέλο Αυτοπαλίνδρουμου Κινούμενου Μέσου (AutoRegressive Integrated Moving Average Model - SARIMA)

Το SARIMA είναι ένα ισχυρό μοντέλο πρόβλεψης χρονοσειρών που χρησιμοποιείται εκτενώς σε διάφορους τομείς, συμπεριλαμβανομένης της πρόβλεψης του καιρού. Επεκτείνει

το παραδοσιακό μοντέλο ARIMA (αυτόματο ολοκληρωμένο κινητό μέσο όρο), ενσωματώνοντας την εποχικότητα και τις τάσεις (Kumari & Muthulakshmi, 2023).

Για την εκτίμηση του μοντέλου SARIMA, το πρώτο βήμα είναι να καθοριστούν οι τιμές των μη εποχικών παραμέτρων p , d και q όπως ακριβώς και τον μοντέλο ARIMA, όπου, p είναι η τάξη της αυτοπαλίνδρομης συνιστώσας (AR), d είναι ο αριθμός διαφοροποιήσεων για επίτευξη στασιμότητας και q είναι η τάξη του μοντέλου κινητού μέσου (MA).

Πέρα από αυτές, το SARIMA ενσωματώνει επιπλέον τέσσερις εποχικές παραμέτρους, που το καθιστούν ικανό να μοντελοποιεί την περιοδικότητα τα P , D , Q και m όπου, P είναι η τάξη της εποχικής αυτοπαλίνδρομης συνιστώσας (SAR), D είναι ο βαθμός εποχικής διαφοροποίησης, Q είναι η τάξη της εποχικής συνιστώσας κινητού μέσου (SMA) και s είναι το μήκος της εποχικής περιόδου των δεδομένων (δηλαδή πόσα χρονικά βήματα διαρκεί ένας πλήρης κύκλος). Ο καθορισμός αυτός γίνεται αναλύοντας τη μερική αυτοσυσχέτιση και συναρτήσεις αυτοσυσχέτισης των χρονοσειρών. Αυτά τα διαγράμματα βοηθούν στον εντοπισμό των τιμών υστερήσεων που είναι σημαντικές και θα πρέπει να ενσωματωθεί στο μοντέλο.

Το μοντέλο SARIMA συμβολίζεται ως SARIMA (p , d , q) $\times$ (P , D , Q , s) (Kumari & Muthulakshmi, 2023).

3.6 Επιλογή Τάξης Μοντέλου - Κριτήριο Πληροφορίας του Akaike (AIC)

Κατά τον προσδιορισμό των κατάλληλων τιμών για τις παραμέτρους p , d και q σε ένα μοντέλο ARIMA(p,d,q), συχνά χρησιμοποιούνται κριτήρια επιλογής μοντέλων που βασίζονται σε στατιστικά μέτρα αξιολόγησης. Ένα από πιο διαδεδομένα είναι το Akaike Information Criterion (AIC). Αυτά τα κριτήρια έχουν ως στόχο να αξιολογήσουν όχι μόνο το πόσο καλά ταιριάζει το μοντέλο στα δεδομένα, αλλά και να ελέγξουν τον βαθμό πολυπλοκότητάς του. Με άλλα λόγια, δεν αρκεί ένα μοντέλο να προσαρμόζεται άριστα στα υπάρχοντα δεδομένα, αλλά πρέπει ταυτόχρονα να αποφεύγει την υπερπροσαρμογή (overfitting), δηλαδή την περιττή προσαρμογή σε θόρυβο ή ασήμαντες λεπτομέρειες. Στην πράξη, αποτελεί έναν τρόπο σύγκρισης διαφορετικών μοντέλων μεταξύ πολλών υποψηφίων μοντέλων, όπου εκείνο με τη χαμηλότερη τιμή AIC θεωρείται συνήθως το καταλληλότερο, καθώς προσφέρει καλή ισορροπία μεταξύ ακρίβειας και απλότητας.

Το AIC είναι ένας δείκτης απόκλιση, ο οποίος ουσιαστικά μετρά την ποσότητα της πληροφορίας που χάνονται από ένα δεδομένο μοντέλο (Jimoh K. et al., 2022). Ως αποτέλεσμα, το κριτήριο AIC βασίζεται στην ιδέα ότι όσο λιγότερες πληροφορίες χάνει ένα μοντέλο, τόσο υψηλότερη είναι η ποιότητά του.

Το AIC ορίζεται ως:

$$AIC = T \log\left(\frac{SSE}{T}\right) + 2(k + 2), \quad (3.7)$$

όπου T είναι ο αριθμός των παρατηρήσεων που χρησιμοποιούνται για την εκτίμηση και k είναι ο αριθμός των παραγόντων πρόβλεψης στο μοντέλο. Το μέρος $k + 2$ της εξίσωσης προκύπτει επειδή υπάρχουν $k + 2$ παράμετροι στο μοντέλο: οι συντελεστές k για τους παράγοντες πρόβλεψης, ο σταθερός όρος και η διακύμανση των υπολοίπων. Η ιδέα εδώ είναι να “τιμωρήσει” την προσαρμογή του μοντέλου (SSE) με το πλήθος των παραμέτρων που πρέπει να εκτιμηθούν (Hyndman & Athanasopoulos, 2022).

3.7 Γραμμικά Μοντέλα Πρόβλεψης σε Χρονοσειρές

Στην εργασία των Sirisha et al. (2022) πραγματοποιείται πρόβλεψη σε δεδομένα πωλήσεων χρησιμοποιώντας μοντέλο ARIMA και μοντέλο SARIMA καθώς και μοντέλο LSTM.. Τα μοντέλα έχουν κατασκευαστεί και χρησιμοποιούνται για την πρόβλεψη κέρδους από τα δεδομένα δοκιμών. Παρατηρούνται ακρίβειες 93,84% (ARIMA), 94,378% (SARIMA) και 97,01% (LSTM) περίπου. Χρησιμοποιώντας τα μοντέλα που κατασκευάστηκαν έχουν γίνει προβλέψεις για τα επόμενα 5 χρόνια. Τα αποτελέσματα δείχνουν ότι το LSTM ξεπερνά και τα δύο στατιστικά μοντέλα στην κατασκευή του καλύτερου.

Η εργασία των Gulnara et al. (2022) βασίζεται στη μέθοδο της κλασικής ARIMA για την πρόβλεψη των μελλοντικών αξιών εμπειρικών δεδομένων στον τομέα των τηλεπικοινωνιών. Αυτή η εργασία στοχεύει στην πρόβλεψη των επακόλουθων επιπέδων μιας σειράς για τον έλεγχο των ροών πληροφοριών στο δίκτυο για να αποφευχθούν απώλειες. Για την πρόβλεψη των χρονοσειρών, χρησιμοποιήθηκε η μέθοδος ARIMA για την πραγματοποίηση αξιόπιστων βραχυπρόθεσμων προβλέψεων με ελάχιστο αριθμό παραμέτρων. Αναλύθηκαν τα αποτελέσματα των ACF και PACF, βάσει των οποίων πραγματοποιήθηκε διαφοροποίηση για να ληφθούν οι σωστές παράμετροι του μοντέλου ARIMA. Ως αποτέλεσμα της μελέτης,

αναπτύχθηκε ένας αλγόριθμος λογισμικού για το μοντέλο ARIMA (0,2,1). Ένα προγνωστικό μοντέλο ARIMA ελήφθη με ακρίβεια 95% , αποδεικνύοντας την επάρκεια του επιλεγμένου μοντέλου.

Στην εργασία τους οι Mehrmolaei & Keyvanpour (2016) προτείνουν μια προσέγγιση βασισμένη στην εφαρμογή ενός μέσου σφάλματος εκτίμησης για την πρόβλεψη χρονοσειρών στο βασικό μοντέλο ARIMA. Σύμφωνα με τα αποτελέσματα αποτέλεσμα, το βελτιωμένο μοντέλο ARIMA είναι καλύτερο από το βασικό μοντέλο ARIMA και η ακρίβεια είναι αποδεκτή για τους στόχους της εργασίας κάνοντας πειράματα πάνω σε τρία διαφορετικά σύνολα δεδομένων.

Κεφάλαιο 4: Μηχανική Μάθηση - Βαθιά Μάθηση

4.1 Μηχανική Μάθηση


Ο τομέας της τεχνητής νοημοσύνης και ιδιαίτερα η μηχανική μάθηση έχουν γνωρίσει ραγδαία ανάπτυξη τα τελευταία χρόνια στο πλαίσιο της ανάλυσης των δεδομένων και της υπολογιστικής επιτρέποντας στις διάφορες εφαρμογές να λειτουργούν με έναν “ευφυή” τρόπο. Σύμφωνα με τον Arthur Samuel, μηχανική μάθηση (ML) είναι η επιστημονική μελέτη αλγορίθμων και στατιστικών μοντέλων που χρησιμοποιούν τα συστήματα υπολογιστών για να εκτελέσουν μια συγκεκριμένη εργασία χωρίς να έχει προγραμματιστεί ρητά (Mahesh, 2020).

Πρακτικά, η μηχανική μάθηση είναι η διαδικασία μέσω της οποίας οι μηχανές εκπαιδεύονται να χειρίζονται δεδομένα με αποτελεσματικότερο τρόπο. Πολλές φορές, μετά τη συλλογή των δεδομένων, δεν είναι εύκολο να εξαχθούν σαφείς πληροφορίες ή να κατανοηθούν μοτίβα. Σε τέτοιες περιπτώσεις η εφαρμογή αλγορίθμων και μοντέλων μηχανικής μάθησης πάνω στα δεδομένα επιταχύνεται και επιτυγχάνεται η εξαγωγή συμπερασμάτων και προβλέψεων.

Η μηχανική μάθηση βασίζεται σε διάφορους τύπους αλγορίθμων για την επίλυση προβλημάτων καθώς δεν υπάρχει ένας ενιαίος τύπος αλγορίθμου που να είναι ο καταλληλότερος για την επίλυση κάθε είδους υπό μελέτη προβλήματος. Έτσι, ανάλογα με τον τύπο του προβλήματος που επιδιώκεται να επιλυθεί, επιλέγεται και ο κατάλληλου τύπου αλγόριθμος. Για μια σωστή επιλογή του τυπου αλγορίθμου που θα χρησιμοποιηθεί, πρέπει να απαντηθούν ερωτήματα όπως, ποιος είναι ο στοχος της εφαρμογής, ποιο είναι το πλήθος των δεδομένων, ποια είναι η ποιότητα των δεδομένων, ποιος είναι ο τύπος των δεδομένων, ποιος ο διαθέσιμος υπολογιστικός χρόνος, η γραμμικότητα των δεδομένων, ποσα είναι τα χαρακτηριστικά και οι παράμετροι κ.α.

Ενώ οι στατιστικές μέθοδοι δυσκολεύονται να συλλάβουν σύνθετα μοτίβα σε δεδομένα χρονοσειρών, λόγω της εξάρτησής τους από την ύπαρξη προκαθορισμένων γραμμικών σχέσεων, μοντέλα μηχανικής μάθησης υπερτερούν στην εκμάθηση μη-γραμμικών μοτίβων απευθείας από τα δεδομένα, χωρίς να εξαρτώνται από τέτοιες παραδοχές. Για την αντιμετώπιση των περιορισμών των στατιστικών μεθόδων, παραδοσιακά μοντέλα μηχανικής μάθησης και βαθιάς μάθησης ολοένα και περισσότερο χρησιμοποιούνται για την πρόβλεψη χρονοσειρών.


Οι αλγόριθμοι μηχανικής μάθησης μπορούν να κατηγοριοποιηθούν σε διάφορες κύριες κατηγορίες. Μερικές από τις σημαντικότερες από αυτές είναι η εποπτευόμενη μάθηση, η μη εποπτευόμενη μάθηση, η ημι-εποπτευόμενη μάθηση, και τα Νευρωνικά Δίκτυα (Εικόνα 4).



Εικόνα 4: Τύποι τεχνικών μηχανικής μάθησης (Mahesh, 2020).

4.1.1 Εποπτευόμενη Μάθηση

Η εποπτευόμενη μάθηση αποτελεί μια προσέγγιση μηχανικής μάθησης που βασίζεται στην κατανόηση μιας συνάρτησης αντιστοίχισης μιας εισόδου και μιας εξόδου, με βάση ζεύγη δειγμάτων εισόδου-εξόδου (Han et al., 2011). Στοχεύει στον χαρακτηρισμό των δεδομένων με βάση προηγούμενες πληροφορίες. Χρησιμοποιεί δηλαδή, μια συλλογή από παραδείγματα επισημασμένων δεδομένων εκπαίδευσης για να συναγάγει τη συνάρτηση αντιστοίχισης. Για την εκπαίδευση του μοντέλου το σύνολο των δεδομένων διαιρείται σε δεδομένα εκπαίδευσης (train set) και δεδομένα ελέγχου (test set) (Εικόνα 5). Η υλοποίηση τέτοιων αλγορίθμων είναι χρήσιμη όταν αναγνωρίζονται συγκεκριμένοι στόχοι-αποτελέσματα που πρέπει να επιτευχθούν από ένα συγκεκριμένο σύνολο δεδομένων εισόδου .



Εικόνα 5: Ροή εργασιών τεχνικών εποπτευόμενης μάθησης (Mahesh, 2020).

Οι πιο κοινές τεχνικές εποπτευόμενης μάθησης είναι η ταξινόμηση (classification) η οποία διαχωρίζει τα δεδομένα και η παλινδρόμηση (regression) η οποία επιδιώκει να αναγνωρίσει μια συνάρτηση κατάλληλα προσαρμοσμένη στα δεδομένα. Η πιο σημαντική διάκριση μεταξύ ταξινόμησης και παλινδρόμησης είναι ότι η ταξινόμηση προβλέπει ξεχωριστές ετικέτες κλάσεων, ενώ η παλινδρόμηση διευκολύνει την πρόβλεψη μιας συνεχούς ποσότητας. Για παράδειγμα, η πρόβλεψη της ετικέτας ταξινόμησης μηνυμάτων ηλεκτρονικού ταχυδρομείου ως “Ανεπιθύμητα” ή “Επιθυμητά” με βάση τις φράσεις ή λέξεις κλειδιά ή η πρόβλεψη μελλοντικής παραγωγής ηλεκτρικής ενέργειας από μια ανεμογεννήτρια, βάσει της ταχύτητας των ανέμων αποτελούν παραδείγματα εποπτευόμενης μάθησης.

Διάφοροι αλγόριθμοι παλινδρόμησης έχουν προταθεί, με τους πιο δημοφιλείς να είναι οι παρακάτω (Sarker, 2021):

- **Δέντρο Απόφασης:** Είναι μια πολύ γνωστή μη παραμετρική εποπτευόμενη μέθοδος μάθησης. Οι μέθοδοι μάθησης Δέντρων Απόφασης χρησιμοποιούνται και για τις εργασίες ταξινόμησης και πρόβλεψης. Πρόκειται ουσιαστικά για γράφημα που αναπαριστά τις επιλογές και τα αποτελέσματά τους σε μορφή δέντρου. Οι κόμβοι στο γράφημα αντιπροσωπεύουν ένα γεγονός ή μια επιλογή και οι άκρες του γραφήματος αντιπροσωπεύουν τους κανόνες ή τις συνθήκες απόφασης. Κάθε δέντρο αποτελείται από κόμβους και κλάδους. Κάθε κόμβος αντιπροσωπεύει χαρακτηριστικά σε μια ομάδα που πρόκειται να ταξινομηθεί και κάθε κλάδος αντιπροσωπεύει μια τιμή που μπορεί να λάβει ο κόμβος. Στην πρόβλεψη χρονοσειρών, τα δέντρα αποφάσεων παλινδρόμησης χρησιμοποιούνται για τη διάσπαση δεδομένων σε μια δομή δέντρου για την πρόβλεψη συνεχών τιμών. Ενώ είναι διαισθητικά και εύκολα στην ερμηνεία, είναι επιρρεπή σε overfitting (Kim et al., 2024).
- **Μηχανές Διανυσματικής Υποστήριξης (Support Vector Machine - SVM):** Οι Μηχανές Διανυσματικής Υποστήριξης είναι εποπτευόμενα μοντέλα μάθησης που

χρησιμοποιούνται για την ταξινόμηση και παλινδρόμηση, που χαρακτηρίζονται από την εύρεση του μέγιστου περιθωρίου. Χειρίζονται αποτελεσματικά δεδομένα υψηλών διαστάσεων και μη γραμμικότητες, καθιστώντας τα ισχυρά για εργασίες ταξινόμησης και παλινδρόμησης. Σε ένα χώρο πολλών διαστάσεων, μια μηχανή διανυσμάτων υποστήριξης κατασκευάζει ένα υπερ-επίπεδο ή ένα σύνολο υπερ-επίπεδων. Στην ουσία σχεδιάζει περιθώρια μεταξύ των τάξεων, ενώ σε προβλήματα παλινδρόμησης, προβλέπει σημεία δεδομένων χρησιμοποιώντας ένα βέλτιστο υπερεπίπεδο. Τα περιθώρια σχεδιάζονται με τέτοιο τρόπο ώστε η απόσταση μεταξύ του περιθωρίου και των κλάσεων να είναι μέγιστη και επομένως, ελαχιστοποιώντας το σφάλμα ταξινόμησης, ενώ σε προβλήματα παλινδρόμησης το υπερεπίπεδο είναι εκπαιδευμένο να ελαχιστοποιεί τα σφάλματα μεταξύ των σημείων δεδομένων, διασφαλίζοντας ότι τα σφάλματα δεν υπερβαίνουν ένα συγκεκριμένο όριο (Kim et al., 2024).

- Γραμμική Παλινδρόμηση: Η γραμμική παλινδρόμηση δημιουργεί μια σχέση μεταξύ της εξαρτημένης μεταβλητής (Y) και μιας ή περισσότερων ανεξάρτητων μεταβλητών (X) (γνωστή και ως γραμμή παλινδρόμησης) χρησιμοποιώντας την ευθεία γραμμή με την καλύτερη εφαρμογή. Η εξαρτημένη μεταβλητή είναι συνεχής, η ανεξάρτητη μεταβλητή μπορεί να είναι συνεχής ή διακριτή.


4.2 Βαθιά Μάθηση - Τεχνητά Νευρωνικά Δίκτυα

Η βαθιά μάθηση (Deep Learning- DL) αποτελεί μέρος μια οικογένειας αλγορίθμων μηχανικής μάθησης, εκείνης των τεχνητών νευρωνικών δικτύων (ANN). Η υπολογιστική αρχιτεκτονική των αλγορίθμων αυτών συνίσταται από τον συνδυασμό μερικών επιπέδων επεξεργασίας όπως το επίπεδο εισόδου, τα κρυφά επίπεδα και το επίπεδο εξόδου τα οποία μαθαίνουν από τα δεδομένα. Γενικά, η βαθιά μάθηση επιτρέπει σε υπολογιστικά μοντέλα που αποτελούνται από πολλαπλά επίπεδα επεξεργασίας, να μαθαίνουν αναπαραστάσεις δεδομένων με πολλαπλά επίπεδα αφαίρεσης.

Η διαδικασία της μάθησης αποτελεί ουσιαστικά την εκτίμηση των παραμέτρων του μοντέλου, έτσι ώστε το μοντέλο (αλγόριθμος) να μπορεί να εκτελέσει μια συγκεκριμένη εργασία. Για παράδειγμα, στα τεχνητά νευρωνικά δίκτυα, οι παράμετροι είναι τα βάρη των χαρακτηριστικών. Η βαθιά μάθηση αποτελεί προσέγγιση πολλών επιπέδων μεταξύ του επιπέδου εισόδου και εξόδου που της επιτρέπει την επεξεργασία μη γραμμικής πληροφορίας με ιεραρχική αρχιτεκτονική και αξιοποιείται για εκμάθηση χαρακτηριστικών και ταξινόμηση προτύπων (Schmidhuber, 2015).

Η βαθιά μάθηση ανακαλύπτει περίπλοκες δομές σε μεγάλα σύνολα δεδομένων, αξιοποιώντας τον αλγόριθμο backpropagation για να καθορίσει πώς ένα μοντέλο πρέπει να προσαρμόσει τις εσωτερικές του παραμέτρους. Οι παράμετροι αυτοί χρησιμοποιούνται για τον υπολογισμό αναπαραστάσεων σε κάθε επίπεδο, με βάση τις αναπαραστάσεις που προέρχονται από το προηγούμενο επίπεδο (LeCun et al., 2015). Το κύριο πλεονέκτημα της βαθιάς μάθησης έναντι των παραδοσιακών μεθόδων μηχανικής μάθησης είναι οι καλύτερες επιδόσεις που προσφέρει, ειδικά πάνω σε μεγάλα σύνολα δεδομένων (Xin et al., 2018).


Πειραματικά αποτελέσματα δείχνουν επιδόσεις αιχμής με την χρήση βαθιάς μάθησης σε σχέση με την παραδοσιακή μηχανική μάθηση στους τομείς της επεξεργασίας εικόνας, υπολογιστικής όρασης, αναγνώρισης ομιλίας, μηχανική μετάφραση, τέχνη, ιατρική απεικόνιση, κυβερνοασφάλεια κ.α. (Alom et al., 2019). Η παρακάτω εικόνα δείχνει ποιοτικά την γενική αύξηση της απόδοσης των αλγορίθμων βαθιάς μάθησης έναντι των κλασικών αλγορίθμων μηχανικής μάθησης αυξανόμενου το πλήθους των δεδομένων, ενώ όσο το πλήθος των δεδομένων μειώνεται η απόδοσή της κλασικής μηχανικής μάθησης υπερτερεί.



Εικόνα 6: Απόδοση αλγορίθμων βαθιάς μάθησης συναρτήσει του πλήθους δεδομένων (Alom et al., 2019)

Τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks - ANN) είναι δημοφιλείς τεχνικές μηχανικής μάθησης που προσομοιώνουν τον μηχανισμό μάθησης σε βιολογικούς οργανισμούς. Το ανθρώπινο νευρικό σύστημα περιέχει κύτταρα, τα οποία αναφέρονται ως νευρώνες. Οι νευρώνες συνδέονται μεταξύ τους με τη χρήση νευραξόνων και δενδριτών και οι περιοχές σύνδεσης μεταξύ νευραξόνων και δενδριτών αναφέρονται ως συνάψεις. Η

δύναμη των συναπτικών συνδέσεων συχνά αλλάζουν ως απάντηση σε εξωτερικά ερεθίσματα. Αυτή η αλλαγή είναι ο τρόπος με τον οποίο λαμβάνει χώρα η μάθηση στους ζωντανούς οργανισμούς. Αυτός ο βιολογικός μηχανισμός προσομοιώνεται σε τεχνητά νευρωνικά δίκτυα, τα οποία περιέχουν υπολογιστικές μονάδες που αναφέρονται ως νευρώνες (Aggarwal, 2023). Τα Τεχνητά Νευρωνικά Δίκτυα συνθέτουν ένα υποείδος της Μηχανικής Μάθησης, το οποίο ονομάζεται Βαθιά Μάθηση (Deep Learning).




Εικόνα 7: Αριστερά: Βιολογικό Νευρωνικό Δίκτυο. Δεξιά: Τεχνητό Νευρωνικό Δίκτυο (Aggarwal, 2023).

4.2.1 Μονο-επίπεδα Νευρωνικά Δίκτυα (Single-layer Perceptrons)

Τα τρία κύρια επίπεδα ενός τυπικού Τεχνητού Νευρωνικού Δικτύου είναι το επίπεδο εισόδου (input layer), το κρυμμένο επίπεδο (hidden layer) και το επίπεδο εξόδου (output layer). Το απλούστερο νευρωνικό δίκτυο αναφέρεται ως perceptron και έχει ένα μόνο επίπεδο εισόδου και έναν κόμβο εξόδου. Οι υπολογιστικές μονάδες συνδέονται μεταξύ τους μέσω συναπτικών βαρών (synaptic weights), τα οποία εξυπηρετούν τον ίδιο ρόλο με τις δυνάμεις των συναπτικών συνδέσεων σε βιολογικούς οργανισμούς. Κάθε είσοδος σε έναν νευρώνα κλιμακώνεται με ένα βάρος, το οποίο επηρεάζει τη συνάρτηση που υπολογίζεται σε αυτή τη μονάδα.

Η αρχιτεκτονική του perceptron φαίνεται στην Εικόνα 8 στην οποία ένα μόνο επίπεδο εισόδου μεταδίδει τα χαρακτηριστικά στον κόμβο εξόδου (με και χωρίς bias). Οι άκρες από την είσοδο στην έξοδο περιέχουν τα βάρη $w_1 \dots w_d$ με τα οποία πολλαπλασιάζονται τα χαρακτηριστικά και προστίθενται στον κόμβο εξόδου. Στη συνέχεια, εφαρμόζεται η συνάρτηση ενεργοποίησης (activation function) για τη μετατροπή της συγκεντρωτικής τιμής σε πρόβλεψη. Ο σκοπός της συνάρτησης ενεργοποίησης είναι να εισάγει μη γραμμικότητα στην έξοδο ενός νευρώνα. Αυτό είναι σημαντικό καθώς σχεδόν όλα τα πραγματικά δεδομένα

είναι μη γραμμικά. Η τιμή της μεταβλητής σε έναν κόμβο σε ένα νευρωνικό δίκτυο αναφέρεται επίσης μερικές φορές ως ενεργοποίηση. Αξίζει να σημειωθεί ότι το perceptron περιέχει δύο επίπεδα, αν και το επίπεδο εισόδου δεν εκτελεί κανέναν υπολογισμό και μεταδίδει μόνο τις τιμές των χαρακτηριστικών. Αυτό ισχύει σε όλες τις νευρωνικές αρχιτεκτονικές, όπου το επίπεδο εισόδου εκτελεί μόνο ρόλο μετάδοσης. Το επίπεδο εισόδου δεν περιλαμβάνεται στην καταμέτρηση του αριθμού των επιπέδων σε ένα νευρωνικό δίκτυο. Δεδομένου ότι το perceptron περιέχει ένα μόνο υπολογιστικό επίπεδο, θεωρείται δίκτυο ενός επιπέδου (Aggarwal, 2023).




Εικόνα 8: Αριστερά: Perceptron χωρίς bias. Δεξιά: Perceptron με bias (Aggarwal, 2023).

Σε πολλές περιπτώσεις, υπάρχει ένα αμετάβλητο μέρος της πρόβλεψης, το οποίο αναφέρεται ως μεροληψία (bias). Η μεροληψία μπορεί να ενσωματωθεί ως το βάρος μιας εισόδου χρησιμοποιώντας έναν νευρώνα μεροληψίας. Αυτό επιτυγχάνεται με την προσθήκη ενός νευρώνα που μεταδίδει πάντα μια τιμή 1 στον κόμβο εξόδου. Το βάρος της άκρης που συνδέει τον νευρώνα μεροληψίας με τον κόμβο εξόδου παρέχει τη μεταβλητή μεροληψίας. Ένα παράδειγμα ενός μεροληπτικού νευρώνα φαίνεται στην Εικόνα 8 (δεξιά). Έτσι η πρόβλεψη δίνεται από την σχέση:

$$\hat{y} = f\left\{\sum_{j=1}^d w_j x_j + b\right\}, \quad (4.1)$$

οπού x_j συμβολίσουμε την τιμή του j -οστού νευρώνα, w_j είναι το αντίστοιχο συναπτικό βάρος και b είναι η μεροληψία. Η παραπάνω συνάρτηση αποτελεί την συνάρτηση ενεργοποίησης.


Η συνάρτηση ενεργοποίησης υποδεικνύει ουσιαστικά τη λειτουργία κάθε νευρώνα και συνεπώς η επιλογή της συνάρτησης ενεργοποίησης είναι ένα κρίσιμο μέρος του σχεδιασμού νευρωνικών δικτύων. Διαφορετικοί τύποι μη γραμμικών συναρτήσεων όπως η συνάρτηση προσήμου (sign), η σιγμοειδής συνάρτηση (sigmoid), η βηματική (step), οι υπερβολικές εφαπτομένες (hyperbolic tangents), ή η ReLU κ.α. χρησιμοποιούνται συνήθως (Εικόνα 9). Η βηματική συνάρτηση δίνει τιμές εξόδου 0 ή 1 αν η τιμή που υπολογίζει ο αθροιστής είναι μεγαλύτερη από μια τιμή κατωφλίου T . Η συνάρτηση προσήμου δίνει θετική ή αρνητική έξοδο (-1 ή 1) αν η τιμή που υπολογίζει ο αθροιστής είναι μικρότερη ή μεγαλύτερη από μια τιμή κατωφλίου T . Στους νευρώνες με σιγμοειδή συνάρτηση ενεργοποίησης οι τιμές μπορούν να είναι οποιοσδήποτε πραγματικός αριθμός μεταξύ 0 και 1.



Εικόνα 9: Απεικόνιση μερικών βασικών συναρτήσεων ενεργοποίησης (Aggarwal, 2023).

4.2.2 Πολυ-επίπεδα Νευρωνικά Δίκτυα (Multi-layer Perceptrons)

Η πιο συνηθισμένη μορφή Νευρωνικών Δικτύων είναι τα πολυεπίπεδα νευρωνικά δίκτυα (MLP). Περιέχουν περισσότερα από ένα υπολογιστικά επίπεδα σε αντίθεση με το μονο-επίπεδο perceptron που περιέχει ένα επίπεδο εισόδου και ένα εξόδου, από τα οποία το στρώμα εξόδου είναι το μόνο υπολογιστικό στρώμα. Το επίπεδο εισόδου μεταδίδει τα δεδομένα στο επίπεδο εξόδου, και όλοι οι υπολογισμοί είναι εντελώς ορατοί από το χρήστη. Τα πολυεπίπεδα νευρωνικά δίκτυα περιέχουν πολλαπλάσια υπολογιστικά επίπεδα, τα οποία είναι τα πρόσθετα ενδιάμεσα επίπεδα (μεταξύ της εισόδου και εξόδου) και αναφέρονται ως κρυμμένα επίπεδα, επειδή οι υπολογισμοί που εκτελούνται δεν είναι ορατοί στον χρήστη.



Εικόνα 10: Η βασική αρχιτεκτονική ενός δικτύου εμπρόσθιας τροφοδότησης με δύο κρυμμένα επίπεδα και ένα μόνο επίπεδο εξόδου (Aggarwal, 2023).

Η αρχιτεκτονική των πολυστρωματικών νευρωνικών δικτύων αναφέρεται ως δίκτυα πρόσθιας τροφοδότησης, επειδή τα διαδοχικά στρώματα τροφοδοτούν το ένα το άλλο προς τα εμπρός από την είσοδο στην έξοδο. Η αρχιτεκτονική αυτή των δικτύων τροφοδοσίας υποθέτει ότι όλοι οι κόμβοι σε ένα επίπεδο συνδέονται με εκείνους του επόμενου επιπέδου. Επομένως, η αρχιτεκτονική του νευρωνικού δικτύου είναι σχεδόν πλήρως καθορισμένη, αφού καθοριστεί ο αριθμός των στρωμάτων και ο αριθμός των κόμβων σε κάθε στρώμα.

Χάρη στη χρήση αλγορίθμων οπίσθιας διάδοσης (backpropagation), είναι δυνατόν να εκπαιδεύσουμε δίκτυα πολλαπλών επιπέδων μέσω μιας εποπτευόμενης προσέγγισης, υπολογίζοντας πρώτα το σφάλμα στο επίπεδο εξόδου και στη συνέχεια την ρύθμιση των βαρών στα προηγούμενα επίπεδα σε μια προς τα πίσω επαναληπτική διαδικασία. Αυτή η διαδικασία διεξάγεται μέσω της εποπτευόμενης μάθησης, στην οποία παρέχονται τόσο τα

δεδομένα εισόδου όσο και η αναμενόμενη έξοδος στο δίκτυο, το οποίο είναι υπεύθυνο για την πραγματοποίηση της αντίστοιχης συσχέτισης προσαρμόζοντας τα βάρη όλων των νευρώνων σε όλα τα επίπεδα για να ελαχιστοποιηθεί το σφάλμα εξόδου (Lazano et al., 2024).

Η επιλογή του σωστού αριθμού κρυφών επιπέδων σε ένα MLP συνδέεται άμεσα με τα κλασικά φαινόμενα της υποπροσαρμογής (underfitting) και της υπερπροσαρμογής (overfitting). Πολύ λίγα κρυφά επίπεδα οδηγούν σε υψηλό σφάλμα μεροληψίας και το μοντέλο αδυνατεί να αποτυπώσει την πολυπλοκότητα των δεδομένων και αποδίδει χαμηλά τόσο στο σύνολο εκπαίδευσης όσο και επικύρωσης. Αντιθέτως, υπερβολικός αριθμός επιπέδων χωρίς επαρκή κανονικοποίηση αυξάνει την διασπορά και ευνοεί την απομνημόνευση, με πολύ χαμηλό σφάλμα στο train αλλά υποχώρηση στη γενίκευση (overfitting).


4.2.3 Convolutional Neural Networks (CNNs)

Τα συνελικτικά νευρωνικά δίκτυα (CNNs) είναι αρχιτεκτονικές βαθιάς μάθησης που αξιοποιούν συνελίξεις για την αυτόματη εξαγωγή ιεραρχικών χαρακτηριστικών από δεδομένα με δομή πλέγματος. Τα CNNs αρχικά σχεδιαστήκαν για εικόνες δύο διαστάσεων, ωστόσο, μπορεί επίσης να χρησιμοποιηθούν αποτελεσματικά για την ανάλυση μονοδιάστατων δεδομένων όπως οι χρονοσειρές (Nigam, 2024).

Τα συνελικτικά νευρωνικά δίκτυα είναι ανάλογα με τα παραδοσιακά ANNs στο ότι αποτελούνται από νευρώνες που αυτοβελτιστοποιούνται μέσω της μάθησης. Κάθε νευρώνας θα εξακολουθεί να λαμβάνει μια είσοδο και να εκτελεί μια λειτουργία (όπως ένα βαθμωτό γινόμενο ακολουθούμενο από μια μη γραμμική συνάρτηση) δηλαδή τη βάση των ANNs. Από τα διανύσματα εισόδου έως την τελική έξοδο, ολόκληρο το δίκτυο θα εξακολουθεί να εκφράζει μια μοναδική συνάρτηση αντιληπτικής βαθμολογίας (το βάρος). Το τελευταίο επίπεδο θα περιέχει την συνάρτηση κόστους και όλες οι τακτικές που αναπτύχθηκαν για τα παραδοσιακά ANN εξακολουθούν να ισχύουν. Ένα κλασσικό CNN μοντέλο αποτελείται από ένα ή περισσότερα συνελικτικά επίπεδα, το οποίο είναι ουσιαστικά εμπνευσμένο από MLP για την αναπαράσταση των δεδομένων (O'Shea, 2015).

Τα CNNs αποτελούνται από τρεις τύπους επιπέδων. Αυτά είναι τα συνελικτικά επίπεδα, τα συγκεντρωτικά επίπεδα (pooling layer) και τα πλήρως συνδεδεμένα επίπεδα (fully-connected layers). Όταν αυτά τα στρώματα στοιβάζονται, έχει σχηματιστεί μια αρχιτεκτονική CNN. Μια απλοποιημένη αρχιτεκτονική CNN απεικονίζεται στη Εικόνα 11. Στο

επίπεδο εισόδου εισέρχονται τα δεδομένα. Το συνελκτικό επίπεδο καθορίζει την έξοδο των νευρώνων μέσω του υπολογισμού του γινομένου συνέλιξης μεταξύ φίλτρων και εισόδου, παράγοντας πίνακες που ονομάζονται χάρτες χαρακτηριστικών (feature maps). Στη συνέχεια, η διορθωμένη γραμμική μονάδα (ReLU) εφαρμόζεται ως μη γραμμική συνάρτηση ενεργοποίησης στην έξοδο του προηγούμενου επιπέδου, σε αντικατάσταση παραδοσιακών συναρτήσεων όπως η σιγμοειδής. Τέλος, το συγκεντρωτικό επίπεδο (pooling layer) εκτελεί μείωση δειγματοληψίας κατά μήκος των χωρικών διαστάσεων της εισόδου, μειώνοντας έτσι τον αριθμό των παραμέτρων και την υπολογιστική πολυπλοκότητα του μοντέλου. Τα πλήρως συνδεδεμένα επίπεδα θα εκτελέσουν στη συνέχεια τα ίδια καθήκοντα που εντοπίζονται και στα τυπικά ANN και θα προσπαθήσουν να παράγουν βαθμολογίες κλάσης από τις ενεργοποιήσεις, που θα χρησιμοποιηθούν για την εξαγωγή αποτελεσμάτων (O'Shea, 2015).



Εικόνα 11: Μια απλή αρχιτεκτονική CNN, αποτελούμενη από μόλις πέντε επίπεδα (O'Shea, 2015).

4.2.4 Long-Short Term Memory Neural Networks (LSTMNs)


Τα LSTM αποτελούν αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Network - RNN) που είναι ένα δυναμικό σύστημα που χρησιμοποιεί την προσέγγιση της αναδρομής. Στην αναδρομή, η έξοδος ενός μοντέλου τροφοδοτείται ως είσοδος στο μοντέλο και πάλι στο επόμενο βήμα. Ένας από τους κύριους αλγόριθμους εκπαίδευσης για το RNN είναι η Οπισθοδιάδοση Μέσω του Χρόνου (BPTT), η οποία είναι παρόμοια με τον αλγόριθμο backpropagation, αλλά έχει και κανόνα αλυσίδας για τον χρόνο (Ghojogh & Ghodsi, 2023). Τα RNN είναι σε θέση να συλλάβουν μη γραμμικές βραχυπρόθεσμες χρονικές εξαρτήσεις

αλλά έχουν το μειονέκτημα της εξαφάνισης (ή έκρηξης) της κλίσης. Έτσι, οι μη στασιμες εξαρτήσεις που συμβαίνουν σε μεγάλο χρονικό διάστημα καταγράφονται λιγότερο καλά από ένα RNN (Lindemann, 2021). Η μοντελοποίηση αλληλουχίας απαιτεί τόσο βραχυπρόθεσμες όσο και μακροπρόθεσμες εξαρτήσεις, έτσι προτάθηκε το δίκτυο μακράς Βραχυπρόθεσμης Μακράς Μνήμης (LSTM) για να χειριστεί τόσο τις βραχυπρόθεσμες όσο και τις μακροχρόνιες εξαρτήσεις (Hochreiter & Schmidhuber, 1997). Το LSTM είναι σε θέση να μαθαίνει από την ακολουθία εισόδου πότε να χρησιμοποιεί βραχυπρόθεσμη εξάρτηση (δηλαδή να καθαρίζει την κατάσταση των κελιών μνήμης) και πότε να χρησιμοποιεί τη μακροπρόθεσμη μνήμη (δηλαδή να μην την καθαρίζει). Τα μοντέλα βασισμένα σε RNNs ουσιαστικά αναπτύχθηκαν για να επεξεργαστούν διαδοχικά δεδομένα όπως οι χρονοσειρές (Seri et al., 2025). Η επαναλαμβανόμενη δομή τους μπορεί αποτελεσματικά να μοντελοποιεί τις χρονικές εξαρτήσεις των δεδομένων χρονοσειρών. Τα μοντέλα RNN Πύλης (Gated RNN), όπως τα LSTM και GRU, έχουν εν μέρη μετριαστεί το πρόβλημα μακροχρόνιας εξάρτησης των vanilla RNNs λόγω εξαφανισμένων κλίσεων.


Το LSTM αποτελείται από πολλά κελιά (cells), καθένα από τα οποία αντιστοιχεί σε μια χρονική περίοδο (Εικόνα 12). Κάθε κελί του LSTM περιέχει αρκετές πύλες για την εκμάθηση διαφορετικών πτυχών των χρονοσειρών εισόδου (Εικόνα 13). Αυτές οι πύλες είναι οι εξής (OGhojogh & Ghodsi, 2023): Η πύλη εισόδου (input gate) όπου αυτή η πύλη λαμβάνει την είσοδο στο τρέχων χρονικό διάστημα (time slot) x_t , και την κρυφή κατάσταση του τελευταίου χρονικού διαστήματος h_{t-1} , και εξάγει το σήμα i_t .

$$i_t = \text{sig}(W_i h_{t-1} + U_i x_t + (p_i \odot c_{t-1}) + b_i), \quad (4.2)$$

οπού, W_i , U_i και η μεροληψία b_i είναι τα βάρη εκμάθησης από την πύλη εισόδου, το $\odot$ δηλώνει το γινόμενο Hadamard είναι η τελική μνήμη από το τελευταίο χρονικό διάστημα και p_i είναι το βάρος εκμάθησης που επιτρέπει μια πιθανή διαρροή πληροφοριών από το προηγούμενο χρονικό διάστημα. Το sig είναι η σιγμοειδής συνάρτηση.



Εικόνα 12: Μια ακολουθία κελιών LSTM που επεξεργάζονται την ακολουθία εισόδου (OGhojogh & Ghodsi, 2023).



Εικόνα 13: Ροή πληροφορίας τύπου μεταφορικής ταινίας (conveyor belt) σε κελί LSTM (OGhojogh & Ghodsi, 2023)).

Μια ακόμα πύλη στα LSTM είναι η πύλη απώλειας μνήμης (forget gate). Η πύλη αυτή επίσης λαμβάνει την είσοδο στο τρέχων χρονικό διάστημα x_t , και την κρυφή κατάσταση του τελευταίου χρονικού διαστήματος h_{t-1} , και εξάγει το σήμα f_t .

$$f_t = \text{sig}(W_f h_{t-1} + U_f x_t + (p_f \odot c_{t-1}) + b_f), \quad (4.3)$$

Η πύλη απώλειας μνήμης εξετάζει την επίδραση της εισόδου και της προηγούμενης κρυφής κατάστασης και ίσως μια διαρροή πληροφοριών από την προηγούμενη μνήμη. Αυτή η πύλη ελέγχει το ποσό της απώλειας μνήμης των προηγούμενων πληροφοριών σε σχέση με τις νεοεισερχόμενες πληροφορίες.

Μια ακόμα πύλη LSTM είναι η πύλη εξόδου (output gate). Η πύλη αυτή επίσης λαμβάνει την είσοδο στο τρέχων χρονικό διάστημα x_t , και την κρυφή κατάσταση του τελευταίου χρονικού διαστήματος h_{t-1} , και εξάγει το σήμα o_t .

$$o_t = \text{sig}(W_o h_{t-1} + U_o x_t + (p_o \odot c_t) + b_o), \quad (4.4)$$

η πύλη εξόδου λαμβάνει υπόψη την επίδραση της εισόδου και της προηγούμενης κρυφής κατάστασης, καθώς και μια πιθανή διαρροή πληροφοριών από την τρέχουσα μνήμη.

Το LSTM περιλαμβάνει μια πύλη που ονομάζεται κελί νέας μνήμης (new memory cell). Η πύλη αυτή λαμβάνει την είσοδο στο τρέχων χρονικό διάστημα x_t , και την κρυφή κατάσταση του τελευταίου χρονικού διαστήματος h_{t-1} , και εξάγει το σήμα $\tilde{c}_t$.

$$\tilde{c}_t = \tanh(W_c h_{t-1} + U_c x_t + b_c), \quad (4.5)$$

Μετά τον υπολογισμό των εξόδων της πύλης εισόδου i_t , της πύλης απώλειας μνήμης f_t , και του κελιού νέας μνήμης $\tilde{c}_t$, υπολογίζεται την τελική μνήμη c_t .

$$c_t = (f_t \odot c_{t-1}) + (i_t \odot \tilde{c}_t), \quad (4.6)$$

οπού c_{t-1} είναι η τελική μνήμη του προηγούμενου χρονικού διαστήματος. Η σχέση αυτή δείχνει πως η τελική μνήμη λαμβάνει υπόψη την επίδραση της πύλης απώλειας μνήμης, της προηγούμενης μνήμης, της εισόδου και της νέας μνήμης.

Μετά τον υπολογισμό της εξόδου της πύλης εξόδου o_t και της τελικής μνήμης c_t , υπολογίζεται η κρυφή κατάσταση h_t (hidden state ή αλλιώς block output).

$$h_t = o_t \odot \tanh(c_t), \quad (4.7)$$

Τέλος, η έξοδος y_t του κελιού LSTM υπολογίζεται ως εξής:

$$\mathbf{y}_t = \mathbf{V}\mathbf{h}_t + \mathbf{b}_y, \quad (4.8)$$

όπου $\mathbf{V}$ και η μεροληψία $\mathbf{b}_y$ είναι τα βάρη εκμάθησης της εξόδου.

4.2.5 Gated Recurrent Units (GRUs)

Οι Επανατροφοδοτούμενες Μονάδες με Πύλες (Gated Recurrent Units - GRUs) μπορούν να θεωρηθούν ως απλοποίηση του LSTM, η οποία δεν χρησιμοποιεί ρητές καταστάσεις κελιών. Ακριβώς όπως το LSTM χρησιμοποιεί πύλες εισόδου, εξόδου, και απώλειας μνήμης για να αποφασίσει πόσα από τα στοιχεία από τον προηγούμενο time-stamp θα μεταφέρει στο επόμενο βήμα, ο GRU χρησιμοποιεί την πύλη ενημέρωσης και την πύλη επαναφοράς. Το GRU δεν διαθέτει ξεχωριστή εσωτερική μνήμη και απαιτεί επίσης λιγότερες πύλες για την εκτέλεση της ενημέρωσης από τη μία κρυφή κατάσταση στην άλλη. Ωστόσο, η βασική ιδέα στο GRU είναι αρκετά παρόμοια με εκείνη ενός LSTM, από την άποψη του τρόπου με τον οποίο εν μέρει επαναφέρει τις κρυμμένες καταστάσεις (Aggarwal, 2023). Όπως και τα LSTM, τα GRU είναι αποτελεσματικά στην εκμάθηση μακροπρόθεσμων εξαρτήσεων σε διαδοχικά δεδομένα όπως οι χρονοσειρές.

Το βασικό GRU περιέχει τις εξής πύλες (Εικόνα 800) (OGhojogh & Ghodsi, 2023):

Η Πύλη Επαναφοράς λαμβάνει την είσοδο εισόδου στο τρέχων χρονικό διάστημα (time slot) x_t , και την κρυφή κατάσταση στο τελευταίο χρονικό διάστημα h_{t-1} , και εξάγει το σήμα r_t .

$$\mathbf{r}_t = \text{sig}(\mathbf{W}_r \mathbf{h}_{t-1} + \mathbf{U}_r \mathbf{x}_t + \mathbf{b}_r), \quad (4.9)$$

οπού, $\mathbf{W}_r$, $\mathbf{U}_r$ και η μεροληψία $\mathbf{b}_r$ είναι τα βάρη εκμάθησης από την πύλη επαναφοράς. Η πύλη επαναφοράς λαμβάνει υπόψη την επίδραση της εισόδου και της προηγούμενης κρυφής κατάστασης, και ελέγχει την ποσότητα της επαναφοράς της προηγούμενης πληροφορίας σχετικά με τις νέες πληροφορίες. Όπως γίνεται κατανοητό, η πύλη επαναφοράς του GRU έχει ομοιότητες με την πύλη απώλειας μνήμης του LSTM.

Η Πύλη Ενημέρωσης, λαμβάνει την είσοδο στο τρέχων χρονικό διάστημα x_t , και την κρυφή κατάσταση στο τελευταίο χρονικό διάστημα h_{t-1} , και εξάγει το σήμα z_t .

$$z_t = \text{sig}(W_z h_{t-1} + U_z x_t + b_z), \quad (4.10)$$

οπού, W_z , U_z και η μεροληψία b_z είναι τα βάρη εκμάθησης απο την πύλη ενημέρωσης. Η πύλη ενημέρωσης εξετάζει την επίδραση της εισόδου και της προηγούμενης κρυφής κατάστασης και ελέγχει το ποσό της χρήσης των νέων δεδομένων εισόδου για την ενημέρωση του κελιού με την επερχόμενη πληροφορία της ακολουθίας. Η πύλης ενημέρωσης του GRU μοιάζει με την πύλη εισόδου στο LSTM.

Το Νέο Κελί Μνήμης λαμβάνει την είσοδο εισόδου στο τρέχων χρονικό διάστημα x_t , και την κρυφή κατάσταση του τελευταίου χρονικού διαστήματος h_{t-1} , και εξάγει το σήμα $\tilde{h}_t$.

$$\tilde{h}_t = \tanh(W_c (r_t \odot h_{t-1}) + U_c x_t + b_c), \quad (4.11)$$


οπού, W_c , U_c και η μεροληψία b_c είναι τα βάρη εκμάθησης για το κελί νέας μνήμης. Η πύλη αυτή λαμβάνει υπόψη την επίδραση της εισόδου και της προηγούμενης κρυφής κατάστασης για να αναπαραστήσει τις νέες πληροφορίες από την τρέχουσα είσοδο. όπως φαίνεται το κελί νέας μνήμης του GRU είναι παρόμοιο με το κελί νέας μνήμης του LSTM. Σημειώστε ότι, στο LSTM, η κρυφή κατάσταση και το κελί νέας μνήμης ήταν διαφορετικά, ωστόσο, η κρυφή κατάσταση του GRU αντικαθιστά το σήμα της νέας μνήμης στο LSTM.

Η Τελική Μνήμη. Μετά τον υπολογισμό των αποτελεσμάτων της πύλης ενημέρωσης z_t και του κελιού νέας μνήμης $\tilde{h}_t$, μπορούμε να υπολογίσουμε την τελική μνήμη h_t .

$$h_t = ((1 - z_t) \odot h_{t-1}) + (z_t \odot \tilde{h}_t), \quad (4.12)$$

Η τελική μνήμη λαμβάνει υπόψη την επίδραση της πύλης ενημέρωσης, την προηγούμενη μνήμη και την νέα μνήμη.

Τα βάρη από αυτές τις πύλες είναι εκπαιδευμένα σε τρόπο ώστε να περάσει ή να αποκλειστεί η είσοδος με βάση την ακολουθία εισόδου και το χρονικό βήμα της ακολουθίας. Γίνεται κατανοητό ότι η τελική μνήμη του GRU μοιάζει με την τελική μνήμη του LSTM, ωστόσο, έχουν κάπως διαφορετική λειτουργικότητα.



Εικόνα 14: Ροή πληροφορίας τύπου μεταφορικής ταινίας (conveyor belt) σε κελί GRU (OGhojogh & Ghodsi, 2023)).

4.3 Μοντέλα Βαθιάς Μάθησης στην Πρόβλεψη Χρονοσειρών

CNN μοντέλα έχουν χρησιμοποιηθεί ευρέως στην πρόβλεψη χρονοσειρών. Οι Wibawa et al. (2022) στην μελέτη τους στοχεύουν στη βελτιστοποίηση της απόδοσης του CNN. Με βάση τα αποτελέσματα της ανάλυσης τους, μπορεί να συναχθεί το συμπέρασμα ότι το CNN με βελτιστο συντελεστή εξομάλυνσης αποδίδει καλύτερα από άλλες επιλεγμένες μεθόδους στην πρόβλεψη χρονοσειρών. Το βέλτιστο άλφα που προτείνεται σε αυτή τη μελέτη παράγει καλύτερα αποτελέσματα αξιολόγησης. Η χρήση των αριθμών Lucas ως κρυφών επιπέδων αυξάνει σημαντικά την απόδοση του αλγορίθμου πρόβλεψης λόγω της παραγόμενης χρυσής αναλογίας.

Οι Velastegui et al. (2020) παρουσιάζουν μια νέα αποτελεσματική προσέγγιση για την πρόβλεψη χρονοσειρών στην πρόβλεψη πωλήσεων πραγματικών φαρμακευτικών προϊόντων. Συγκρίνοντας τα αποτελέσματα πρόβλεψης ενός CNN μοντέλου, ενός ρηχό MLP και ενός βαθύ MLP συμπεραίνουν επίσης πως η φάση εκπαίδευσης των μεθόδων πρόβλεψης CNN έχει πολύ χαμηλότερο υπολογιστικό κόστος, σε σύγκριση με τις άλλες δύο μεθόδους πρόβλεψης.

Οι Korpinska et al. (2018) στην εργασία τους μελετήσαν την εφαρμογή των CNNs για την πρόβλεψη ενεργειακών χρονοσειρών, ιδιαίτερα την ηλιακή ενέργεια και την πρόβλεψη φορτίου ηλεκτρικής ενέργειας. Συγκρίνουν την απόδοση των CNN με τα MLP NNs, καθώς και με τα δίκτυα LSTM. Τα αποτελέσματά μας έδειξαν ότι το MLP και το CNN ήταν οι πιο ακριβείς μέθοδοι πρόβλεψης και στις τέσσερις χρονοσειρές μελέτης, ενώ το LSTM ήταν η λιγότερο ακριβής μέθοδος. Το CNN επέδειξε παρόμοια ακρίβεια και χρόνο εκπαίδευσης με το MLP, και ως εκ τούτου είναι μια πολλά υποσχόμενη μέθοδος για την πρόβλεψη ενεργειακών χρονοσειρών, που αξίζει περαιτέρω διερεύνηση.

Στην βιβλιογραφία έχουν γίνει διάφορες εφαρμογές LSTM μοντέλων για την πρόβλεψη χρονοσειρών. Οι Kong et al. (2024) ανέπτυξαν μια LSTM-based μέθοδο, το PsLSTM, για μακροχρόνια πρόβλεψη χρονοσειρών χρησιμοποιώντας το framework sLSTM σε συνδυασμό με patching. Οι Wen & Li (2023), ένα νέο LSTM-attention-LSTM μοντέλο πρόβλεψης χρονοσειρών, βασισμένοι σε LSTM, coding-decoding και attention μηχανισμού. Εφάρμοσαν το νέο μοντέλο σε πέντε χρονοσειρές δεδομένων για την πρόβλεψη. Τα πειραματικά αποτελέσματα δείχνουν ότι το προτεινόμενο μοντέλο είναι καλύτερο από τα συνηθισμένα μοντέλα πρόβλεψης LSTM.

Στην βιβλιογραφία συναντώνται πολλές προσπάθειες εφαρμογής GRU-based μοντέλων για πρόβλεψη χρονοσειρών. Οι Zhang et al., (2024) παρουσιάζουν μια καινούργια RNN αρχιτεκτονική, το eGRU, για την πρόβλεψη χρονοσειρών. Το eGRU ξεπερνά σε απόδοση το vanilla GRU και άλλες state-of-the-art RNN παραλλαγές. Η προτεινόμενη αρχιτεκτονική αξιοποιεί δύο κρυφά μέλη, normal και extreme, με ένα κοινό σύνολο παραμέτρων για να μάθει τόσο τα κανονικά όσο και τα μοτίβα ακραίων τιμών διατηρώντας χρονικές πληροφορίες. Εκτενή πειράματα σε τέσσερα σύνολα δεδομένων, δείχνουν καλύτερη απόδοση πρόβλεψης του eGRU σε σύγκριση με έξι state-of-the-art RNN παραλλαγές. Οι Bousnagar et al., (2023) ελέγξαν την απόδοση των αλγορίθμων GRU και LSTM πανω σε ένα σύνολο δεδομένων εγγράφων σε σχολεία της Αλαμπάμα. Τα αποτελέσματά δείχνουν ότι το GRU μπορεί να είναι μια καλύτερη επιλογή από το LSTM για πρόβλεψη χρονοσειρών, ιδιαίτερα όταν έχουμε να κάνουμε με σχετικά μικρά σύνολα δεδομένων, όπως το συγκεκριμένο.


Οι Li et al (2024b) προτείνουν ένα νέο μοντέλο που χρησιμοποιεί Πολική Αναπαράσταση (Polar Representation learning) μαθαίνοντας να προβλέπει τη μακροπρόθεσμες χρονοσειρές με υψηλή μεταβλητότητα. Το μοντέλο που ονομάζεται DAN (Distance-weighted Auto-regularized Neural network) διακρίνει και μαθαίνει τις πολικές αναπαραστάσεις μακρινών και κοντινών δεδομένων, συνδυάζοντας τα για να ενισχύσουν την απόδοση της πρόβλεψης. Αντιμετωπίζει το πρόβλημα ανισορροπίας των ακραίων τιμών, τα οποία συμβαίνουν σπάνια, αλλά είναι ζωτικής σημασίας για ακριβείς προβλέψεις, χρησιμοποιώντας Kruskal-Wallis δειγματοληψία και χρησιμοποιώντας μια Multi-Loss Regularization μέθοδο για να μάθει αποτελεσματικά τόσο τις ακραίες όσο και τις κανονικές τιμές ταυτόχρονα.

Οι Galib et al. (2022) ανέπτυξαν το DeepExtrema, ένα μοντέλο που προβλέπει τη μέγιστη τιμή ενός μπλοκ μιας χρονοσειράς μέσω του συνδυασμού ενός βαθιού νευρωνικού δικτύου (βαθιά LSTM) μαζί με τη Γενικευμένης Θεωρίας Ακραίων Τιμών (GEV). Το δίκτυο αυτό μαθαίνει να παράγει παραμέτρους της GEV (θέση, κλίμακα, σχήμα) υπό κατάλληλη παραμετροποίηση ώστε να τηρούνται οι περιορισμοί (π.χ. θετικότητα κλίμακας), και εκπαιδεύεται με πιθανοθεωρητική απώλεια για να δώσει υπό όρους εκτιμήσεις του μέγιστου ενός μπλοκ. Η συνεισφορά της εργασίας αυτή είναι ότι μεταφέρει την EVT μέσα σε deep learning χωρίς να παραβιάζονται οι περιορισμοί των παραμέτρων, παρέχοντας ένα μοντέλο που σέβεται τη μορφή ουράς καθώς προβλέπει ακραία μέγιστα. Σε εκτεταμένα πειράματα (συνθετικά και πραγματικά δεδομένα) δείχνει υπεροχή έναντι κλασικών και νευρωνικών baseline μεθόδων για block-maxima forecasting.

Στο άρθρο τους οι Shi et al. (2024) παρουσιάζουν το ReFine, μια απλή αλλά ισχυρή, προσέγγιση για πρόβλεψη ακραίων γεγονότων σε χρονοσειρές, η οποία συνδυάζει δύο στάδια: (1) reweighting, όπου τα βάρη των δειγμάτων υπολογίζονται με διεπίπεδη βελτιστοποίηση ώστε η εκπαίδευση να επικεντρώνεται περισσότερο για τα σπάνια γεγονότα, και (2) προαιρετικό fine-tuning αποκλειστικά σε ακραία δείγματα για περαιτέρω εξειδίκευση. Στο μοντέλο ως backbone χρησιμοποιείται ένα απλό Πολυ-Επίπεδο Perceptron με 8 κρυφά πλήρως συνδεδεμένα επίπεδα. Η ιδέα είναι μια δυναμική βελτιστοποίηση βαρών που ελαχιστοποιεί άμεσα την απώλεια σε ένα μικρό extreme-only σύνολο αξιολόγησης και έτσι το βασικό μοντέλο διατηρεί την απόδοσή του, αλλά βελτιώνεται στις ουρές της κατανομής. Σε πειράματα με πολλαπλά σύνολα δεδομένων, οι συγγραφείς αναφέρουν ότι το meta-reweighting υπερέχει συστηματικά έναντι των άλλων προσεγγίσεων και ότι το fine-tuning μπορεί να δώσει πρόσθετα κέρδη.

4.3.1 Μοντέλα Reweight_EVT και Reweight_META

Το ReFine (Reweighting and Fine-tuning Model) είναι μια μέθοδος η οποία αποτελείται από δύο βήματα: (α) το re-weighting, όπου τα βάρη των δειγμάτων στη συνάρτηση κόστους μαθαίνονται δυναμικά ώστε να ενθαρρυνθεί το μοντέλο να επικεντρωθεί στην εκμάθηση των λίγων ακραίων δειγμάτων και να αποτρέψει τον τεράστιο αριθμό των κανονικών δειγμάτων από την πόλωση του μοντέλου, και (β) προαιρετικό fine-tuning μόνο σε ακραία δείγματα για προσαρμογή του μοντέλου σε αυτά μέσω της επανεκπαίδευσή τους αποκλειστικά και μόνο σε σπάνια ακραία φαινόμενα. Και τα δύο βήματα είναι model-agnostic, μπορούν να τοποθετηθούν πάνω από MLP, RNN, Transformers κ.ο.κ. (στα πειράματα χρησιμοποιείται επίτηδες ένα απλό MLP για καθαρότητα σύγκρισης) (Shi et al., 2024).




Εικόνα 15: Διαδικασία εκπαίδευσης του μη σταθμισμένου framework, της προσέγγισης επανυπολογισμού βαρών και της μεθόδου fine-tuning. Τα οβάλ σχήματα αντιπροσωπεύουν τους χώρους δειγματοληψίας, οι μικροί κύκλοι αντιπροσωπεύουν μεμονωμένες εισόδους, ενώ τα μεγέθη τους υποδηλώνουν τα βάρη τους. Y_i και $\hat{Y}_i$ είναι οι τιμές επικύρωσης και πρόβλεψης, αντίστοιχα. Τα εκπαιδευσιμα μοντέλα επισημαίνονται με το σύμβολο 'φωτιά' στην επάνω αριστερή γωνία. Τα μεμονωμένα επίπεδα επισημαίνονται ως εκπαιδευσιμα ή "παγωμένα" κατά τη διάρκεια του fine-tuning (Shi et al., 2024).

Οι συγγραφείς στην εργασία τους παρουσιάζουν τρεις προσεγγίσεις αυτής της εφαρμογής: (a) την προσέγγιση της Αντίστροφης Αναλογικής Συνάρτησης (IPF) όπου περιλαμβάνει τη δημιουργία ενός ιστογράμματος συχνότητας όλων των δειγμάτων εκμάθησης και τον προσδιορισμό των βαρών για το σφάλμα πρόβλεψης κάθε δείγματος με βάση την

αντίστροφη συχνότητα της ομάδας του, (b) την προσέγγιση της Θεωρία Ακραίων Τιμών (EVT) όπου στο μοντέλο ενσωματώνεται η EVT που μελετά τις τιμές στο άκρο της ουράς και ουσιαστικά οι τιμές που υπερβαίνουν ένα όριο μ που μπορεί να προσεγγιστεί με τη Γενικευμένη Κατανομή Pareto (GPD) και (c) την προσέγγιση της Μετα-Μάθησης (Meta Learning) όπου σε αντίθεση με τις δύο προηγούμενες στρατηγικές που υπολογίζουν τα βάρη ποινής αξιοποιώντας προηγούμενη γνώση της κατανομής δεδομένων, στην προσέγγισή αυτή, θεωρούμε τα βάρη ως υπερπαραμέτρους που μπορούν να επηρεάσουν το μοντέλο. Ως εκ τούτου, χρησιμοποιούν τη μετα-μάθηση για να μάθουν δυναμικά τις βέλτιστες τιμές που μπορούν να ελαχιστοποιώντας την συνάρτηση απώλειας του αποκλειστικού συνόλου αξιολόγησης.

Στην περίπτωση του reweighting με EVT (Reweight_EVT), γίνεται πρώτα στατιστική ανάλυση της κατανομής των δεδομένων ώστε να εντοπιστούν οι τιμές που βρίσκονται στις ουρές της κατανομής. Η EVT χρησιμοποιεί την GPD για τον ακριβέστερο προσδιορισμό των thresholds, δηλαδή του σημείου στο οποίο οι παρατηρήσεις θεωρούνται πλέον ακραίες. Με βάση αυτόν τον προσδιορισμό, τα δεδομένα χωρίζονται σε δύο κατηγορίες, τα κανονικά δεδομένα που βρίσκονται μέσα στην κεντρική κατανομή και και τα ακραία δεδομένα στην ουρά της κατανομής. Αφού γίνει αυτός ο διαχωρισμός, το μοντέλο προχωρά σε αναπροσδιορισμό των βαρών (reweighting). Οι ακραίες τιμές λαμβάνουν μεγαλύτερο βάρος στη συνάρτηση κόστους κατά την εκπαίδευση, έτσι ώστε το μοντέλο να «τιμωρείται» περισσότερο όταν κάνει λάθος πρόβλεψη σε αυτές.

Στην περίπτωση του reweighting με Meta-Learning (Reweight_META) το πρόβλημα τίθεται ως μια μοντέλο-αγνωστική μέθοδο πρόβλεψης ακραίων γεγονότων σε χρονοσειρές που μετα-μαθαίνει βάρη απώλειας ανά δείγμα με χρήση ενός μικρού extreme-only σετ αξιολόγησης ως διεπίπεδη (bilevel) βελτιστοποίηση. Η καινοτομία της Reweight_META σε σχέση με πιο απλές προσεγγίσεις είναι ότι τα βάρη δεν καθορίζονται χειροκίνητα, αλλά μαθαίνονται αυτόματα μέσω μιας διαδικασίας meta-learning. Ο εσωτερικός βρόχος εκπαιδεύει τις παραμέτρους του μοντέλου με μια σταθμισμένη απώλεια (τα τρέχοντα βάρη πολλαπλασιάζουν το σφάλμα κάθε δείγματος), ενώ ο εξωτερικός βρόχος ενημερώνει τα βάρη ώστε να ελαχιστοποιείται η απώλεια σε ένα μικρό σύνολο αξιολόγησης που περιέχει μόνο ακραία δείγματα (extreme-only validation). Σε κάθε κύκλο εκπαίδευσης γίνεται ουσιαστικά εξής: (1) γίνεται ένα δοκιμαστικό βήμα στο train batch, (2) μετρίεται το σφάλμα πάνω στα ακραία του validation set, (3) προσαρμόζονται τα βάρη των δειγμάτων ώστε να μικραίνει το σφάλμα, και (4) εκτελείται το κανονικό βήμα εκπαίδευσης με τα νέα βάρη. Έτσι, τα δείγματα που βοηθούν να πέσει το σφάλμα στα ακραία γεγονότα λαμβάνουν μεγαλύτερο βάρος, και το δίκτυο κατευθύνεται να μάθει καλύτερα τις ουρές. Το fine-tuning αποτελεί ένα προαιρετικό στάδιο που παγώνει τα πρώιμα επίπεδα του βασικού μοντέλου και εκπαιδεύει οριακά τα τελευταία μόνο πάνω σε ακραία, με μικρό ρυθμό μάθησης και κανονικοποίηση, ώστε να εκπαιδευτεί περαιτέρω για τα σπάνια συμβάντα.



Εικόνα 16 : Σχηματική απεικόνιση της μεθόδου επαναπροσδιορισμού των βαρών με μετα-μάθηση (Reweight_META) (Shi et al., 2024)

Στα πειράματα τους οι Shi et al. (2024) εξετάζουμε διάφορα baselines μοντέλα, συμπεριλαμβανομένων μη σταθμισμένων μοντέλων (unweighted models), LSTM, Transformer (που είναι ένα attention-based μοντέλο που μπορεί να χρησιμοποιηθεί για προβλέψεις χρονοσειρών) και ορισμένων υφιστάμενων σταθμισμένων μοντέλων που χρησιμοποιούν την αντίστροφη αναλογική συνάρτηση (IPF), τη θεωρία ακραίων τιμών (EVT) και το NEC+.


Τα αποτελέσματα των πειραμάτων τους δείχνουν ότι και οι τρεις reweighting μέθοδοι αποδείχθηκαν αποτελεσματικές. Η Meta-learning προσέγγιση, φαίνεται πως ξεπερνάει τις άλλες δύο ευριστικές μεθόδους σε απόδοση, επιβεβαιώνοντας τα σημαντικά πλεονεκτήματα που επιδιώκουν βέλτιστα βάρη με αυτοματοποιημένο τρόπο. Τα αποτελέσματα τους δείχνουν ότι τα μοντέλα που εκπαιδεύονται αποκλειστικά σε μόνο κανονικά ή μόνο ακραία δείγματα είναι καταδικασμένα από την κατανομή τους, αποδεικνύοντας ότι τόσο τα κανονικά όσο και τα ακραία δείγματα είναι απαραίτητα. Fine-tuning μπορεί περαιτέρω να ενισχύσει την απόδοση των μεθόδων, αλλά είναι λιγότερο αποτελεσματική μερικές φορές.

4.3.2 Μοντέλο DAN (Distance-weighted Auto-regularized Neural network)

Οι Li et al (2024b), στην εργασία τους προτείνουν το DAN, ένα νευρωνικό μοντέλο για μακροπρόθεσμη πρόβλεψη χρονοσειρών όπου συνυπάρχουν μακρινές εξαρτήσεις και σπάνιες αλλά κρίσιμες ακραίες τιμές. Κεντρική ιδέα είναι η πολική αναπαράσταση (polar representation) όπου το μοντέλο μαθαίνει δύο ξεχωριστούς, αλλά συνεργαζόμενους χώρους χαρακτηριστικών έναν που ειδικεύεται στα μακρινά ("far") και έναν στα κανονικά ("near") σημεία της σειράς, ώστε τα ακραία να μη «χαθούν» μέσα στην κυριαρχία των συνηθισμένων τιμών. Παράλληλα, αξιοποιεί δείκτες (indicators) από εξωγενείς μεταβλητές ή αν δεν υπάρχουν, δημιουργεί τεχνητό δείκτη από Gaussian Mixture Model (GMM) για να ενισχύσει την πληροφορία σε μονομεταβλητές σειρές.

Αρχιτεκτονικά, το DAN οργανώνεται σε δύο στάδια, το RepGen και το RepMerg. Στο RepGen (δημιουργία αναπαραστάσεων) υπάρχουν τρία παράλληλα encoder-decoder blocks, ένα για τα μακρινά (far), ένα για τα κοντινά (near) και ένα για τον δείκτη (indicator). Στο μοντέλο εντάσσεται ένα στρώμα βελτίωσης δείκτη (indicator refine layer), στο οποίο δύο μικρά συνελκτικά δίκτυα επεξεργάζονται τον δείκτη σε τοπικά χρονικά παράθυρα, ενισχύοντας την πληροφορία του (αποθορυβοποίηση και ανάδειξη τοπικών μοτίβων). Το υποσύστημα RepGen είναι στοιβαγμένο (stacked) και έτσι μπορεί να εφαρμοστεί επανειλημμένα, ώστε κάθε διέλευση να βελτιώνει σταδιακά την ποιότητα των παραγόμενων αναπαραστάσεων.

Στο στάδιο RepMerg (συγχώνευση αναπαραστάσεων) οι τρεις ροές far, near και indicator ενοποιούνται με δομημένο τρόπο όπου ένα υποσύστημα LSTM-Fully Connected αρχικοποιείται με τη far αναπαράσταση (ώστε να περιέχει την πληροφορία για ακραίες συμπεριφορές) και δέχεται ως είσοδο τη σειρά του δείκτη. Η έξοδός του στη συνέχεια συνδυάζεται με την πρόβλεψη της near ροής μέσω διανυσμάτων πυλών ελέγχου m_{near}, m_{far} όπου τα οποία μαθαίνονται από το μοντέλο και εξαρτώνται από τον δείκτη. Οι πύλες αυτές καθορίζουν, σε κάθε χρονική στιγμή, το σχετικό βάρος των δύο κλάδων (πόσο θα συμβάλει η far έναντι της near), με στόχο να τονίζεται όταν χρειάζεται η πληροφορία των ακραίων χωρίς να θυσιάζεται η ακρίβεια στις κανονικές τιμές. Το αποτέλεσμα είναι μια προσαρμοστική συγχώνευση, που εστιάζει στα κρίσιμα σημεία της χρονοσειράς και παράγει την τελική πρόβλεψη.



Εικόνα 17: Το framework του μοντέλου DAN (Li et al., 2024b)

Κομβικό στοιχείο εκπαίδευσης είναι μια πολλαπλή, αποστασιοσταθμισμένη συνάρτηση κόστους (distance-weighted multi-loss) που ορίζονται βάρη ανά σημείο που δίνουν μεγαλύτερη βαρύτητα στα άκρα (far) και μικρότερη στις κοντινές τιμές (near). Συγκεκριμένα χρησιμοποιούνται βάρη $w_f = (\tanh y)^2$ για τα άκρα, $w_n = (1 - |\tanh y|)^2$ για τα κοντινά και $w_p = \sqrt{w_f}$ για μια ενδιάμεση ρύθμιση. Πάνω σε αυτά ορίζονται τέσσερις όροι loss που ρυθμίζουν τις πολικές προβλέψεις και τον δείκτη, μαζί με τον βασικό RMSE.

Ένας ρυθμιζόμενος συντελεστής λ μειώνεται σταδιακά ανά εποχή ώστε στην αρχή της εκπαίδευσης οι κανονιστικοί όροι έχουν μεγαλύτερο βάρος και καθοδηγούν έντονα το μοντέλο, ενώ όσο προχωρά η εκπαίδευση το βάρος τους μειώνεται, ώστε το μοντέλο να εστιάζει περισσότερο στο βασικό στόχο πρόβλεψης. Επιπλέον, για την ανισορροπία (σπανιότητα ακραίων) εφαρμόζεται Kruskal–Wallis sampling όπου γίνεται υπερδειγματοληψία ακολουθιών με υψηλή τιμή του στατιστικού H (υποδηλώνει ετερογένεια - πιθανή παρουσία άκρων), ώστε το μοντέλο να βλέπει αρκετά ακραία γεγονότα.

Πειραματικά, το DAN αξιολογείται σε τέσσερα πραγματικά υδρολογικά σύνολα δεδομένων και υπερτερεί σημαντικά τόσο έναντι εξειδικευμένων υδρολογικών μοντέλων (π.χ. NEC+) όσο και γενικών μεθόδων για long-term forecasting (Informer, FEDformer κ.ά.). Επίσης φαίνεται πως κάθε συνιστώσα (πολικές αναπαραστάσεις, refine layer, gate vectors, Kruskal–Wallis sampling, multi-loss) συνεισφέρει μετρήσιμα στο συνολικό κέρδος, ιδίως στην ακρίβεια των αιχμών (peaks) χωρίς να θυσιάζεται η επίδοση στα κανονικά σημεία. Συνολικά, το DAN προσφέρει ένα ενιαίο, end-to-end πλαίσιο που λειτουργεί καλά στην πρόβλεψη ακραίων φαινομένων.

Κεφάλαιο 5: Πειραματικό Μέρος

Στο παρόν κεφάλαιο παρουσιάζεται αναλυτικά το πειραματικό σκέλος της διπλωματικής εργασίας, το οποίο αφορά την αξιολόγηση της αποδοτικότητας μοντέλων βαθιάς μάθησης σε προβλήματα πρόβλεψης χρονοσειρών περιβαλλοντικών δεδομένων, καθώς και τη σύγκρισή τους με πιο απλές κλασικές μεθόδους πρόβλεψης. Για την υλοποίηση και τη δοκιμή των μεθόδων, χρησιμοποιήθηκαν τρία διαφορετικά σύνολα δεδομένων που αφορούν περιβαλλοντικά δεδομένα, με στόχο να εξεταστεί η συμπεριφορά των μοντέλων σε διαφορετικές μορφές και χαρακτηριστικά χρονοσειρών.

Πιο συγκεκριμένα, το πρώτο σύνολο δεδομένων περιλαμβάνει μετρήσεις θερμοκρασίας στην περιοχή του Χονγκ Κονγκ. Πρόκειται για μια σχετικά ομαλή χρονοσειρά, με εποχιακές διακυμάνσεις και περιοδικότητα, κατάλληλη για τη βασική αξιολόγηση της ικανότητας των μοντέλων να αναγνωρίζουν πρότυπα σε μακροχρόνιες περιόδους.

Το δεύτερο σύνολο δεδομένων περιλαμβάνει δεδομένα ιστορικών σεισμικών εντάσεων για την περιοχή της Καλιφόρνια. Χαρακτηρίζεται από σπάνιες και απότομες κορυφώσεις και βυθισεις, δηλαδή ακραίες τιμές αλλά και περιόδους σχεδόν μηδενικής δραστηριότητας, οι οποίες δημιουργούν ιδιαίτερες προκλήσεις για τις μεθόδους πρόβλεψης, καθώς απαιτείται να αναγνωρίσουν δυσερμήνευτα γεγονότα και μη γραμμικές δυναμικές.

Το τρίτο σύνολο δεδομένων αποτελείται από μετρήσεις βροχόπτωσης στην περιοχή του Σίδνεϊ, επίσης με παρουσία ακραίων τιμών. Η χρονοσειρά αυτή περιλαμβάνει συχνές διακυμάνσεις και περιόδους πολύ μικρής δραστηριότητας, γεγονός που την καθιστά κατάλληλη για τη μελέτη μοντέλων που καλούνται να προβλέψουν τόσο την έναρξη όσο και την ένταση έντονων φαινομένων.

Η παρουσίαση ξεκινά με την περιγραφή των τριών συνόλων δεδομένων, εστιάζοντας στη δομή, την έκτασή τους και τα βασικά στατιστικά χαρακτηριστικά που τις διακρίνουν. Στη συνέχεια, παρατίθεται η πειραματική διαδικασία, περιλαμβάνοντας τις επιλεγμένες αρχιτεκτονικές βαθιάς μάθησης (όπως LSTM, GRU κ.α.) καθώς και τις παραδοσιακές μεθόδους πρόβλεψης (όπως ARIMA και SARIMA), οι οποίες χρησιμοποιούνται ως σημεία αναφοράς. Παρουσιάζονται επίσης τα κριτήρια αξιολόγησης των επιδόσεων (RMSE και MAE).

Τέλος, γίνεται σύγκριση των αποτελεσμάτων ανάμεσα στις διαφορετικές προσεγγίσεις και αναλύονται τα πλεονεκτήματα και οι αδυναμίες κάθε μεθόδου. Η ανάλυση αυτή οδηγεί σε


σημαντικά συμπεράσματα σχετικά με την καταλληλότητα των μοντέλων βαθιάς μάθησης στην πρόβλεψη χρονοσειρών με ποικίλα χαρακτηριστικά, και ιδίως στην πρόβλεψη σπάνιων ή ακραίων περιβαλλοντικών φαινομένων.

5.1 Δεδομένα


5.1.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ

Το πρώτο σύνολο δεδομένων που χρησιμοποιήθηκε στην παρούσα εργασία αφορά μετρήσεις μεγίστων μηνιαίων θερμοκρασιών στην περιοχή του Χονγκ Κονγκ και προέρχεται από την επίσημη διαδικτυακή πύλη data.gov.hk, η οποία φιλοξενεί δεδομένα του Παρατηρητηρίου του Χονγκ Κονγκ (Hong Kong Observatory - HKO). Το αρχικό σύνολο δεδομένων περιελάμβανε λεπτομερείς εγγραφές (49.002 εγγραφές) για τη μέγιστη ημερήσια θερμοκρασία (κλίμακα Κελσίου, °C) στον σταθμό παρατήρησης για την χρονική περίοδο από τον Ιανουάριο του 1884 έως και τον Φεβρουάριο του 2025. Λόγω ενός μεγάλου κενού που υπάρχει στα δεδομένα (missing values) για την περίοδο από το 1940 έως και το 1946, επιλέχθηκε να εξεταστεί η περίοδος 1947-2025.


Τα δεδομένα μετασχηματίστηκαν από ημερήσιες σε μέγιστες μηνιαίες θερμοκρασίες καθώς διατηρήθηκε για κάθε μήνα η μέγιστη τιμή. Ο στόχος αυτού του μετασχηματισμού ήταν η μείωση του πλήθους των εγγραφών και η εστίαση στην ανίχνευση και πρόβλεψη θερμοκρασιακών αιχμών, οι οποίες είναι πιο κρίσιμες σε εφαρμογές όπως η πρόβλεψη καυσώνων ή η μελέτη των επιπτώσεων της κλιματικής αλλαγής καθώς επίσης προκειμένου το υπολογιστικό σύστημα που υπάρχει διαθέσιμο να ανταπεξέλθει στις απαιτήσεις των μοντέλων. Το μετασχηματισμένο dataset περιλαμβάνει 938 εγγραφές, που αντιστοιχούν σε μηνιαίες μέγιστες θερμοκρασίες από τον Ιανουάριο του 1947 έως τον Φεβρουάριο του 2025. Αυτό υποδεικνύει συνεχή μηνιαία κάλυψη για 78+ έτη. Η χρονοσειρά που προκύπτει εμφανίζει ισχυρή εποχικότητα χωρίς έντονες ακραίες τιμές. Υπάρχουν ενδείξεις ήπιας αυξητικής τάσης στις κορυφές των τελευταίων δεκαετιών και η κατανομή είναι ασύμμετρη με μια συγκέντρωση γύρω από τους 32–34°C.



Εικόνα 18: Χρονοσειρά μέγιστης μηνιαίας θερμοκρασίας στο σταθμό του Παρατηρητηρίου του Χονγκ Κονγκ για την περίοδο 1/1947 έως 2/2025.



Εικόνα 19: Κατανομή μέγιστων μηνιαίων θερμοκρασιών στο σταθμό του Παρατηρητηρίου του Χονγκ Κονγκ για την περίοδο 1/1947 έως 2/2025.



Εικόνα 20: Αποσύνθεση χρονοσειράς μέγιστων μηνιαίων θερμοκρασιών στο σταθμό του Παρατηρητηρίου του Χονγκ Κονγκ για την περίοδο 1/1947 έως 2/2025.


5.1.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια

Το δεύτερο σύνολο δεδομένων που χρησιμοποιήθηκε στην παρούσα εργασία αφορά σεισμικές εντάσεις που έχουν καταγραφεί στην πολιτεία της Καλιφόρνια, με στόχο τη μελέτη της ικανότητας των μοντέλων πρόβλεψης να εντοπίζουν ακραία και σπάνια φαινόμενα σεισμών. Τα δεδομένα έχουν ληφθεί από την Εθνική Βάση Δεδομένων Γεωκινδύνων της NOAA (NGDC – National Geophysical Data Center) και περιλαμβάνονται στη συλλογή με τίτλο "Significant Earthquake Database" (κωδικός: G01142). Το αρχικό σύνολο δεδομένων αποτελείται από περισσότερες από 150.000 παρατηρήσεις σεισμικών εντάσεων (σε κλίμακα Modified Mercalli Index - MMI) και πρόκειται για μια συλλογή αναφορών ζημιών και αισθητών παρατηρήσεων για πάνω από 23.000 σεισμούς στις ΗΠΑ από το 1638-1985. Η πλειοψηφία των εντάσεων είναι για πόλεις των ΗΠΑ, αλλά υπάρχουν επίσης μερικοί σεισμοί


και εντάσεις για τον Παναμά (1925-1975), τις Φιλιππίνες (1926-1937) και το Μεξικό (1887-1981) (USGS, 2025).

Απο τα αρχικά δεδομένα διατηρήθηκαν και χρησιμοποιήθηκαν μόνο οι μέγιστες μηνιαίες σεισμικές εντάσεις για την πολιτεία της Καλιφόρνια. Τα δεδομένα μέχρι και το 1914 φαίνεται να είναι ελλιπή με πολλές ελλειπούσες τιμές και για αυτο το λόγω ως χρονική περίοδος ενδιαφέροντος ορίστηκε η περίοδος από το Ιανουάριο του 1915 έως και των Δεκέμβριο του 1985 και μόνο για την πολιτεία της Καλιφόρνια διότι για αυτή τη περιοχή υπάρχουν πληρέστερες παρατηρήσεις με το πλήθος των μηνιαίων μεγίστων παρατηρήσεων να είναι 852.


Όπως φαίνεται και απο τα διαγράμματα των Εικόνων 21 και 22, οι περισσότερες τιμές κυμαίνονται μεταξύ 5 και 6, γεγονός που δείχνει συγκέντρωση γύρω από μέτριες εντάσεις ενώ υπάρχουν σχετικά σπάνιες υψηλές τιμές (π.χ. 9–11), οι οποίες λειτουργούν ως ακραία φαινόμενα. Η χρονοσειρά φαίνεται να παρουσιάζει έντονη στοχαστικότητα και μη περιοδική συμπεριφορά καθώς δεν φαίνεται να υπάρχουν επαναλαμβανόμενα μοτίβα, όπως θα συνέβαινε σε εποχικές σειρές. Η αποσύνθεση της σειράς επιβεβαιώνει ότι η εποχικότητα είναι αμελητέα καθώς το seasonal component είναι σχεδόν μηδενικό ενώ η τάση εμφανίζει μικρές διακυμάνσεις, αλλά δεν ακολουθεί σαφή αυξητική ή φθίνουσα πορεία, συνεπώς θα μπορούσαμε να πουμε ότι είναι παρούσα αλλά αδύναμη.



Εικόνα 21: Χρονοσειρά μέγιστης μηνιαίας σεισμικής έντασης στην πολιτεία της Καλιφόρνια για την περίοδο 1/1915 έως 12/1985.



Εικόνα 22: Κατανομή μέγιστης μηνιαίας σεισμικής έντασης στην πολιτεία της Καλιφόρνια για την περίοδο 1/1915 έως 12/1985.




Εικόνα 23: Αποσύνθεση χρονοσειράς μέγιστης μηνιαίας σεισμικής έντασης στην πολιτεία της Καλιφόρνια για την περίοδο 1/1915 έως 12/1985.


5.1.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ

Το τρίτο και τελευταίο σύνολο δεδομένων που χρησιμοποιήθηκε αφορά τη συνολική μηνιαία βροχόπτωση στην περιοχή του Σίδνεϊ, όπως καταγράφηκε στον μετεωρολογικό σταθμό SYDNEY (OBSERVATORY HILL). Τα δεδομένα προέρχονται από το Αυστραλιανό Γραφείο Μετεωρολογίας (Bureau of Meteorology) και καλύπτουν μία από τις πιο μακρόχρονες και πληρέστερες κλιματολογικές σειρές στην περιοχή, καλύπτοντας την περίοδο από τον Ιούλιο του 1858 έως τον Αύγουστο του 2020, δηλαδή συνολικά 1944 παρατηρήσεις.


Τα δεδομένα παρουσιάζουν ισχυρή εποχικότητα, ισχυρή μεταβλητότητα και ασυμμετρία στην κατανομή με κυρίαρχες τιμές μεταξύ 0–150 mm και περιορισμένες αλλά σημαντικές ακραίες τιμές που ξεπερνούν τα 500 mm. Η σειρά χαρακτηρίζεται από απότομες διακυμάνσεις μεταξύ διαδοχικών μηνών, με συχνές μεταβάσεις από ξηρούς σε πολύ υγρούς μήνες, κάτι που καθιστά την πρόβλεψη πιο απαιτητική, ειδικά για μοντέλα που βασίζονται σε γραμμικές ή κανονικές υποθέσεις. Τέλος, η παρουσία ακραίων φαινομένων σε συνδυασμό με μεταβαλλόμενες τάσεις και την υψηλή μεταβλητότητα καθιστά τη χρονοσειρά απαιτητική για πρόβλεψη.



Εικόνα 24: Χρονοσειρά συνολικής μηνιαίας βροχόπτωσης στο Σίδνεϊ για την περίοδο 7/1858 έως 8/2020.



Εικόνα 25: Κατανομή συνολικής μηνιαίας βροχόπτωσης στο Σίδνεϊ για την περίοδο 7/1858 έως 8/2020.



Εικόνα 26: Αποσύνθεση χρονοσειράς συνολικής μηνιαίας βροχόπτωσης στο Σίδνεϊ για την περίοδο 7/1858 έως 8/2020.

5.2 Πειράματα - Αποτελέσματα

Στην ενότητα αυτή παρουσιάζονται οι παράμετροι που επιλέχθηκαν για την εκπαίδευση και αξιολόγηση των μοντέλων πρόβλεψης, καθώς και τα αποτελέσματα που προέκυψαν για κάθε ένα από τα τρία σύνολα δεδομένων που χρησιμοποιήθηκαν. Η προσέγγιση είναι μονομεταβλητή (univariate), καθώς χρησιμοποιείται μόνο η υπό εξέταση κάθε φορά μεταβλητή (θερμοκρασία, σεισμική ένταση, βροχόπτωση). Η επιλογή των υπερπαραμέτρων και η διαμόρφωση της αρχιτεκτονικής κάθε μοντέλου βασίστηκε σε πειραματική διερεύνηση, με στόχο τη βέλτιστη απόδοση ως προς συγκεκριμένους δείκτες αξιολόγησης. Για κάθε χρονοσειρά παρουσιάζονται αναλυτικά τα μοντέλα που εφαρμόστηκαν, οι παράμετροι που χρησιμοποιήθηκαν σε κάθε περίπτωση, καθώς και η συγκριτική απόδοσή τους.

Επίσης παρουσιάζονται για κάθε περίπτωση η τιμές των μετρικών που προέκυψαν. Για την αξιολόγηση της απόδοσης των μοντέλων χρησιμοποιήθηκαν οι μετρικές RMSE και MAE, οι οποίες χρησιμοποιούνται καθολικά στη βιβλιογραφία πρόβλεψης χρονοσειρών και συνεπώς είναι ευρέως αποδεκτές για τέτοιους σκοπούς και επίσης μπορούν να συγκριθούν εύκολα με άλλα μοντέλα. Και οι δύο μετρικές εκφράζονται στη μονάδα του στόχου (π.χ. mm βροχόπτωσης, μονάδες έντασης κ.λπ.), άρα τα αποτελέσματα είναι κατανοητά και πρακτικά.

Η RMSE δίνει μεγαλύτερη έμφαση σε μεγάλες αποκλίσεις, ενώ η MAE προσφέρει μια πιο σταθερή εκτίμηση του μέσου σφάλματος. Η ταυτόχρονη χρήση τους παρέχει μια ολοκληρωμένη εικόνα της ακρίβειας και της σταθερότητας των μοντέλων καθώς για παράδειγμα αν $RMSE \gg MAE$ τότε υπάρχουν μεγάλα σφάλματα ή outliers ενώ αν $RMSE \approx MAE$ τότε τα σφάλματα είναι ομοιόμορφα κατανομημένα. Ωστόσο, αναγνωρίζεται ότι οι συγκεκριμένες μετρικές δεν λαμβάνουν υπόψη το σχετικό μέγεθος των τιμών, ούτε την κατεύθυνση του σφάλματος,


Κάθε ένα από τα τρία σύνολα δεδομένων τροφοδοτήθηκε σε επτά διαφορετικά μοντέλα πρόβλεψης καλύπτοντας τόσο κλασικές στατιστικές μεθόδους όσο και σύγχρονες προσεγγίσεις βαθιάς μάθησης. Τα μοντέλα **ARIMA** και **SARIMA** είναι γραμμικά στατιστικά μοντέλα, κατάλληλα για χρονοσειρές με στασιμότητα και εποχικότητα αντίστοιχα. Τα μοντέλα **CNN** και **GRU** ανήκουν στην κατηγορία των νευρωνικών δικτύων βαθιάς μάθησης, με το CNN να εντοπίζει τοπικά μοτίβα και το GRU να διαχειρίζεται χρονικές εξαρτήσεις. Το **DAN** είναι επίσης ένα νευρωνικό δίκτυο, σχεδιασμένο για να δίνει μεγαλύτερη έμφαση σε σπάνια ή ακραία παραδείγματα. Τα μοντέλα **Reweight_EVT** και **Reweight_META** βασίζονται σε τεχνικές επαναπροσδιορισμού βαρών (reweighting) και ενσωματώνουν στοιχεία από θεωρία ακραίων τιμών και μεταμάθησης (meta-learning) αντίστοιχα, στοχεύοντας ειδικά στη βελτίωση της πρόβλεψης ακραίων τιμών σε χρονοσειρές.

5.2.1 ARIMA


5.2.1.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ

Προκειμένου να τροφοδοτηθούν στο μοντέλο ARIMA τα δεδομένα μεγίστων μηνιαίων θερμοκρασιών για την εκπαίδευση του μοντέλου, θα πρέπει πρώτα να χωριστούν σε σύνολο εκπαίδευσης (train set) και σύνολο επικύρωσης (test set). Ορίζεται λοιπόν ως σύνολο εκπαίδευσης το 85% του συνόλου και πρόκειται για την περίοδο από τον Ιανουάριο του 1947 έως και τον Δεκέμβριο του 2012 (792 εγγραφές) ενώ το υπόλοιπο 15% αποτελεί το σύνολο επικύρωσης (146 εγγραφές) και πρόκειται για την περίοδο από τον Ιανουάριο του 2013 έως και τον Φεβρουάριο του 2025.

Στην συνέχεια υπολογίζονται οι παράμετροι του μοντέλου (p , d , q) χρησιμοποιώντας την συνάρτηση `auto_arima` της βιβλιοθήκης `rmдарima`, ορίζοντας ως κριτήριο πληροφoρίας το AIC. Τα αποτελέσματα έδειξαν ότι το καλύτερο μοντέλο είναι το ARIMA(2,0,3) και έτσι η εκπαίδευση του μοντέλου έγινε με βάση αυτές τις τιμές. Παρακάτω παρουσιάζεται διάγραμμα στο οποίο έχει αποτυπωθεί η απόδοση του μοντέλου. Επίσης δίνονται και τα αποτελέσματα των μετρικών.



Εικόνα 27: Μέγιστη μηνιαία θερμοκρασία: πλήρης χρονοσειρά πραγματικών τιμών και προβλέψεις ARIMA για τα τελευταία έτη.



Εικόνα 28: Σύγκριση πραγματικών και προβλέψεων ARIMA για την περίοδο 2013–2025.


RMSE: 1.75, MAE: 1.40

Το μοντέλο ARIMA φαίνεται να πετυχαίνει καλή ακρίβεια πρόβλεψης για το παρών σύνολο δεδομένων με χαμηλές τιμές σφάλματος και σωστή αναπαραγωγή της εποχικότητας της σειράς καταφέροντας να αναπαράγει τις επαναλαμβανόμενες αυξομειώσεις που παρουσιάζει η σειρά, κάτι που δείχνει ότι έχει μάθει την εποχική δυναμική της σειράς, ακόμη και αν πρόκειται για «καθαρό» ARIMA. Ωστόσο, φαίνεται μια υστέρηση στις τιμές πρόβλεψης καθώς επίσης και μια εξομάλυνση στις αιχμές μην αποδίδοντας με ακρίβεια τις μεγαλύτερες τιμές, έτσι οι διαφορές μεταξύ RMSE και MAE δείχνει ότι, αν και τα περισσότερα σφάλματα είναι μικρά, υπάρχουν ορισμένες τιμές με μεγαλύτερη απόκλιση. Αυτό είναι τυπικό πρόβλημα στα γραμμικά μοντέλα όπως το ARIMA, τα οποία έχουν περιορισμένη ικανότητα πρόβλεψης ασυνήθιστα μικρών ή μεγάλων τιμών.


5.2.1.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια

Προκειμένου να τροφοδοτηθούν στο μοντέλο ARIMA τα δεδομένα μεγίστων μηνιαίων σεισμικών εντάσεων για την εκπαίδευση του μοντέλου, θα πρέπει πρώτα να χωριστούν σε σύνολο εκπαίδευσης και σύνολο επικύρωσης. Ορίζεται λοιπόν ως σύνολο εκπαίδευσης το 80% του συνόλου και πρόκειται για την περίοδο από τον Ιανουάριο του 1915 έως και τον Δεκέμβριο του 1971 (684 εγγραφές) ενώ το υπόλοιπο 20% αποτελεί το σύνολο επικύρωσης (168 εγγραφές) και πρόκειται για την περίοδο από τον Ιανουάριο του 1972 έως και τον Δεκέμβριο του 1985.

Στην συνέχεια υπολογίζονται οι παράμετροι του μοντέλου (p , d , q) χρησιμοποιώντας την συνάρτηση `auto_arima`, ορίζοντας ως κριτήριο πληροφoρίας το AIC. Τα αποτελέσματα έδειξαν ότι το καλύτερο μοντέλο είναι το ARIMA(0,1,1) και έτσι η εκπαίδευση του μοντέλου έγινε με βάση αυτές τις τιμές. Παρακάτω παρουσιάζεται διάγραμμα στο οποίο έχει αποτυπωθεί η απόδοση του μοντέλου. Επίσης δίνονται και τα αποτελέσματα των μετρικών.



Εικόνα 29: Μέγιστη μηνιαία σεισμική ένταση: πλήρης χρονοσειρά πραγματικών τιμών και προβλέψεις ARIMA για τα τελευταία έτη.



Εικόνα 30: Σύγκριση πραγματικών και προβλέψεων ARIMA για την περίοδο 1/1972–12/1985.

RMSE: 0.95, MAE: 0.77

Παρότι οι μετρικές σφάλματος RMSE και MAE εμφανίζονται αριθμητικά μικρές, το μοντέλο ARIMA δεν παρουσιάζει ικανότητα παρακολούθησης της δυναμικής της σεισμικής έντασης.


Οι τιμές της MMI στο σύνολο δεδομένων κυμαίνονται από 1 έως 11, με πολλές τιμές γύρω στο 5–6, άρα, ένα σφάλμα της τάξης του 0.95 μπορεί να θεωρηθεί σχετικά μεγάλο σε σχέση με το εύρος των τιμών (π.χ. 0.95 απόκλιση σε τιμή 5 είναι ~19% σφάλμα).

Το μοντέλο φαίνεται να εξομαλύνει τις προβλέψεις του που είναι σχεδόν σταθερές γύρω από τη μέση τιμή, αποτυγχάνοντας να αποτυπώσει τις διακυμάνσεις τόσο κανονικών πόσο μάλλον ακραίων τιμών που χαρακτηρίζουν τη χρονοσειρά. Το μοντέλο φαίνεται να μην ανταποκρίνεται ούτε στις αυξήσεις ούτε στις απότομες πτώσεις. Θα μπορούσε να ειπωθεί πως αυτό είναι αναμενόμενο σε σειρές με χαμηλή περιοδικότητα, υψηλό θόρυβο και σπάνια, ακραία γεγονότα, όπως μια σεισμική χρονοσειρά. Το αποτέλεσμα αυτό αντικατοπτρίζει τον περιορισμό των γραμμικών μοντέλων σε περιβάλλοντα με υψηλή στοχαστικότητα και απουσία σαφούς εποχικότητας ή τάσης.


5.2.1.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ

Προκειμένου να τροφοδοτηθούν στο μοντέλο ARIMA τα δεδομένα μηνιαίων βροχοπτώσεων για την εκπαίδευση του μοντέλου, θα πρέπει πρώτα να χωριστούν σε σύνολο εκπαίδευσης και σύνολο επικύρωσης. Ορίζεται λοιπόν ως σύνολο εκπαίδευσης το 80% του συνόλου και πρόκειται για την περίοδο από τον Ιούνιο του 1858 έως και τον Δεκέμβριο του 1987 (1554 εγγραφές) ενώ το υπόλοιπο 20% αποτελεί το σύνολο επικύρωσης (390 εγγραφές) και πρόκειται για την περίοδο από τον Ιανουάριο του 1988 έως και τον Αύγουστο του 2020.

Στην συνέχεια υπολογίζονται οι παράμετροι του μοντέλου (p , d , q) χρησιμοποιώντας την συνάρτηση `auto_arima`, ορίζοντας ως κριτήριο πληροφορίας το AIC και τα αποτελέσματα το έδειξαν ότι το καλύτερο μοντέλο είναι το ARIMA(1,0,0) και έτσι η εκπαίδευση του μοντέλου έγινε με βάση αυτές τις τιμές. Παρακάτω παρουσιάζεται διάγραμμα στο οποίο έχει αποτυπωθεί η απόδοση του μοντέλου. Επίσης δίνονται και τα αποτελέσματα των μετρικών.



Εικόνα 31: Συνολική μηνιαία βροχόπτωση: πλήρης χρονοσειρά πραγματικών τιμών και προβλέψεις ARIMA για τα τελευταία έτη.



Εικόνα 32: Σύγκριση πραγματικών και προβλέψεων ARIMA για την περίοδο 1/1988–8/2020.

RMSE: 90.22, MAE: 65.91


Το μοντέλο ARIMA παρουσίασε και σε αυτή την περίπτωση πάρα πολύ χαμηλή απόδοση στην πρόβλεψη των μηνιαίων βροχοπτώσεων, με υψηλές τιμές σφάλματος. Αν και οι αριθμητικές τιμές μπορεί να φαίνονται αναμενόμενες λόγω του μεγάλου εύρους της χρονοσειράς όπου η βροχόπτωση κυμαίνεται από 0 έως 600+ mm, το μοντέλο απέτυχε να αποτυπώσει τις απότομες διακυμάνσεις και τα ακραία γεγονότα, και περιορίστηκε σε προβλέψεις γύρω από τον μέσο όρο, σημαντικά εξομαλυμένες που δεν ακολουθούν καθόλου τις αιχμές της πραγματικής σειράς. Το RMSE είναι σημαντικά υψηλότερο από το MAE, που σημαίνει ότι υπάρχουν αρκετές προβλέψεις με πολύ μεγάλο σφάλμα.

Η έλλειψη δυναμικής προσαρμογής σε εποχικά μοτίβα και ακραίες τιμές καθιστά το ARIMA ακατάλληλο για πρόβλεψη σε τέτοιου τύπου δεδομένων, λειτουργώντας κυρίως ως baseline σύγκρισης με πιο σύνθετα μοντέλα. Αυτό είναι αναμενόμενο σε γραμμικά μοντέλα, τα οποία δεν έχουν την ικανότητα να προσαρμόζονται σε στοχαστικές και μη γραμμικές εξάρσεις.


5.2.2 SARIMA

5.2.2.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ

Αρχικά υπολογίζονται οι παράμετροι του μοντέλου $(p,d,q) \times (P,D,Q,s)$ χρησιμοποιώντας την συνάρτηση `auto_arima` και προσθέτοντας τις παραμέτρους `seasonal=True`, `m=12` στην συνάρτηση προκειμένου να γίνει αναζήτηση για ένα εποχιακό μοντέλο, ορίζοντας ως κριτήριο πληροφoρίας το AIC. Τα αποτελέσματα έδειξαν ότι το καλύτερο μοντέλο είναι το SARIMA(1,0,0)(1,0,2,12) και έτσι η εκπαίδευση του μοντέλου έγινε με βάση αυτές τις τιμές. Παρακάτω παρουσιάζεται διάγραμμα στο οποίο έχει αποτυπωθεί η απόδοση του μοντέλου. Επίσης δίνονται και τα αποτελέσματα των μετρικών.



Εικόνα 33: Μέγιστη μηνιαία θερμοκρασία: πλήρης χρονοσειρά πραγματικών τιμών και προβλέψεις SARIMA για τα τελευταία έτη.




Εικόνα 34: Σύγκριση πραγματικών και προβλέψεων SARIMA για την περίοδο 2013–2025.

RMSE: 1.22, MAE: 0.94

Οι τιμές σφάλματος του SARIMA μοντέλου φαίνεται να είναι βελτιωμένες σε σχέση με το μοντέλο ARIMA (το οποίο είχε $RMSE = 1.75$ και $MAE = 1.40$). Παρόλα αυτά μια ποιοτική εκτίμηση των αποτελεσμάτων δεν δείχνει αισθητή βελτίωση των προβλέψεων. Το SARIMA αποτυπώνει ελάχιστα καλύτερα την εποχικότητα σε σχέση με το απλό ARIMA μοντέλο, ωστόσο εξακολουθεί και εκείνο να εξομαλύνει τις διακυμάνσεις και δεν ανταποκρίνεται με ακρίβεια στις ακραίες τιμές της χρονοσειράς. Σημαντική βελτίωση φαίνεται στο ότι δεν παρατηρούνται σημαντικές υστερήσεις στις προβλεπόμενες τιμές με την ταύτισή τους με την πραγματική σειρά να είναι καλύτερη,


Αν και θεωρητικά το SARIMA είναι πιο κατάλληλο για δεδομένα με έντονη εποχικότητα όπως οι θερμοκρασίες, στο συγκεκριμένο παράδειγμα οι διαφορές των προβλέψεων μεταξύ των μοντέλων ARIMA & SARIMA είναι ανεπαίσθητες ως προς το εύρος των προβλεπόμενων τιμών. Από το διάγραμμα προκύπτει ότι και τα δύο μοντέλα αποδίδουν ικανοποιητικά, ωστόσο το SARIMA προσαρμόζεται καλύτερα στις λεπτομέρειες της χρονοσειράς, αποτυπώνοντας πιο πιστά ως προς τις χρονικές υστερήσεις αλλά το ίδιο ως προς τις μεγαλύτερες και χαμηλότερες τιμές (Εικόνα 35).




Εικόνα 35: Μέγιστη μηνιαία θερμοκρασία: ποιοτική σύγκριση προβλέψεων μοντέλων SARIMA (πορτοκαλί) και ARIMA (πράσινο).

5.2.2.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια

Αρχικά υπολογίζονται οι παράμετροι του μοντέλου $(p,d,q) \times (P,D,Q,s)$ χρησιμοποιώντας την συνάρτηση `auto_arima` και προσθέτοντας τις παραμέτρους `seasonal=True`, `m=12` στην συνάρτηση προκειμένου να γίνει αναζήτηση για ένα εποχιακό μοντέλο, ορίζοντας ως κριτήριο πληροφορίας το AIC. Τα αποτελέσματα έδειξαν ότι το καλύτερο μοντέλο είναι το SARIMA(0,1,1)(1,0,1,12) και έτσι η εκπαίδευση του μοντέλου έγινε με βάση αυτές τις τιμές. Παρακάτω παρουσιάζεται διάγραμμα στο οποίο έχει αποτυπωθεί η απόδοση του μοντέλου. Επίσης δίνονται και τα αποτελέσματα των μετρικών.



Εικόνα 36: Μέγιστη μηνιαία σεισμική ένταση: πλήρης χρονοσειρά πραγματικών τιμών και προβλέψεων SARIMA για τα τελευταία έτη.




Εικόνα 37: Σύγκριση πραγματικών και προβλεπόμενων τιμών SARIMA για την περίοδο 1/1972–12/1985.

RMSE: 0.95, MAE: 0.77

Η εφαρμογή του μοντέλου SARIMA στη χρονοσειρά σεισμικών εντάσεων έδειξε ελάχιστη περιορισμένη πρακτική αξία καθώς αποτυγχάνει να αποδώσει τη δυναμική της χρονοσειράς, με τις τιμές των μετρικών να είναι οι ίδιες με του μοντέλου ARIMA. Όπως φαίνεται στο διάγραμμα, το μοντέλο απέδωσε σταθερές (σχεδόν οριζόντιες) και υπερεξομαλυσμένες προβλέψεις με ελάχιστες διακυμάνσεις γύρω από μια τιμή κοντά στο 5.3. Αυτό δεν ανταποκρίνεται στις έντονες διακυμάνσεις και τις αιχμές της πραγματικής σεισμικής

δραστηριότητας. Αυτό αναδεικνύει τον περιορισμό των γραμμικών εποχικών μοντέλων σε σειρές με υψηλή στοχαστικότητα, ακραίες τιμές και απουσία επαναλαμβανόμενων προτύπων, αναδεικνύοντας την ανάγκη για πιο ευέλικτα και μη γραμμικά μοντέλα πρόβλεψης.




Εικόνα 38: Μέγιστη μηνιαία σεισμική ένταση: ποιοτική σύγκριση προβλέψεων μοντέλων SARIMA (πορτοκαλί) και ARIMA (πράσινο).

Η συγκριτική αξιολόγηση των μοντέλων ARIMA και SARIMA για τη χρονοσειρά των σεισμικών εντάσεων στην Καλιφόρνια δείχνει ότι κανένα από τα δύο δεν είναι κατάλληλο για την αποτύπωση της υποκείμενης δυναμικής. Και τα δύο μοντέλα παράγουν υπερβολικά εξομαλυμένες προβλέψεις που δεν ανταποκρίνονται στις έντονες διακυμάνσεις, με αποτέλεσμα οι προβλέψεις να κινούνται σταθερά σε πολύ στενό εύρος γύρω από τον μέσο όρο της σειράς. Η προσθήκη εποχικότητας στο SARIMA δεν προσφέρει ουσιαστικό πλεονέκτημα, καθώς η συγκεκριμένη χρονοσειρά δεν εμφανίζει περιοδικότητα, αντίθετα προσθέτει περιττή πολυπλοκότητα χωρίς απόδοση. Το αποτέλεσμα υπογραμμίζει την αδυναμία των γραμμικών στατιστικών μοντέλων να διαχειριστούν στοχαστικά, ασταθή και ακραία δεδομένα, όπως είναι αυτά που σχετίζονται με σεισμική δραστηριότητα.


5.2.2.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ

Αρχικά υπολογίζονται οι παράμετροι του μοντέλου $(p,d,q) \times (P,D,Q,s)$ χρησιμοποιώντας την συνάρτηση `auto_arima` και προσθέτοντας τις παραμέτρους `seasonal=True`, `m=12` στην συνάρτηση προκειμένου να γίνει αναζήτηση για ένα εποχιακό μοντέλο, ορίζοντας ως κριτήριο πληροφορίας το AIC. Τα αποτελέσματα έδειξαν ότι το καλύτερο μοντέλο είναι το

SARIMA(0,0,1)(1,0,1,12) και έτσι η εκπαίδευση του μοντέλου έγινε με βάση αυτές τις τιμές. Παρακάτω παρουσιάζεται διάγραμμα στο οποίο έχει αποτυπωθεί η απόδοση του μοντέλου. Επίσης δίνονται και τα αποτελέσματα των μετρικών.



Εικόνα 39: Συνολική μηνιαία βροχόπτωση: πλήρης χρονοσειρά πραγματικών τιμών και προβλέψεων SARIMA για τα τελευταία έτη




Εικόνα 40: Σύγκριση πραγματικών και προβλέψεων ARIMA για την περίοδο 1/1988–8/2020.

RMSE: 89.07, MAE: 64.23

Το μοντέλο SARIMA πέτυχε σχετικά ικανοποιητική απόδοση στην αναπαραγωγή της εποχικότητας των δεδομένων βροχόπτωσης (ετήσιο κύκλο), όπως φαίνεται από τη σταθερή περιοδικότητα των προβλέψεων. Ωστόσο, οι τιμές των μετρικών και η οπτική ανάλυση του διαγράμματος υποδεικνύουν σημαντική δυσκολία στην πρόβλεψη ακραίων γεγονότων και

μεγάλη απόκλιση σε περιόδους υψηλής βροχόπτωσης. Το μοντέλο τείνει να προβλέπει τιμές γύρω από τον μέσο όρο, εξομαλυνοντας υπερβολικά τη στοχαστική συμπεριφορά της χρονοσειράς και αποτυγχάνοντας να εντοπίσει φαινόμενα έντονης βροχόπτωσης. Συνεπώς, παρότι το SARIMA αποτελεί ισχυρό baseline για εποχιακά δεδομένα, αποδεικνύεται ανεπαρκές για σύνολα δεδομένων βροχόπτωσης με έντονες και απρόβλεπτες διακυμάνσεις και ακραίες τιμές όπως το συγκεκριμένο.



Εικόνα 41: Συνολική μηνιαία βροχόπτωση: ποιοτική σύγκριση προβλέψεων μοντέλων SARIMA (πορτοκαλί) και ARIMA (πράσινο).

Από τη σύγκριση των μοντέλων ARIMA και SARIMA στην πρόβλεψη της μηνιαίας βροχόπτωσης, γίνεται φανερό ότι το SARIMA παρουσιάζει σημαντικά καλύτερη συμπεριφορά, καθώς μπορεί να ενσωματώσει την ετήσια εποχικότητα της χρονοσειράς και να προσεγγίσει ικανοποιητικά τη φυσική κυκλικότητα των δεδομένων και παρουσιάζει μεγαλύτερο εύρος διακυμάνσεων σε σύγκριση με το ARIMA. Αντίθετα, το ARIMA εμφανίζεται πλήρως ανεπαρκές, προσφέροντας σταθερές, εξομαλυμένες προβλέψεις (μέσος όρος) καθ' όλη τη διάρκεια της πρόβλεψης που αγνοούν τη δυναμική της σειράς. Παρ' όλα αυτά, ακόμη και το SARIMA δεν καταφέρνει να αποδώσει τις ακραίες τιμές και τις αιχμές που χαρακτηρίζουν τις περιόδους πιο έντονης ή ελάχιστης βροχόπτωσης.

5.2.3 CNN

Στα πλαίσια της παρούσας διπλωματικής, χρησιμοποιήθηκε ένα Συνελικτικό Νευρωνικό Δίκτυο μιας διάστασης (1D-CNN) για την πρόβλεψη των τιμών των υπό εξέταση συνόλων δεδομένων. Ο λόγος που επιλέχθηκε το μοντέλο CNN είναι διότι τα μοντέλα αυτά λειτουργούν γενικά καλά στην καταγραφή τοπικών μοτίβων, τάσεων και

επαναλαμβανόμενων μοτίβων σε δεδομένα χρονοσειρών. Παρόλα αυτά όταν ο πρωταρχικός στόχος είναι η πρόβλεψη ακραίων γεγονότων, τα CNN από μόνα τους μπορεί να μην είναι τα βέλτιστα.

Το δίκτυο 1D-CNN αποτελείται από πέντε στρώματα, δύο διαδοχικά συνελκτικά στρώματα (Conv1D) που εξάγουν χαρακτηριστικά από τη χρονοσειρά, ένα στρώμα Flatten που μετατρέπει τα δεδομένα σε μονοδιάστατη μορφή, ένα πυκνό (Dense) στρώμα για περαιτέρω συνδυασμό χαρακτηριστικών και ένα τελικό στρώμα εξόδου για παλινδρόμηση. Οι συνελκτικές στρώσεις χρησιμοποιούν συνάρτηση ενεργοποίησης ReLU. Το μοντέλο εκπαιδεύτηκε με τον βελτιστοποιητή Adam, χρησιμοποιώντας ως συνάρτηση κόστους το μέσο τετραγωνικό σφάλμα (MSE) και ως μετρική το μέσο απόλυτο σφάλμα (MAE). Τα δεδομένα κανονικοποιήθηκαν στο $[0, 1]$ με MinMaxScaler για καλύτερη εκπαίδευση του νευρωνικού δικτύου ενώ στο τέλος αποκανονικοποιούνται για να επανέλθουν στο επιθυμητό εύρος τιμών. Η συγκεκριμένη αρχιτεκτονική επιβλέπει ότι το μοντέλο θα μπορεί να αναγνωρίζει τόσο τοπικές όσο και γενικότερες εξαρτήσεις στη χρονοσειρά, αξιοποιώντας τα φίλτρα της συνέλιξης για ανίχνευση σημαντικών προτύπων.

Προκειμένου να βρεθούν οι κατάλληλες παράμετροι για το κάθε μοντέλο έγιναν διάφορα πειράματα για διάφορες τιμές για κάποιες από τις σημαντικότερες υπερπαραμέτρους του μοντέλου. Οι υπερπαραμέτροι που επιλέχθηκαν ως σημαντικότερες προκειμένου να γίνουν διάφορα πειράματα είναι:


- 1) Το Μέγεθος παραθύρου εισόδου (n_lag) που είναι ο αριθμός προηγούμενων μηνών που χρησιμοποιήθηκαν για πρόβλεψη και ουσιαστικά ελέγχει πόσο ιστορικό περιβάλλον βλέπει το μοντέλο. Η αξία των πειραμάτων αυτών είναι να δειχθεί πώς η μακροπρόθεσμη έναντι της βραχυπρόθεσμης μνήμης επηρεάζει την πρόβλεψη.
- 2) Ο αριθμός φίλτρων του Conv1D, διότι ελέγχει την ικανότητα του μοντέλου να εξάγει και να μαθαίνει σύνθετα μοτίβα από την ακολουθία εισόδου. Ο υψηλότερος αριθμός φίλτρων μπορεί να αποτυπώσει πιο διαφοροποιημένα χαρακτηριστικά, αλλά μπορεί να οδηγήσουν σε υπερπροσαρμογή (overfitting).
- 3) Το Μέγεθος παρτίδας ($batch_size$), το οποίο επηρεάζει την ταχύτητα και τη σταθερότητα της εκπαίδευσης, τη σύγκλιση και πιθανώς την απόδοση γενίκευσης.

Σε κάθε περίπτωση έγιναν διάφορα πειράματα για διαφορετικές τιμές των παραμέτρων αυτών και παρακάτω παρουσιάζονται τα αποτελέσματα των μετρικών. Συγκεκριμένα η παράμετρος $batch_size$ δοκιμάστηκε για τιμές 16, 32, 64 και 128, η παράμετρος n_lag


δοκιμάστηκε για τιμές 6, 12, 24 και ο αριθμός των φίλτρων του Conv1D δοκιμάστηκε για τιμές 8, 16, 32 και 64.

5.2.3.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ


Τα δεδομένα χωρίστηκαν χρονολογικά σε σύνολο εκπαίδευσης και επικύρωσης με το σύνολο εκπαίδευσης να αποτελεί το 85% των δεδομένων και το σύνολο επικύρωσης να είναι το υπόλοιπο 15% όπως ακριβώς και στα προηγούμενα μοντέλα. Προκειμένου να βρεθούν οι κατάλληλες υπερπαραμέτροι για το μοντέλο έγιναν διάφορα πειράματα για τις διάφορες τιμές τους. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των διαφόρων τιμών για κάθε υπερπάρμετρο.



Εικόνα 42: Επίδραση μεγέθους παρτίδας στην απόδοση του μοντέλου CNN.




Εικόνα 43: Επίδραση του μεγέθους παραθύρου εισόδου στην απόδοση του μοντέλου CNN.



Εικόνα 44: Επίδραση του αριθμού των φίλτρων στο πρώτο συνελικτικού επίπεδο του μοντέλου CNN.

Τα πειραματικά αποτελέσματα υποδεικνύουν ότι το βέλτιστο CNN για το συγκεκριμένο πρόβλημα διαμορφώνεται με batch size ίσο με 64, η_lag ίσο με 24 και αριθμό φίλτρων στο πρώτο Conv1D στρώμα ίσο με 64. Τα αποτελέσματα πρόβλεψης του μοντέλου αυτού δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:

RMSE: 1.22, MAE: 0.95.




Εικόνα 45: Σύγκριση πραγματικής σειράς και CNN προβλέψεων στα δεδομένα μεγίστων μηνιαίων θερμοκρασιών.

Το μοντέλο CNN παρουσιάζει αρκετά καλή απόδοση στην πρόβλεψη της μέγιστης μηνιαίας θερμοκρασίας, αποτυπώνοντας με συνέπεια την έντονη εποχικότητα των δεδομένων. Η ακρίβειά του είναι καλή τόσο στις υψηλές όσο και στις χαμηλές θερμοκρασίες, με μικρές αποκλίσεις κυρίως στις ακραίες τιμές. Η οπτική προσαρμογή δείχνει ότι το μοντέλο έχει μάθει αποτελεσματικά τα περιοδικά μοτίβα της σειράς, ενώ η πολύ μικρές χρονικές μη συστηματικές υστερήσεις του με την πραγματική σειρά το καθιστά σχετικά αξιόπιστο για προβλέψεις. Παρά τη συνολική καλή απόδοση του μοντέλου, υπάρχει μια ελαφρά υποεκτίμηση σε ορισμένες αιχμές που υποδηλώνει περιθώριο βελτίωσης, ειδικά στην αποτύπωση ακραίων τιμών.


5.2.3.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια

Τα δεδομένα χωρίστηκαν χρονολογικά σε σύνολο εκπαίδευσης και επικύρωσης με το σύνολο εκπαίδευσης να αποτελεί το 80% των δεδομένων και το σύνολο επικύρωσης να είναι


το υπόλοιπο 20% όπως ακριβώς και στα προηγούμενα μοντέλα. Προκειμένου να βρεθούν οι κατάλληλες υπερπαραμέτροι για το μοντέλο έγιναν διάφορα πειράματα για διάφορες τιμές των υπερπαραμέτρων. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των υπερπαραμέτρων.



Εικόνα 46: Επίδραση μεγέθους παρτίδας στην απόδοση του μοντέλου CNN.




Εικόνα 47: Επίδραση του μεγέθους παραθύρου εισόδου στην απόδοση του μοντέλου CNN.



Εικόνα 48: Επίδραση του αριθμού των φίλτρων στο πρώτο συνελικτικού επίπεδο του μοντέλου CNN.

Στην συγκεκριμένη περίπτωση, από το διάγραμμα της επιρροής του αριθμού των φίλτρων στο πρώτο Conv1D στρώμα φαίνεται πως η απόδοση του μοντέλου στα πειράματα έχει ασήμαντα μικρές διαφορές σύμφωνα με τις μετρικές, οπότε ο αριθμός των φίλτρων επιλέχθηκε με βάση την ποιοτική αξιολόγηση του μοντέλων. Τα πειραματικά αποτελέσματα υποδεικνύουν ότι το βέλτιστο CNN για το συγκεκριμένο πρόβλημα διαμορφώνεται με batch size ίσο με 128, n_lag ίσο με 12 και αριθμό φίλτρων στο πρώτο Conv1D στρώμα ίσο με 16. Τα αποτελέσματα πρόβλεψης του μοντέλου αυτού δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:




Εικόνα 49: Σύγκριση πραγματικής σειράς και CNN προβλέψεων στα δεδομένα μεγίστων μηνιαίων σεισμικών εντάσεων.

RMSE: 0.95, MAE: 0.74


Το CNN, αν και θεωρητικά ικανό να ανιχνεύει τοπικά μοτίβα και μη γραμμικές σχέσεις, στην περίπτωση των σεισμικών εντάσεων αποτυγχάνει να αναπαράγει την υψηλή μεταβλητότητα και τα ακραία γεγονότα που χαρακτηρίζουν τη χρονοσειρά. Οι προβλέψεις του είναι εξομαλυσμένες και κινούνται κοντά στον μέσο όρο, παρέχοντας μέτρια απόδοση και ουσιαστικά αδυνατώντας να προβλέψει μεγάλες αιχμές. Παρόλα αυτά είναι εμφανώς καλύτερη η απόδοση από τα αντίστοιχα αποτελέσματα των κλασσικών γραμμικών μοντέλων καθώς επιτυγχάνει πρόβλεψη με μεγαλύτερη διακύμανση τιμών ενώ σε κάποιες περιπτώσεις αναγνωρίζει σωστά την τάση για αύξηση των τιμών χωρίς όμως να επιτυγχάνει σωστή πρόβλεψη. Το αποτέλεσμα αυτό υποδηλώνει ότι για τέτοιου τύπου δεδομένα απαιτούνται πιο εξειδικευμένες τεχνικές (π.χ. μοντέλα με έμφαση σε σπάνια γεγονότα ή μεθόδους ανίχνευσης ανωμαλιών) ώστε να βελτιωθεί η πρόβλεψη.

5.2.3.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ


Η αρχική χρονοσειρά χωρίστηκε χρονολογικά σε σύνολο εκπαίδευσης και επικύρωσης με το σύνολο εκπαίδευσης να αποτελεί το 80% των δεδομένων και το σύνολο επικύρωσης να είναι το υπόλοιπο 20% όπως ακριβώς και στα προηγούμενα μοντέλα. Προκειμένου να βρεθούν οι κατάλληλες υπερπαραμέτροι για το μοντέλο έγιναν διάφορα πειράματα για διάφορες τιμές τους και παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών αυτών.



Εικόνα 50: Επίδραση μεγέθους παρτίδας στην απόδοση του μοντέλου CNN.




Εικόνα 51: Επίδραση του μεγέθους παραθύρου εισόδου στην απόδοση του μοντέλου CNN.



Εικόνα 52: Επίδραση του αριθμού των φίλτρων στο πρώτο συνελκτικού επίπεδο του μοντέλου CNN

Τα πειραματικά αποτελέσματα υποδεικνύουν ότι το βέλτιστο CNN για το συγκεκριμένο πρόβλημα διαμορφώνεται με batch size ίσο με 128, n_lag ίσο με 12 και αριθμό φίλτρων στο πρώτο Conv1D στρώμα ίσο με 64. Τα αποτελέσματα πρόβλεψης του μοντέλου αυτού δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:



Εικόνα 53: Σύγκριση πραγματικής σειράς και CNN προβλέψεων στα δεδομένα συνολικών μηνιαίων βροχοπτώσεων.

RMSE: 91.38, MAE: 66.86.

Το μοντέλο CNN καταφέρνει να αποτυπώσει τη βασική εποχικότητα και τη γενική μορφή της χρονοσειράς βροχόπτωσης στο Σίδνεϊ, ωστόσο παρουσιάζει σημαντική αδυναμία στην πρόβλεψη των ακραίων τιμών. Η πρόβλεψη είναι αρκετά εξομαλυμένη, γεγονός που οδηγεί σε υποεκτίμηση των μεγάλων αιχμών και υπερεκτίμηση των πολύ χαμηλών τιμών. Παρόλα αυτά παρατηρείται πως το μοντέλο “προσπαθεί” να προβλέψει κάποιες λίγες, όχι τόσο ακραίες αλλά ασυνήθιστα μεγάλες τιμές οι οποίες όμως αποτυγχάνουν τόσο ως προς το χρονικό σημείο αλλά και ως προς την έντασή τους.

Η υπερεκτίμηση των χαμηλών τιμών από το CNN προκύπτει από έναν συνδυασμό στατιστικής ασυμμετρίας, μεροληψίας προς τον μέσο όρο λόγω της φύσης της εκπαίδευσης και της αρχιτεκτονικής αφού η εξομαλυντική φύση των convolutional layers μειώνουν την ακραία διακύμανση στις προβλέψεις, καθώς και ίσως της περιορισμένης πληροφορίας για την πρόβλεψη ξαφνικών ξηρών περιόδων.

Παρά την σχετική επάρκειά του για μέτριες τιμές, η απόδοσή του σε σπάνια αλλά κλιματικά σημαντικά γεγονότα (π.χ. πλημμύρες) είναι περιορισμένη αλλά εμφανώς καλύτερη από την απόδοση των κλασσικών γραμμικών μοντέλων πρόβλεψης. Αυτό δείχνει ότι για τέτοιου είδους δεδομένα απαιτούν μοντέλα ή τεχνικές που δίνουν μεγαλύτερη έμφαση στα ακραία φαινόμενα.

5.2.4 GRU

Στην παρούσα εργασία αξιολογείτε η απόδοση ενός νευρωνικού δικτύου τύπου GRU (Gated Recurrent Unit) στην πρόβλεψη χρονοσειρών με ακραίες τιμές. Η διάσπαση των δεδομένων σε σύνολα εκπαίδευσης και ελέγχου έγινε για κάθε σύνολο δεδομένων επιλέγοντας της ίδες χρονικές περιόδους όπως και στα προηγούμενα μοντέλα, προκειμένου τα αποτελέσματα να είναι συγκρίσιμα.

Για την κανονικοποίηση των δεδομένων εφαρμόστηκε η μέθοδος Min–Max Scaling, με στόχο τη μετατροπή όλων των τιμών σε ένα εύρος $[0,1]$. Η κανονικοποίηση πραγματοποιήθηκε ξεχωριστά για τα δεδομένα εκπαίδευσης και τα δεδομένα επικύρωσης, ώστε να διατηρηθούν οι κατάλληλες αναλογίες στην κάθε περίπτωση. Επιπλέον, οι παράμετροι της κλιμάκωσης (ελάχιστη και μέγιστη τιμή) υπολογίστηκαν αποκλειστικά από το


σύνολο εκπαίδευσης. Με αυτόν τον τρόπο αποφεύγεται η διαρροή πληροφορίας (data leakage), δηλαδή η ακούσια ενσωμάτωση πληροφοριών από το σύνολο επικύρωσης κατά το στάδιο της εκπαίδευσης, η οποία θα μπορούσε να οδηγήσει σε υπεραισιόδοξες εκτιμήσεις της απόδοσης του μοντέλου.

Όσον αφορά την αρχιτεκτονική του μοντέλου, υλοποιήθηκε ως Sequential GRU δίκτυο με δύο επίπεδα. Το πρώτο επίπεδο αποτελεί ένα GRU Layer με αριθμό μονάδων (νευρώνες) που ορίζεται έπειτα από πειραματική διερευνητική διαδικασία με διάφορες τιμές (32, 64, 128). Το δεύτερο επίπεδο αποτελεί ένα Dense Layer με 1 νευρώνα και γραμμική ενεργοποίηση, κατάλληλο για πρόβλεψη συνεχών τιμών. Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκε ο βελτιστοποιητής Adan και ως συνάρτηση κόστους το MSE. Επίσης το μέγεθος παρτίδας (batch size) ορίζεται έπειτα από πειραματική διερευνητική διαδικασία με διάφορες τιμές (16, 32, 64, 128) καθώς επηρεάζει την ταχύτητα σύγκλισης και τη σταθερότητα εκπαίδευσης. Τέλος με αντίστοιχο τρόπο επιλέχθηκε και η υπερπαραμέτρος του μεγέθους παραθύρου εισόδου (n_lag) καθώς ελέγχθηκε η επίδραση της στην απόδοση του μοντέλου για διάφορες τιμές της (6, 12, 24).


Στα πλαίσια της παρούσας εργασίας θεωρούμε ότι η χρήση GRU για την πρόβλεψη ακραίων τιμών σε χρονοσειρές είναι μια λογική επιλογή, καθώς μπορεί να χειριστεί την εποχικότητα και τις τάσεις, ενώ παράλληλα περιορίζει τον αριθμό παραμέτρων σε σύγκριση με άλλα RNN μοντέλα, μειώνοντας τον κίνδυνο υπερπροσαρμογής.

5.2.4.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ


Το σύνολο δεδομένων χωρίστηκε και πάλι χρονολογικά σε σύνολο εκπαίδευσης και επικύρωσης με το σύνολο εκπαίδευσης να αποτελεί το 85% των δεδομένων και το σύνολο επικύρωσης να είναι το υπόλοιπο 15% όπως ακριβώς και στα προηγούμενα μοντέλα. Προκειμένου να βρεθούν οι κατάλληλες υπερπαραμέτροι για το μοντέλο έγιναν διάφορα πειράματα για διάφορες τιμές των υπερπαραμέτρων. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των παραμέτρων.



Εικόνα 54: Επίδραση μεγέθους παρτίδας στην απόδοση του μοντέλου GRU.




Εικόνα 55: Επίδραση του μεγέθους παραθύρου εισόδου στην απόδοση του μοντέλου GRU.



Εικόνα 56: Επίδραση του αριθμού των νευρώνων στο μοντέλο GRU.


Τα πειραματικά αποτελέσματα υποδεικνύουν ότι το βέλτιστο GRU για το συγκεκριμένο πρόβλημα διαμορφώνεται με batch size ίσο με 32, η_lag ίσο με 12 και αριθμό φίλτρων στο πρώτο Conv1D στρώμα ίσο με 64. Τα αποτελέσματα πρόβλεψης του μοντέλου αυτού δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:



Εικόνα 57: Σύγκριση πραγματικής σειράς και GRU προβλέψεων στα δεδομένα μεγίστων μηνιαίων θερμοκρασιών.

RMSE: 1.34, MAE: 1.05.

Το GRU επιτυγχάνει υψηλή προσαρμογή στη δομή και την εποχικότητα των μέγιστων μηνιαίων θερμοκρασιών στο Χονγκ Κονγκ. Η ικανότητά του να ακολουθεί τις ετήσιες διακυμάνσεις είναι εμφανής, με κάποιες μικρές αποκλίσεις στις ακραίες τιμές. Η μικρή υποεκτίμηση σε κάποιες κορυφές πιθανόν σχετίζεται με τον φυσικό “συντηρητισμό” των μοντέλων πρόβλεψης που εκπαιδεύονται με MSE, τα οποία τείνουν να αποφεύγουν πολύ υψηλές αποκλίσεις από τον μέσο όρο. Παρατηρείτε μια συστηματική υποεκτίμηση των ήπιων χειμερινών θερμοκρασιών που δείχνει ότι το GRU, αν και ισχυρό στην αναπαραγωγή του γενικού εποχικού μοτίβου, παρουσιάζει bias στις χαμηλές θερμοκρασίες όταν αυτές είναι κάτω από το σύνηθες εποχικό επίπεδο. Συνολικά, το μοντέλο δείχνει ισχυρή ικανότητα γενίκευσης και ακριβή χρονολογική ευθυγράμμιση.




Εικόνα 58: Μέγιστη μηνιαία θερμοκρασία: ποιοτική σύγκριση προβλέψεων μοντέλων CNN(μπλέ) και GRU (πορτοκαλί).


Και τα δύο μοντέλα είναι ιδιαίτερα ικανά στην πρόβλεψη της εποχικότητας των θερμοκρασιών, αλλά το CNN εμφανίζει καλύτερη ικανότητα αναπαραγωγής των ακραίων τιμών τόσο των μεγίστων όσο και των ελαχίστων. Το GRU τείνει να υποεκτιμά ελαφρώς τα άκρα (κυρίως τα ελάχιστα) ενώ το CNN φαίνεται να πετυχαίνει πιο κοντινές στις πραγματικές τιμές προβλέψεις τόσο στα μέγιστα όσο και στα ελάχιστα. Αφού ο στόχος είναι κυρίως η πιστή αναπαράσταση ακραίων θερμοκρασιών, το CNN φαίνεται ελαφρώς πιο κατάλληλο, ενώ το GRU είναι πιο ασφαλές για εφαρμογές που απαιτούν σταθερότητα και λιγότερη ευαισθησία στον θόρυβο.

5.2.4.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια


Το σύνολο δεδομένων χωρίστηκε και πάλι χρονολογικά σε σύνολο εκπαίδευσης και επικύρωσης με το σύνολο εκπαίδευσης να αποτελεί το 80% των δεδομένων και το σύνολο επικύρωσης να είναι το υπόλοιπο 20% και έγιναν διάφορα πειράματα για διάφορες τιμές των υπερπαραμέτρων. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των παραμέτρων.



Εικόνα 59: Επίδραση μεγέθους παρτίδας στην απόδοση του μοντέλου GRU.




Εικόνα 60: Επίδραση του μεγέθους παραθύρου εισόδου στην απόδοση του μοντέλου GRU.



Εικόνα 61: Επίδραση του αριθμού των νευρώνων στο μοντέλο GRU.


Τα πειραματικά αποτελέσματα υποδεικνύουν ότι το βέλτιστο GRU για το συγκεκριμένο πρόβλημα διαμορφώνεται με batch size ίσο με 32, η_lag ίσο με 12 και αριθμό φίλτρων στο πρώτο Conv1D στρώμα ίσο με 32. Τα αποτελέσματα πρόβλεψης του μοντέλου αυτού δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:



Εικόνα 62: Σύγκριση πραγματικής σειράς και GRU προβλέψεων στα δεδομένα μεγίστων μηνιαίων σεισμικών εντάσεων.

RMSE: 0.97, MAE: 0.72.

Το GRU καταφέρνει να αποτυπώσει το μέσο επίπεδο σεισμικής έντασης, αλλά παρουσιάζει ισχυρή εξομάλυνση και μεγάλη αδυναμία πρόβλεψης γεγονότων εκτός του μέσου επιπέδου σεισμικής έντασης. Αυτό ίσως οφείλεται στο μέγεθος του dataset αλλά κυρίως στην υψηλή ακανόνιστη μεταβλητότητα, που δυσκολεύουν το μοντέλο να μάθει αξιόπιστα τα μοτίβα. Η απόδοση δεν καθόλου επαρκής για ανίχνευση και πρόβλεψη έντονων σεισμικών επεισοδίων, και απαιτούνται πιο εξειδικευμένες τεχνικές ή προσαρμοσμένες συναρτήσεις κόστους που δίνουν έμφαση στα άκρα.




Εικόνα 63: Μέγιστη μηνιαία σεισμική ένταση: ποιοτική σύγκριση προβλέψεων μοντέλων CNN(μπλέ) και GRU (πορτοκαλί).


Το μοντέλο CNN συλλαμβάνει τη γενική τάση των σεισμικών εντάσεων, αλλά και τα δύο μοντέλα αποτυγχάνουν να αναπαράγουν τις έντονες διακυμάνσεις πόσο μάλλον τα ακραία επεισόδια. Στα δεδομένα σεισμικών εντάσεων, όπου η περιοδικότητα είναι αδύναμη και οι ακραίες τιμές σπάνιες αλλά σημαντικές, το CNN παρουσιάζει ελαφρώς μεγαλύτερη ευαισθησία ανίχνευσης τοπικών αυξομειώσεων σε σχέση με το GRU, το οποίο παράγει πιο ομαλές και συντηρητικές προβλέψεις. Το CNN προβλέπει ένα μεγαλύτερο εύρος τιμών σε σχέση με το GRU, αλλά και πάλι αρκετά μακριά από το πραγματικό εύρος τιμών. Για εφαρμογές όπως η δική μας, όπου η ακρίβεια στα ακραία γεγονότα είναι κρίσιμη, και τα δύο μοντέλα χρειάζονται περαιτέρω βελτιστοποίηση, πιθανόν με χρήση τεχνικών που δίνουν μεγαλύτερο βάρος στα outliers ή συνδυασμό με εξειδικευμένα μοντέλα πρόβλεψης ακραίων τιμών.

5.2.4.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ


Το σύνολο δεδομένων χωρίστηκε και πάλι χρονολογικά σε 80% σύνολο εκπαίδευσης και 20% και έγιναν διάφορα πειράματα για διάφορες τιμές των υπερπαραμέτρων. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των παραμέτρων.



Εικόνα 64: Επίδραση μεγέθους παρτίδας στην απόδοση του μοντέλου GRU.




Εικόνα 65: Επίδραση του μεγέθους παραθύρου εισόδου στην απόδοση του μοντέλου GRU.



Εικόνα 66: Επίδραση του αριθμού των νευρώνων στο μοντέλο GRU.


Τα πειραματικά αποτελέσματα υποδεικνύουν ότι το βέλτιστο GRU για το συγκεκριμένο πρόβλημα διαμορφώνεται με batch size ίσο με 16, η_lag ίσο με 12 και αριθμό φίλτρων στο πρώτο Conv1D στρώμα ίσο με 32. Τα αποτελέσματα πρόβλεψης του μοντέλου αυτού δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:



Εικόνα 67: Σύγκριση πραγματικής σειράς και GRU προβλέψεων στα δεδομένα συνολικών μηνιαίων βροχοπτώσεων.

RMSE: 89.39, MAE: 65.59.

Το GRU αποδίδει ελαφρώς την γενική τάση των δεδομένων και ενός ήπιου εποχικού μοτίβου της βροχόπτωσης, ωστόσο αποτυγχάνει στην ακριβή αναπαραγωγή της υψηλής μεταβλητότητας και των ακραίων γεγονότων που χαρακτηρίζουν τα δεδομένα. Η συντηρητική του προσέγγιση το καθιστά καταλληλότερο ίσως για προβλέψεις μέσων συνθηκών, αλλά δεν είναι χρήσιμο για εφαρμογές που απαιτούν έγκαιρη και ακριβή πρόβλεψη έντονων καιρικών φαινομένων.



Εικόνα 68: Συνολική μηνιαία βροχόπτωση: ποιοτική σύγκριση προβλέψεων μοντέλων CNN(μπλέ) και GRU (πορτοκαλί).

Και τα δύο μοντέλα κατόρθωσαν να αναπαράγουν μια πολύ γενική δομή της χρονοσειράς, με το CNN να αποτυπώνει ικανοποιητικά την εναλλαγή μεταξύ υγρών και ξηρών περιόδων, ενώ τα αποτελέσματα του GRU είναι πιο εξομαλυσμένα. Το CNN εμφάνισε μεγαλύτερη ευελιξία στην παρακολούθηση των βραχυπρόθεσμων διακυμάνσεων, καθώς και καλύτερη απόκριση στις μεσαίας έντασης αιχμές, γεγονός που αποδίδεται στην ικανότητά του να ανιχνεύει τοπικά χρονικά μοτίβα μέσω των συνελκτικών φίλτρων.

Αντίθετα, το GRU παρουσίασε πιο ομαλή και σταθερή καμπύλη πρόβλεψης, με μικρότερο εύρος τιμών, γεγονός που το καθιστά ανθεκτικότερο σε τυχαίο θόρυβο αλλά και πιο συντηρητικό στην πρόβλεψη. Αυτό είχε ως αποτέλεσμα την υποεκτίμηση των ακραίων τιμών βροχόπτωσης, με τις κορυφές να συμπιέζονται σε επίπεδα πολύ χαμηλότερα από τις πραγματικές μετρήσεις. Παράλληλα, το GRU υπερεκτίμησε συστηματικά τις χαμηλές τιμές κατά τις ξηρές περιόδους, χάνοντας σε πιστότητα στην αποτύπωση των περιόδων έντονης ξηρασίας.

5.2.5 DAN

Στα πλαίσια της παρούσας εργασίας αν και διατηρήθηκε η βασική αρχιτεκτονική του μοντέλου DAN, χωρίς αλλαγές στους μηχανισμούς εκπαίδευσης ή στην επιστημονική μεθοδολογία, χρειάστηκε να γίνουν κάποιες τροποποιήσεις στον κώδικα του μοντέλου προκειμένου να είναι συμβατά με το μοντέλο τα υπό εξέταση σύνολα δεδομένων. Οι αλλαγές είναι κυρίως προσαρμογές ώστε το μοντέλο να μπορεί να χειριστεί μηνιαία δεδομένα (θερμοκρασίας, σεισμικής έντασης, βροχόπτωσης) αντί για τα αρχικά υδρολογικά/υδρομετεωρολογικά δεδομένα της εργασίας των συγγραφέων που είναι μετρήσεις ανά 15 λεπτά. Πιο συγκεκριμένα οι αλλαγές που πραγματοποιήθηκαν είναι οι εξής:

- Προσαρμογή χρονικού βήματος και παραμέτρων εκπαίδευσης. Το αρχικό DAN είχε σχεδιαστεί για υδρολογικά δεδομένα υψηλής χρονικής ανάλυσης (15-λεπτά). Στην παρούσα εφαρμογή, το μοντέλο εκπαιδεύεται με ιστορικό 12 μηνιαίων παρατηρήσεων (παράθυρο εισόδου) προκειμένου να προβλέψει την τιμή της μέγιστης τιμής της μεταβλητής για τον αμέσως επόμενο μήνα (ορίζοντας πρόβλεψης ενός βήματος). Έγιναν αλλαγές στις σχετικές παραμέτρους (`input_len`, `output_len`, `epochs` και `batch_size`), ώστε να ταιριάζουν στο πλήθος παρατηρήσεων και στον χρονικό ορίζοντα πρόβλεψης του dataset.
- Ανασχεδιασμός εποχικών χαρακτηριστικών. Στην αρχική έκδοση, τα κυκλικά εποχικά χαρακτηριστικά (συναρτήσεις `cos_date` και `sin_date`) βασίζονταν σε ημέρες και ώρες (συχνότητα 288 βημάτων/ημέρα). Στη νέα έκδοχή, τα χαρακτηριστικά αυτά υπολογίζονται αποκλειστικά με βάση τον μήνα του έτους (κύκλος 12 μηνών), ώστε να συλλαμβάνεται η ετήσια εποχικότητα στις μηνιαίες θερμοκρασίες.
- Παράκαμψη κομματιών κώδικα που ήταν ειδικά για υδρολογικές χρονοσειρές (π.χ. έλεγχος υδρολογικού έτους Σεπτέμβρης–Μάιος).


Για τα υπό μελέτη σύνολα δεδομένων, προκειμένου να βρεθούν οι κατάλληλες υπερπαραμέτροι για το μοντέλο, έγιναν διάφορα πειράματα για διάφορες τιμές κάποιων επιλεγμένων υπερπαραμέτρων. Οι παράμετροι που εξετάστηκαν είναι:

- Η κρυφή διάσταση των LSTM (`hidden_dim`), κοινή για όλα τα LSTM μπλοκ. Μεγαλύτερες τιμές (π.χ. 128–512) θεωρητικά αυξάνουν τη χωρητικότητα για πολύπλοκη δυναμική, αλλά επιβραδύνουν την εκπαίδευση και ενδέχεται να οδηγήσουν σε υπερπροσαρμογή, ενώ μικρότερες τιμές (π.χ. 64–128) λειτουργούν ως ενσωματωμένη κανονικοποίηση.


- Η διάσταση των φίλτρων στο Conv1D της κωδικοποίησης (cnn_dim), που ελέγχει πόσο πλούσια είναι τα πολυκλιμακωτά τοπικά γνωρίσματα πριν τροφοδοτηθούν στα LSTM. Η αύξηση (π.χ. 64, 128, 256) μπορεί να βοηθήσει στην ανάδειξη εποχικών μοτίβων, με αντίτιμο περισσότερες παραμέτρους και χρόνο εκπαίδευσης.
- Η βαθμίδα βάθους των LSTM (layer), δηλαδή ο αριθμός των στοιβών ανά μπλοκ. Η μετάβαση από 1 σε 2 επίπεδα μπορεί να βελτιώσει την αναπαράσταση ταυτόχρονα βραχυπρόθεσμων και μακροπρόθεσμων εξαρτήσεων, αυξάνοντας όμως την πολυπλοκότητα και τις απαιτήσεις ρύθμισης. Μια στοχευμένη διερεύνηση (για τιμές 1, 2) είναι συνήθως επαρκής.

5.2.5.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ


Το σύνολο δεδομένων όπως και για τα προηγούμενα μοντέλα χωρίστηκε σε 85% σύνολο εκπαίδευσης και 15% σύνολο επικύρωσης. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των υπερπαραμέτρων.




Εικόνα 69: Επίδραση μεγέθους παρτίδας στην απόδοση του μοντέλου DAN.



Εικόνα 70: Επίδραση της κρυφής διάστασης των LSTM στην απόδοση του μοντέλου DAN.




Εικόνα 71: Επίδραση της διάστασης των φίλτρων του Conv1D στην απόδοση του μοντέλου DAN.



Εικόνα 72: Επίδραση της βαθμίδας βάθους των LSTM στην απόδοση του μοντέλου DAN.

Τα πειραματικά αποτελέσματα υποδεικνύουν ότι το βέλτιστο DAN μοντέλο για το συγκεκριμένο σύνολο δεδομένων διαμορφώνεται με batch size ίσο με 16, hidden_dim ίσο με 512, αριθμό φίλτρων στο πρώτο Conv1D στρώμα ίσο με 256 και αριθμό επιπέδων LSTM ανά μπλοκ ίσο με 2. Τα αποτελέσματα πρόβλεψης του μοντέλου αυτού δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:




Εικόνα 73: Σύγκριση πραγματικής σειράς και DAN προβλέψεων στα δεδομένα μεγίστων μηνιαίων θερμοκρασιών.

RMSE = 1.39, MAE = 0.98


Με βάθος LSTM = 1 ανά μπλοκ, το μοντέλο πέτυχε RMSE = 1.51 και MAE = 1.11. Η καμπύλη προβλέψεων ακολουθεί τη βασική εποχικότητα, αλλά εμφανίζει ελαφρά «συμπύεση πλάτους» (υποεκτίμηση κορυφών και υπερεκτίμηση κοιλάδων) και μικρή χρονική υστέρηση σε ορισμένα διαστήματα. Με βάθος LSTM = 2, τα αποτελέσματα βελτιώνονται σε RMSE = 1.3932 και MAE = 0.98 οι κορυφές και κοιλάδες αποτυπώνονται ελαφρώς πιστότερα και το lag ελαφρώς μειώνεται. Συγκριτικά, το βάθος 2 μειώνει το RMSE κατά ~8% και το MAE κατά ~11% σε σχέση με το βάθος 1, με μοναδικό κόστος τον μεγαλύτερο χρόνο εκπαίδευσης όπου χρειάστηκε τον οκταπλάσιο χρόνο εκπαίδευση σε σχέση με το άλλο μοντέλο. Συνεπώς, για τα συγκεκριμένα δεδομένα, το μοντέλο με 2 επίπεδα LSTM κρίνεται καταλληλότερο, καθώς προσφέρει χαμηλότερα σφάλματα και καλύτερη παρακολούθηση της εποχικής δυναμικής.

5.2.5.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια


Το σύνολο δεδομένων όπως και για τα προηγούμενα μοντέλα σε 80% σύνολο εκπαίδευσης και 10% σύνολο επικύρωσης. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των παραμέτρων.




Εικόνα 74: Επίδραση μεγέθους παρτίδας στην απόδοση του μοντέλου DAN.



Εικόνα 75: Επίδραση της διάστασης των φίλτρων του Conv1D στην απόδοση του μοντέλου DAN.




Εικόνα 76: Επίδραση της κρυφής διάστασης των LSTM στην απόδοση του μοντέλου DAN.



Εικόνα 77: Επίδραση της βαθμίδας βάθους των LSTM στην απόδοση του μοντέλου DAN.

Τα πειραματικά αποτελέσματα υποδεικνύουν ότι το βέλτιστο DAN μοντέλο για το συγκεκριμένο σύνολο δεδομένων είναι εκείνο με batch size ίσο με 128, κρυφή διάσταση των LSTM (hidden_dim) ίσο με 128, αριθμό φίλτρων στο πρώτο Conv1D στρώμα (cnn_dim) ίσο με 256 και αριθμός επιπέδων LSTM ανά μπλοκ ίσο με 1. Τα αποτελέσματα πρόβλεψης του μοντέλου αυτού δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:




Εικόνα 78: Σύγκριση πραγματικής σειράς και DAN προβλέψεων στα δεδομένα μεγίστων μηνιαίων θερμοκρασιών.

RMSE: 0.95, MAE: 0.74


Το μοντέλο DAN, όπως φαίνεται στο διάγραμμα, συλλαμβάνει τον μέσο όρο αλλά όχι την ακραία συμπεριφορά των μηνιαίων μέγιστων σεισμικών εντάσεων. Η καμπύλη πρόβλεψης είναι εμφανώς εξομαλυμένη, και ακολουθεί το γενικό μέσο όρο ($\approx 5-5.5$) και εμφανίζει μικρές κυματώσεις, αλλά υποεκτιμά συστηματικά τις ψηλότερες τιμές (π.χ. 7–9) αλλά και υπερεκτιμά τις χαμηλότερες. Το DAN στην περίπτωση αυτή, μοντελοποιεί μέτρια το υπόβαθρο της σειράς αλλά αποτυγχάνει συστηματικά στις σπάνιες/ακραίες εξάρσεις. Φαίνεται πως σε κάποιες περιπτώσεις προβλέπει σωστά μια επερχόμενη αύξηση του μεγέθους αλλά χωρίς να καταφέρνει να προσεγγίσει τις σωστές τιμές. Το μοντέλο δεν φαίνεται να ανιχνεύει ισχυρή εποχικότητα στη χρονοσειρά των μηνιαίων μέγιστων σεισμικών εντάσεων αν και αξίζει να σημειωθεί ότι στα δεδομένα δεν προκύπτουν σταθερά, περιοδικά μοτίβα που να προμηνύουν τις κορυφώσεις, έτσι το μοντέλο δεν διαθέτει αρκετές προβλεπτικές ενδείξεις για να τις εντοπίσει.

5.2.5.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ


Τα δεδομένα χωρίστηκαν σε 80% σύνολο εκπαίδευσης και 10% σύνολο επικύρωσης. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των παραμέτρων.




Εικόνα 79: Επίδραση μεγέθους παρτίδας στην απόδοση του μοντέλου DAN.



Εικόνα 80: Επίδραση της κρυφής διάστασης των LSTM στην απόδοση του μοντέλου DAN.




Εικόνα 81: Επίδραση της διάστασης των φίλτρων του Conv1D στην απόδοση του μοντέλου DAN.



Εικόνα 82: Επίδραση της βαθμίδας βάθους των LSTM στην απόδοση του μοντέλου DAN.

Τα πειραματικά αποτελέσματα υποδεικνύουν ότι το βέλτιστο DAN μοντέλο για το συγκεκριμένο σύνολο δεδομένων είναι εκείνο με batch size ίσο με 16, κρυφή διάσταση των LSTM (hidden_dim) ίσο με 1024, αριθμό φίλτρων στο πρώτο Conv1D στρώμα (cnn_dim) ίσο με 64 και αριθμός επιπέδων LSTM ανά μπλοκ ίσο με 1. Τα αποτελέσματα πρόβλεψης του μοντέλου αυτού δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:



Εικόνα 83: Σύγκριση πραγματικής σειράς και DAN προβλέψεων στα δεδομένα συνολικής μηνιαίας βροχόπτωσης.

RMSE: 92.85, MAE: 73.02

Η απόδοση του DAN στα μηνιαία ύψη βροχής δείχνει ότι το μοντέλο αποδίδει ικανοποιητικά τη μέση συμπεριφορά, αλλά εξομαλύνει έντονα τα μεγάλα ύψη βροχής, με την πρόβλεψη γενικά να κινείται γύρω από το τυπικό εύρος ($\approx 60\text{--}110\text{ mm}$), ενώ τα πραγματικά δεδομένα εμφανίζουν επαναλαμβανόμενα spikes $>300\text{--}600\text{ mm}$ που υποεκτιμώνται. Αυτό αποτυπώνεται και στις μετρικές $\text{MAE} = 73.02\text{ mm}$ και σημαντικά μεγαλύτερο $\text{RMSE} = 92.85\text{ mm}$, που υποδηλώνει λίγες αλλά μεγάλες αποκλίσεις στις αιχμές (το τετραγωνικό σφάλμα «τιμωρεί» δυσανάλογα τα μεγάλα λάθη). Συνεπώς, το μοντέλο είναι σταθερό και αξιόπιστο για τη γενική τάση, αλλά έχει περιθώριο βελτίωσης στην ουρά της κατανομής, εκεί όπου επιχειρησιακά μετρά περισσότερο.

Αξίζει να σημειωθεί ότι το μοντέλο αποδίδει αρκετά ικανοποιητικότερα τη μέση συμπεριφορά της σειράς σε σχέση με όλα τα μέχρι τώρα μοντέλα που έχουν εξεταστεί πάνω στην συγκεκριμένη χρονοσειρά. Φαίνεται να προβλέπει αρκετά καλά τα χρονικά σημεία στα οποία θα προκύψει μια αύξηση των τιμών παρόλο που γενικά οι προβλέψεις είναι συντηρητικές. Παρατηρούμε ότι οι προβλέψεις για τα πρώτα χρόνια είναι λιγότερο συντηρητικές, προβλέποντας τιμές μέχρι και $>300\text{mm}$ που πλησιάζουν περισσότερο τις πραγματικές τιμές αλλά και πάλι το σφάλμα είναι μεγάλο.

5.2.6 Reweight-EVT

Στα πλαίσια της παρούσας εργασίας αν και διατηρήθηκε η βασική αρχιτεκτονική και ο τρόπος λειτουργίας του αρχικού μοντέλου. Συγκεκριμένα, παραμένει ίδια η μεθοδολογία του Reweight-EVT: (α) διαμόρφωση εποπτευόμενων δειγμάτων με κυλιόμενο παράθυρο (n_hours), (β) κανονικοποίηση MinMaxScaler, (γ) εκτίμηση των ουρών με Γενικευμένη Κατανομή Pareto (GPD) πάνω από κατώφλι p -οστού εκατοστημορίου, (δ) υπολογισμός βαρών ως αντίστροφη της συνάρτησης επιβίωσης $1/SF$ για τα ακραία δείγματα και κανονικοποίηση τους, όπου τα βάρη EVT περνούν στο `model.fit(..., sample_weight=weights)` και (ε) εκπαίδευση του ίδιου νευρωνικού δικτύου MLP με αυτά τα βάρη μέσω του `sample_weight`, με EarlyStopping/ModelCheckpoint.

Προκειμένου στο μοντέλο να μπορούν να τροφοδοτηθούν τα υπό μελέτη σύνολα δεδομένων, χρειάστηκε να γίνουν κάποιες τροποποιήσεις στον αρχικό κώδικα. Οι αλλαγές είναι κυρίως προσαρμογές ώστε το μοντέλο να μπορεί να δουλέψει με μηνιαία δεδομένα

αντί για τα ωριαία πολυμεταβλητά δεδομένα (Jena climate) που χρησιμοποιούσαν οι συγγραφείς Shi et al. (2024). Πιο συγκεκριμένα οι αλλαγές που πραγματοποιήθηκαν είναι οι εξής:

- Πλέον αντί για κυλιόμενο παράθυρο 72 ωρών και ορίζοντα 12 βημάτων για μια πολυμεταβλητή σειρά, το μοντέλο δέχεται μια μονομεταβλητή σειρά με παράθυρο 12 μηνών και ορίζοντα 1 μήνα. Η δημιουργία supervised πλαισίωσης (series_to_supervised) και η λογική επιλογής κατωφλίου 95ου εκατοστημορίου και εφαρμογής Generalized Pareto (GPD) για την εκτίμηση ουράς, παραμένουν ίδιες.
- Πλέον ο διαχωρισμός του συνόλου δεδομένων έγινε από ποσοστιαίο (70/15/15) σε χρονικό με σαφή ημερομηνία τομής (train/val/test), κάτι που δεν αλλάζει τη μέθοδο αλλά την προσαρμόζει σε σειρά πραγματικού χρόνου.


Για τα υπό μελέτη σύνολα δεδομένων, προκειμένου να βρεθούν οι κατάλληλες τιμές κάποιων επιλεγμένων υπερπαραμέτρων του μοντέλου έγιναν διάφορα πειράματα για διάφορες τιμές τους. Οι παράμετροι που εξετάστηκαν είναι:

- Ο Ρυθμός μάθησης (learning_rate) και το μέγεθος παρτίδας (BATCH). Το learning rate ορίζει πόσο μεγάλο βήμα κάνει ο βελτιστοποιητής σε κάθε ενημέρωση βαρών. Πολύ υψηλή τιμή επιταχύνει την εκπαίδευση πιθανώς αλλά μπορεί να χάσει τοπικά ελάχιστα ενώ πολύ μικρή τιμή απαιτεί περισσότερες εποχές και υπάρχει κίνδυνος να κολλήσει σε τοπικά ελάχιστα. Το Batch size (μέγεθος παρτίδας) καθορίζει πόσα δείγματα χρησιμοποιούνται για να εκτιμηθεί κάθε φορά η κλίση του σφάλματος. Μικρό batch (π.χ. 8–16) ίσως εισάγει θόρυβο στην κλίση αλλά συχνά γενικεύει καλύτερα σε μικρές χρονοσειρές, αλλά επίσης κάνει την εκπαίδευση πιο αργή ανά εποχή. Μεγάλο batch (π.χ. 128–256) ίσως σταθεροποιεί τις κλίσεις και επιταχύνει την εκπαίδευση, αλλά μπορεί να χειροτερέψει τη γενίκευση και να χάσει σπάνια γεγονότα μέσα στον μέσο όρο του batch. Για σειρές με ακραίες τιμές είναι συνήθως προτιμότερα μικρότερα batches ώστε τα ακραία να επηρεάζουν περισσότερο την ενημέρωση των βαρών. Οι δύο υπερπαραμέτροι αλληλεπιδρούν για αυτό για κάθε μεταβολή της μίας από τις δύο ελέγχεται και η άλλη.
- Παράθυρο ιστορικού (input_len). Ορίζει πόσο παρελθόν βλέπει το δίκτυο και επηρεάζει άμεσα τα εποχικά/κυκλικά σήματα που μπορεί να μάθει το μοντέλο. Θα ελεγχθούν οι τιμές 6, 12, 18, 24. Μικρό παράθυρο μπορεί να συνεπάγεται λιγότερη μνήμη, πιο σταθερή εκπαίδευση αλλά μη αναγνώριση δομών, ενώ μεγάλο παράθυρο μπορεί να συνεπάγεται πλουσιότερο πλαίσιο παρατηρήσεων αλλά περισσότερες παράμετροι και κίνδυνος υπερπροσαρμογής.
- Κατώφλι EVT (percentile). Για την ενίσχυση της μάθησης στα ακραία γεγονότα εφαρμόστηκε προσέγγιση Extreme Value Theory (EVT) τύπου Peak-Over-Threshold. Ορίστηκε κατώφλι ως p-οστό εκατοστημόριο του δείκτη έντασης, ώστε το άνω p%


των τιμών να θεωρείται υπέρβαση. Για παράδειγμα, αν οριστεί $p=95$, τότε το u είναι η τιμή κάτω από την οποία βρίσκεται το 95% των δειγμάτων, άρα το πάνω 5% θεωρείται ακραίο (exceedances). Πάνω σ' αυτά τα ακραία ($x>u$) εφαρμόζεται Peak-Over-Threshold και προσαρμόζεται μια Γενικευμένη Κατανομή Pareto (GPD). Από τα ακραία δείγματα υπολογίζονται τα βάρη (όσο πιο μακριά από το κατώφλι, τόσο μεγαλύτερο βάρος), και γίνεται κανονικοποίηση. Έτσι, τα ακραία δείγματα μετράνε περισσότερο κατά την εκπαίδευση. Χαμηλό κατώφλι (π.χ. 90%) μπορεί να σημαίνει πως πολλά δείγματα χαρακτηρίζονται ως ακραία και τα βάρη απλώνονται πιο ομοιόμορφα άρα θα υπάρξουν πιο ήπιοι τονισμοί των ακραίων, καλύτερη σταθερότητα, αλλά μικρότερη εστίαση στα πραγματικά spikes. Υψηλό κατώφλι (π.χ. 97.5–99) μπορεί να σημαίνει λίγα, πολύ βαριά δείγματα. Γίνεται έντονη στόχευση στα spikes, αλλά αυξάνει ο κίνδυνος αστάθειας (λίγες παρατηρήσεις για να εκτιμηθεί σωστά η ουρά).

5.2.6.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ


Το σύνολο δεδομένων χωρίστηκε σε 85% σύνολο εκπαίδευσης και 15% σύνολο επικύρωσης. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των παραμέτρων. Για το batch size ελέγχονται οι τιμές 16, 32, 64, 128 και για το learning rate οι τιμές 0.001, 0.0001 και 0.00001. Για την παράμετρο του παραθύρου ιστορικού εξετάστηκαν οι τιμές 6, 12, 18, 24. Τέλος για την τιμή κατωφλίου p εξετάστηκαν τα ποσοστά 92.5, 95, 97.5 και 99.



Εικόνα 84: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_EVT με σταθερό ρυθμό εκπαίδευση 0.00001.




Εικόνα 85: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_EVT με σταθερό ρυθμό εκπαίδευση 0.0001




Εικόνα 86: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_EVT με σταθερό ρυθμό εκπαίδευση 0.001

Παρατηρώντας τα διαγράμματα απόδοσης συναρτήσει των υπερπαραμέτρων learning rate και batch size, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμές learning_rate = 0.0001 και batch size = 32.




Εικόνα 87: Επίδραση του μεγέθους παραθύρου ιστορικού στην απόδοση του μοντέλου Reweight-EVT.

Παρατηρώντας το διάγραμμα απόδοσης συναρτήσει της ιστορικού παραθύρου, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμή input_len= 12 μήνες.



Εικόνα 88: Επίδραση της τιμής κατωφλίου στην απόδοση του μοντέλου Reweight-EVT.

Παρατηρώντας το διάγραμμα απόδοσης συναρτήσει του εκατοστημορίου, συμπεράνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμή percentile=95. Τα αποτελέσματα πρόβλεψης του μοντέλου με $\text{learning_rate} = 0.0001$, $\text{BATCH} = 32$, $\text{input_len}=12$ και $\text{percentile}=95$ δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:




Εικόνα 89: Σύγκριση πραγματικής σειράς και Reweight_EVT προβλέψεων στα δεδομένα μεγίστων μηνιαίων θερμοκρασιών.

RMSE: 1.26, MAE: 0.98.


Η πρόβλεψη ακολουθεί πολύ καλά την ετήσια εποχικότητα της χρονοσειράς. Οι κορυφές και οι κοιλάδες εμφανίζονται σχεδόν στις σωστές χρονικές στιγμές, χωρίς εμφανές συστηματικό lag. Το μοντέλο τείνει να εξομαλύνει ελαφρώς το σήμα καθώς οι καλοκαιρινές κορυφές συχνά υποεκτιμώνται ελαφρά και οι χειμερινές χαμηλές τιμές υπερεκτιμώνται. Δηλαδή το πλάτος των εποχικών διακυμάνσεων συμπιέζεται, κάτι αναμενόμενο σε μοντέλα που ελαχιστοποιούν MSE όπως έχει ξανα αναφερθεί. Το RMSE = 1.26 °C είναι λίγο μεγαλύτερο από το MAE, δείχνοντας ότι υπάρχουν ορισμένα σχετικά μεγαλύτερα λάθη πρόβλεψης (κυρίως σε αιχμές), αλλά όχι σε συχνή βάση. Το Reweight-EVT αποδίδει πολύ καλά στη γενική εποχική δομή και στο μέσο επίπεδο της σειράς, με χαμηλά μηνιαία σφάλματα (~1 °C). Το κύριο περιθώριο βελτίωσης αφορά την ένταση των ακραίων κορυφών/κοιλάδων, όπου η πρόβλεψη εμφανίζεται πιο ομαλή από το πραγματικό σήμα. Για εργασίες που απαιτούν πιστή αποτύπωση της εποχικότητας και του baseline είναι ιδιαίτερα επαρκές, για έμφαση όμως στα ακραία συμβάντα αν και αρκετά ικανοποιητικό ίσως χρειαστεί πιο επιθετική στάθμιση EVT ή πρόσθετα χαρακτηριστικά που ενισχύουν το πλάτος.

5.2.6.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια


Το σύνολο δεδομένων χωρίστηκε σε 80% σύνολο εκπαίδευσης και 10% σύνολο επικύρωσης. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των παραμέτρων. Για το learning rate ελέγχονται οι τιμές 16, 32, 64, 128 και 256 και για το batch size οι τιμές 0.1, 0.01 και 0.001. Για την παράμετρο του παραθύρου ιστορικού εξετάστηκαν οι τιμές 6, 12, 18, 24. Τέλος για την τιμή κατωφλίου p εξετάστηκαν τα ποσοστά 92.5, 95, 97.5 και 99.



Εικόνα 90: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_EVT με σταθερό ρυθμό εκπαίδευση 0.1.




Εικόνα 91: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight-EVT με σταθερό ρυθμό εκπαίδευση 0.01.




Εικόνα 92: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_EVT με σταθερό ρυθμό εκπαίδευση 0.001.

Παρατηρώντας τα διαγράμματα απόδοσης συναρτήσεως των υπερπαραμέτρων learning rate και batch size, συμπραίνουμε ότι τα καλύτερα αποτελέσματα για το μοντέλο προκύπτουν για τιμές learning_rate = 0.1 και BATCH = 64.




Εικόνα 93: Επίδραση του μεγέθους ιστορικού παραθύρου στην απόδοση του μοντέλου Reweight-EVT.

Παρατηρώντας το διάγραμμα απόδοσης συναρτήσει της ιστορικού παραθύρου, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμή `input_len=12`.



Εικόνα 94: Επίδραση της τιμής κατωφλίου στην απόδοση του μοντέλου Reweight-EVT.

Παρατηρώντας το διάγραμμα απόδοσης συναρτήσει του εκατοστημορίου, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμή `percentile=95`. Τα αποτελέσματα πρόβλεψης του μοντέλου με `learning_rate = 0.1`, `BATCH = 64`, `input_len=12` και `percentile=95` δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:



Εικόνα 95: Σύγκριση πραγματικής σειράς και Reweight_EVT προβλέψεων στα δεδομένα μεγίστων μηνιαίων σεισμικών εντάσεων.


RMSE: 0.97, MAE: 0.74.

Η καμπύλη πρόβλεψης κινείται γύρω από ένα σχετικά σταθερό επίπεδο (~5–5.6) και ακολουθεί τον μέσο όρο της σειράς, αλλά με μικρό πλάτος διακύμανσης. Το εύρος διακύμανσης των προβλέψεων είναι εμφανώς μικρότερο από εκείνο των πραγματικών τιμών, οι απότομες αιχμές σε μήνες με έντονες εκτιμήσεις έντασης υποεκτιμώνται συστηματικά. Επιπλέον, στο συγκεκριμένο σύνολο δεδομένων δεν προκύπτει σαφές επαναλαμβανόμενο εποχικό μοτίβο· συνεπώς το μοντέλο δεν διαθέτει ισχυρά περιοδικά σήματα για να στοχεύσει χρονικά τις κορυφές. Η συμπεριφορά αυτή είναι αναμενόμενη για σήματα με σποραδικά, μη γραμμικά ακραία γεγονότα και χαμηλή αυτοσυσχέτιση. Η εκπαίδευση με MSE ωθεί τις προβλέψεις προς τον μέσο, ενώ ο μηχανισμός αναβάθμισης βαρών (EVT reweighting) ενδέχεται να μην είναι αρκετά επιθετικός ώστε οι λίγες ακραίες παρατηρήσεις να επηρεάζουν ουσιαστικά τη συνάρτηση κόστους.


5.2.6.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ

Το σύνολο δεδομένων χωρίστηκε σε 80% σύνολο εκπαίδευσης και 10% σύνολο επικύρωσης. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των παραμέτρων. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των παραμέτρων. Για το learning rate ελέγχονται οι τιμές 16, 32, 64, 128 και 256 και για το batch size οι τιμές 0.01, 0.001 και


0.0001. Για την παράμετρο του παραθύρου ιστορικού εξετάστηκαν οι τιμές 6, 12, 18, 24. Τέλος για την τιμή κατωφλίου ρ εξετάστηκαν τα ποσοστά 92.5, 95, 97.5 και 99.



Εικόνα 96: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_EVT με σταθερό ρυθμό εκπαίδευση 0.0001.




Εικόνα 97: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_EVT με σταθερό ρυθμό εκπαίδευση 0.001.




Εικόνα 98: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_EVT με σταθερό ρυθμό εκπαίδευση 0.01.

Παρατηρώντας τα διαγράμματα απόδοσης συναρτήσει των υπερπαραμέτρων learning rate και batch size, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμές learning_rate = 0.001 και BATCH = 32.




Εικόνα 99: Επίδραση του μεγέθους παραθύρου ιστορικού στην απόδοση του μοντέλου Reweight_EVT.

Παρατηρώντας το διάγραμμα απόδοσης συναρτήσει της ιστορικού παραθύρου, συμπεράνουμε οτι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμή $input_len=12$.



Εικόνα 100: Επίδραση της τιμής κατωφλίου στην απόδοση του μοντέλου Reweight_EVT.

Παρατηρώντας το διάγραμμα απόδοσης συναρτήσεως του εκατοστημορίου, συμπεράνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμή percentile=95. Τα αποτελέσματα πρόβλεψης του μοντέλου με `learning_rate = 0.001`, `BATCH = 32`, `input_len=12` και `percentile=95` δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:



Εικόνα 101: Σύγκριση πραγματικής σειράς και Reweight-EVT προβλέψεων στα δεδομένα συνολικών μηνιαίων βροχοπτώσεων.

RMSE: 89.61, MAE: 66.72.

Το Reweight-EVT αποδίδει τη βασική τάση της μηνιαίας βροχόπτωσης και φαίνεται να εντοπίζει ένα σήμα προβλέποντας μια εναλλαγή υγρων και ξηρών μηνών, αλλά υστερεί πολύ σημαντικά στη σύλληψη της έντασης των ακραίων επεισοδίων. Οι σποραδικές, πολύ υψηλές αιχμές (π.χ. >300–600) αλλά ακόμα και μικρότερες τιμές που δεν αποτελούν ακραίες τιμές χάνονται αφού η καμπύλη παραμένει γύρω από ένα σχετικά σταθερό επίπεδο (~70–100), με έντονη εξομάλυνση. Φαίνεται καταλληλότερο για την πρόβλεψη μέσου φορτίου βροχής, όχι όμως για ακριβή πρόβλεψη σπάνιων μεγάλων φαινομένων, που είναι και το πιο δύσκολο κομμάτι αυτής της χρονοσειράς.

5.2.7 Reweight-META

Στα πειράματα της παρούσας εργασίας διατηρήθηκε η βασική αρχιτεκτονική και ο τρόπος λειτουργίας του μοντέλου κάνοντας μόνο κάποιες προσαρμογές προκειμένου το μοντέλο να μπορεί να δεχθεί τα υπό μελέτη σύνολα δεδομένων. Οι τροποποιήσεις που έγιναν αφορούν ρυθμίσεις για τα δεδομένα καθώς πρόκειται για μονομεταβλητές σειρές μηνιαίων τιμών και είναι οι εξής:


- Πλέον αντί για κυλιόμενο παράθυρο 72 ωρών και ορίζοντα 12 βημάτων για μια πολυμεταβλητή σειρά, το μοντέλο δέχεται μια μονομεταβλητή σειρά με παράθυρο 12 μηνών και ορίζοντα 1 μήνα.
- Ο διαχωρισμός των δεδομένων γίνεται πλέον με βάση ημερομηνίες και όχι ως ποσοστό του συνόλου.

Για τα υπό μελέτη σύνολα δεδομένων, προκειμένου να βρεθούν οι κατάλληλες υπερπαραμέτροι για το μοντέλο έγιναν διάφορα πειράματα και για διάφορες τιμές κάποιων επιλεγμένων υπερπαραμέτρων. Οι παράμετροι που εξετάστηκαν είναι:


- Ρυθμός μάθησης των βαρών (meta learning rate). Ο ρυθμός μάθησης των βαρών (meta-LR) είναι η βασική ρύθμιση που καθορίζει πόσο γρήγορα ανακατανέμονται τα βάρη ανά δείγμα στο Reweight_META ώστε να δοθεί έμφαση στα ακραία. Μεγάλο meta-LR ίσως τα κάνει να αλλάζουν επιθετικά (κίνδυνος αστάθειας λόγω περσυγκέντρωσης βάρους σε λίγα δείγματα), μικρό meta-LR μπορεί να τα αφήνει σχεδόν ομοιόμορφα (ουσιαστικά σαν ERM).
- Ο Ρυθμός μάθησης (learning rate) και το μέγεθος παρτίδας (BATCH). Το learning rate ορίζει πόσο μεγάλο βήμα κάνει ο βελτιστοποιητής σε κάθε ενημέρωση βαρών. Πολύ υψηλή τιμή επιταχύνει την εκπαίδευση πιθανώς αλλά μπορεί να χάσει τοπικά ελάχιστα ενώ πολύ μικρή τιμή απαιτεί περισσότερες εποχές και υπάρχει κίνδυνος να κολλήσει σε τοπικά ελάχιστα. Το Batch size καθορίζει πόσα δείγματα χρησιμοποιούνται για να εκτιμηθεί κάθε φορά η κλίση του σφάλματος.
- Παράθυρο ιστορικού (input_len). Ορίζει πόσο παρελθόν βλέπει το δίκτυο, επηρεάζει άμεσα τα εποχικά/κυκλικά σήματα που μπορεί να μάθει το μοντέλο.
- Κατώφλι Percentile. Ο ορισμός των ακραίων καθορίζει τι ακριβώς βελτιστοποιεί το Reweight_META και γι' αυτό πρέπει να είναι σαφής, τεκμηριωμένος και συμβατός με το εκάστοτε πεδίο. Συνήθως χρησιμοποιείται ένα κατώφλι ποσοστημορίου P (π.χ. 92.5/95/97.5/99), ώστε ως ακραία να χαρακτηρίζονται οι παρατηρήσεις του στόχου y που υπερβαίνουν το κατώφλι.

5.2.7.1 Μέγιστες Μηνιαίες Θερμοκρασίες - Χονγκ Κονγκ


Το σύνολο δεδομένων χωρίστηκε σε 85% σύνολο εκπαίδευσης και 15% σύνολο επικύρωσης. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των παραμέτρων. Τα πειράματα έγιναν για τιμές meta-LR 0.00001, 0.0001, 0.0005, 0.001, 0.005, 0.001 και 0.05, για το batch size ελέγχονται οι τιμές 16, 32, 64, 128 και 256 για το learning rate οι τιμές 0.001, 0.0001 και 0.00001. Για την παράμετρο του παραθύρου ιστορικού εξετάστηκαν οι τιμές 6, 12, 18, 24 και τέλος για την τιμή κατωφλίου ρ εξετάστηκαν τα ποσοστά 92.5, 95, 97.5 και 99.



Εικόνα 102: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_META με σταθερό ρυθμό εκπαίδευση 0.00001.




Εικόνα 103: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_META με σταθερό ρυθμό εκπαίδευση 0.0001.




Εικόνα 104: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_META με σταθερό ρυθμό εκπαίδευση 0.001.

Παρατηρώντας τα διαγράμματα απόδοσης συναρτήσεως των υπερπαραμέτρων learning rate και batch size, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμές learning_rate = 0.00001 και BATCH = 128.




Εικόνα 105: Επίδραση του ρυθμού meta-learning στην απόδοση του μοντέλου Reweight_META.

Παρατηρώντας τα διαγράμματα απόδοσης συναρτήσεως των υπερπαραμέτρων meta-learning, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμές meta_learning = 0.005.




Εικόνα 106: Επίδραση του μεγέθους του ιστορικού παραθύρου στην απόδοση του μοντέλου Reweight_META.

Παρατηρώντας το διάγραμμα απόδοσης συναρτήσει της ιστορικού παραθύρου, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμή $input_len=12$.



Εικόνα 107: Επίδραση της τιμής κατωφλίου στην απόδοση του μοντέλου Reweight_META.


Παρατηρώντας το διάγραμμα απόδοσης συναρτήσεως του εκατοστημορίου, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμή percentile=92.5. Τα αποτελέσματα πρόβλεψης του μοντέλου με `learning_rate = 0.00001`, `BATCH = 128`, `meta_learning = 0.005`, `input_len=12` και `percentile=92.5` δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:



Εικόνα 108: Σύγκριση πραγματικής σειράς και Reweight_META προβλέψεων στα δεδομένα μεγίστων μηνιαίων θερμοκρασιών.

RMSE: 1.32, MAE: 1.03.

Η καμπύλη πρόβλεψης του Reweight_META ακολουθεί αρκετά καλά την πραγματική μηνιαία μέγιστη θερμοκρασία, αναπαράγοντας αρκετά πιστά την εποχικότητα και το εύρος τιμών. Οι συνολικές μετρικές $RMSE=1.32^{\circ}C$ και $MAE=1.03^{\circ}C$ δείχνουν μέσο σφάλμα της τάξης του $\sim 1^{\circ}C$, άρα η γενική προσαρμογή είναι καλή. Οπτικά, τα μεγαλύτερα σφάλματα εμφανίζονται κυρίως στις κορυφές και κοιλάδες με ελαφρά υποεκτίμηση των θερμών ενώ παρατηρείται σε κάποιες προβλέψεις υπερεκτίμηση των ελαχίστων. Με βάση τον σκοπό του Reweight_META (έμφαση στα άκρα), τα αποτελέσματα υποδηλώνουν ότι το μοντέλο συλλαμβάνει αξιόπιστα το υπόβαθρο και τις ήπιες διακυμάνσεις, με περιθώριο βελτίωσης ακριβώς στις ακραίες τιμές το οποίο ίσως να βελτιωνόταν με fine-tuning μόνο στα ακραία. Συνολικά, η επίδοση είναι ισορροπημένη με μικρό μέσο σφάλμα, καλή εποχική πιστότητα και μεμονωμένες αποκλίσεις στα σημεία μέγιστης δυσκολίας που στοχεύει η μέθοδος.




Εικόνα 109: Σύγκριση πραγματικής σειράς DAN, Reweight_EVT και Reweight_META προβλέψεων στα δεδομένα μεγίστων μηνιαίων θερμοκρασιών.

Όπως φαίνεται στο συγκριτικό διάγραμμα των προβλέψεων των τριών μοντέλων για τα δεδομένα θερμοκρασιών, και τα τρία μοντέλα αποδίδουν σωστά την ετήσια εποχικότητα και δεν εμφανίζουν ουσιαστική υστέρηση φάσης καθώς οι κορυφές και οι κοιλάδες ευθυγραμμίζονται χρονικά με τα πραγματικά δεδομένα. Ωστόσο διαφέρουν στο πλάτος και στη διαχείριση των μεγίστων και ελαχίστων τιμών καθώς το DAN (πορτοκαλί) είναι το πιο ομαλό και τείνει να υποεκτιμά συστηματικά τις θερινές κορυφές και να υπερεκτιμά ελαφρά ορισμένες χειμερινές ελάχιστες. Το Reweight-EVT (πράσινο) διατηρεί μεγαλύτερο πλάτος στις περισσότερες χρονιές οι κορυφές του είναι πιο κοντά στα πραγματικά (μερικές φορές και ελαφρώς πάνω από αυτά), άρα αποδίδει καλύτερα τα έντονα καλοκαίρια αλλά με μικρό ρίσκο υπερεκτίμησης. Το Reweight-META (κόκκινο) ισορροπεί ανάμεσα στα δύο καθώς κρατά σχεδόν το ίδιο εύρος με το EVT, αλλά εμφανίζει λίγο πιο συντηρητική προσέγγιση στις κορυφές σε σχέση με το Reweight-EVT. Συνοψίζοντας, για γενική τάση και σταθερές προβλέψεις το DAN είναι ασφαλές ενώ για αποτύπωση ακραίων θερμών περιόδων το Reweight-EVT και κυρίως το Reweight-META φαίνονται πιο κατάλληλα, με το EVT να προσφέρει την πιο ισορροπημένη εικόνα ανάμεσα σε ακρίβεια κορυφών και συνολική ομαλότητα.


5.2.7.2 Μέγιστες Μηνιαίες Σεισμικές Εντάσεις - Καλιφόρνια

Το σύνολο δεδομένων χωρίστηκε σε 80% σύνολο εκπαίδευσης και 10% σύνολο επικύρωσης. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των παραμέτρων. Τα πειράματα έγιναν για τιμές meta-LR 0.00001, 0.0001, 0.0005, 0.001, 0.005, 0.001 και 0.05, για το batch size ελέγχονται οι τιμές 16, 32, 64, 128 και 256 για το learning rate οι τιμές 0.001, 0.0001 και 0.00001. Για την παράμετρο


του παραθύρου ιστορικού εξετάστηκαν οι τιμές 6, 12, 18, 24 και τέλος για την τιμή κατωφλίου ρ εξετάστηκαν τα ποσοστά 92.5, 95, 97.5 και 99.



Εικόνα 110: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_META με σταθερό ρυθμό εκπαίδευση 0.00001.




Εικόνα 111: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_META με σταθερό ρυθμό εκπαίδευση 0.0001.




Εικόνα 112: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_META με σταθερό ρυθμό εκπαίδευση 0.001.

Παρατηρώντας τα διαγράμματα απόδοσης συναρτήσεως των υπερπαραμέτρων learning rate και batch size, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμές learning_rate = 0.001 και BATCH = 32.




Εικόνα 113: Επίδραση του ρυθμού meta-learning στην απόδοση του μοντέλου Reweight_META.

Παρατηρώντας τα διαγράμματα απόδοσης συναρτήσει των υπερπαραμέτρων meta-learning, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμές $\text{meta_learning} = 0.001$.




Εικόνα 114: Επίδραση του μεγέθους του ιστορικού παραθύρου στην απόδοση του μοντέλου Reweight_META.

Παρατηρώντας το διάγραμμα απόδοσης συναρτήσει του ιστορικού παραθύρου, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμή $\text{input_len}=18$.



Εικόνα 115: Επίδραση της τιμής κατωφλίου στην απόδοση του μοντέλου Reweight_META.


Παρατηρώντας το διάγραμμα απόδοσης συναρτήσεως του εκατοστημορίου, συμπεράνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμή percentile=92.5. Τα αποτελέσματα πρόβλεψης του μοντέλου με $\text{learning_rate} = 0.001$, $\text{BATCH} = 32$, $\text{meta_learning} = 0.001$, $\text{input_len}=18$ και $\text{percentile}=92.5$ δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:



Εικόνα 116: Σύγκριση πραγματικής σειράς και Reweight_META προβλέψεων στα δεδομένα μεγίστων μηνιαίων σεισμικών εντάσεων.

RMSE: 1.05, MAE: 0.82.

Η απόδοση του Reweight_META στα δεδομένα μέγιστης μηνιαίας σεισμικής έντασης δείχνει ότι το μοντέλο αναπαράγει ικανοποιητικά το κεντρικό επίπεδο χωρίς όμως να εντοπίζει ικανοποιητικά τις διακυμάνσεις της σειράς, με $MAE=0.82$ και $RMSE=1.05$ μονάδες ένταση. Η σχέση $RMSE > MAE$ υποδηλώνει ότι, παρότι τα περισσότερα σφάλματα είναι μικρά, υπάρχουν αραιές αλλά έντονες αποκλίσεις στις ακραίες κορυφές/κοιλάδες. Οπτικά, η προβλεπόμενη καμπύλη τείνει να είναι πιο ομαλή από την πραγματική ενώ γενικά υποεκτιμά τις πολύ υψηλές αιχμές (π.χ. γύρω στο 1979–1980) και κατά διαστήματα υπερεκτιμά χαμηλά τοπικά ελάχιστα, και εμφανίζει τυπικό φαινόμενο “regression to the mean” σε σήματα με σπάνια και θορυβώδη άκρα. Οι προβλέψεις του συγκεκριμένου μοντέλου φαίνεται να είναι καλύτερες από όλων των προηγούμενων υπο την έννοια ότι όντως το μοντέλο φαίνεται να προσπαθεί να προβλέψει ακραίες τιμές προβλέποντας μέχρι και την τιμή έντασης 8 αν και παρόλα αυτά δεν καταφέρνει να την τοποθετήσει χρονικά σωστά. Επίσης το συγκεκριμένο μοντέλο εμφανίζει μεγαλύτερο εύρος τιμών πρόβλεψης σε σύγκριση με τα προηγούμενα μοντέλα. Θα μπορούσαμε να πούμε έτσι λοιπόν ότι το μοντέλο απαντά με επιτυχία σε ένα ερώτημα πρόβλεψης του τύπου “Ποια είναι η μέγιστη τιμή σεισμικής έντασης που μπορεί να παρατηρηθεί στην περιοχή για τα επόμενα 5 χρόνια, δηλαδή για την περίοδο 1972-1977”, καθώς όντως η μέγιστη τιμή είναι το 8. Το μοντέλο είναι αξιόπιστο στη μέση συμπεριφορά της σειράς, αλλά έχει σημαντικό περιθώριο βελτίωσης ακριβώς εκεί όπου μας ενδιαφέρει περισσότερο, στις σπάνιες έντονες εξάρσεις.




Εικόνα 117: Σύγκριση πραγματικής σειράς DAN, Reweight_EVT και Reweight_META προβλέψεων στα δεδομένα μεγίστων μηνιαίων σεισμικών εντάσεων.

Με βάση το διάγραμμα σύγκρισης των προβλέψεων των τριών μοντέλων στα δεδομένα σεισμικών εντάσεων, όλα τα μοντέλα αποδίδουν ένα βασικό επίπεδο της μηνιαίας σεισμικής έντασης γύρω στο 5–5.5, χωρίς όμως οι διακύμανση των προβλέψεων να ακολουθεί πιστά εκείνη των πραγματικών τιμών. Το DAN φαίνεται να είναι το πιο συντηρητικό καθώς μειώνει έντονα το πλάτος, υποεκτιμά συστηματικά τις κορυφές και υπερεκτιμά τα χαμηλά. Το


Reweight-EVT κρατά μεγαλύτερο πλάτος και πλησιάζει καλύτερα τις μέτριες κορυφές, όμως και αυτό δεν πιάνει τα πολύ μεγάλα μέγιστα ή ελάχιστα και κατά διαστήματα εμφανίζει μικρά overshoots. Το Reweight-META αντιδρά πιο γρήγορα στις μεταβολές και διαφοροποιεί περισσότερο τις κοιλάδες, προσφέροντας μια ισορροπία ανάμεσα στην ομαλότητα του DAN και το μεγαλύτερο πλάτος του EVT, αλλά παραμένει ανεπαρκές για τις εξαιρετικά σπάνιες κορυφές. Συνοψίζοντας, το Reweight-META δίνει την πιο προσαρμοστική συμπεριφορά συνολικά, χωρίς όμως να επιλύει το πρόβλημα μη πρόβλεψης ακραίων τιμών όπου και αναγνωρίζεται η ανάγκη για ισχυρότερη έμφαση στα άκρα (π.χ. αυστηρότερος ορισμός extremes, tuning στο meta-LR, ή fine-tuning μόνο στα άκρα) αν και το μοντέλο προέβλεψε μια ακραία τιμή η οποία όμως δεν είναι σωστά χρονικά τοποθετημένη.

5.2.7.3 Συνολικές Μηνιαίες Βροχοπτώσεις - Σίδνεϊ


Το σύνολο δεδομένων χωρίστηκε σε 80% σύνολο εκπαίδευσης και 10% σύνολο επικύρωσης. Παρακάτω δίνονται διαγράμματα μεταβολής της απόδοσης του μοντέλου συναρτήσει των τιμών των παραμέτρων. Τα πειράματα έγιναν για τιμές meta-LR 0.00001, 0.0001, 0.0005, 0.001, 0.005, 0.001 και 0.05, για το batch size ελέγχονται οι τιμές 16, 32, 64, 128 και 256 για το learning rate οι τιμές 0.001, 0.0001 και 0.00001. Για την παράμετρο του παραθύρου ιστορικού εξετάστηκαν οι τιμές 6, 12, 18, 24 και τέλος για την τιμή κατωφλίου ρ εξετάστηκαν τα ποσοστά 92.5, 95, 97.5 και 99.



Εικόνα 118: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_META με σταθερό ρυθμό εκπαίδευση 0.00001.




Εικόνα 119: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_META με σταθερό ρυθμό εκπαίδευση 0.0001.




Εικόνα 120: Επίδραση του μεγέθους παρτίδας στην απόδοση του μοντέλου Reweight_META με σταθερό ρυθμό εκπαίδευση 0.001.

Παρατηρώντας τα διαγράμματα απόδοσης συναρτήσει των υπερπαραμέτρων learning rate και batch size, συμπαιρόνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμές learning_rate = 0.00001 και BATCH = 128.




Εικόνα 121: Επίδραση του ρυθμού meta-learning στην απόδοση του μοντέλου Reweight_META.

Παρατηρώντας τα διαγράμματα απόδοσης συναρτήσει των υπερπαραμέτρων meta-learning, συμπεραίνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμές meta_learning = 0.005.




Εικόνα 122: Επίδραση του μεγέθους του ιστορικού παραθύρου στην απόδοση του μοντέλου Reweight_META.

Παρατηρώντας το διάγραμμα απόδοσης συναρτήσει της ιστορικού παραθύρου, συμπεράνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμή $input_len=18$.



Εικόνα 123: Επίδραση της τιμής κατωφλίου στην απόδοση του μοντέλου Reweight_META.


Παρατηρώντας το διάγραμμα απόδοσης συναρτήσεως του εκατοστημορίου, συμπεράνουμε ότι τα καλύτερα αποτελέσματα από το μοντέλο προκύπτουν για τιμή $\text{percentile}=99$. Τα αποτελέσματα πρόβλεψης του μοντέλου με $\text{learning_rate} = 0.00001$, $\text{BATCH} = 128$, $\text{meta-learning} = 0.005$, $\text{input_len}=18$ και $\text{percentile}=99$ δίνονται στο διάγραμμα παρακάτω και οι αντίστοιχες μετρικές είναι οι εξής:



Εικόνα 124: Σύγκριση πραγματικής σειράς και Reweight_META προβλέψεων στα δεδομένα συνολικών μηνιαίων βροχοπτώσεων.

RMSE: 92.87, MAE: 68.95.

Στα μηνιαία ύψη βροχής το Reweight_META αποδίδει σχετικά καλά τη μέση συμπεριφορά, αλλά δυσκολεύεται να αποτυπώσει τις μεγάλες αιχμές καθώς η καμπύλη πρόβλεψης κινείται σε στενότερο εύρος γύρω από το τυπικό επίπεδο, ενώ τα πραγματικά δεδομένα παρουσιάζουν έντονα, σποραδικά spikes (π.χ. >300 – 600). Οι μετρικές $\text{RMSE}=92.87$ και $\text{MAE}=68.95$ mm σημαίνουν ότι το μέσο απόλυτο σφάλμα είναι της τάξης μερικών δεκάδων mm, αλλά όταν εμφανίζονται ακραίες βροχές το σφάλμα αυξάνει αισθητά, αυτό φαίνεται και από το ότι το RMSE είναι σημαντικά μεγαλύτερο από το MAE. Με άλλα λόγια, το μοντέλο παρακολουθεί το υπόβαθρο, όμως τείνει να υποεκτιμά τις πολύ υγρές περιόδους και να υπερεκτιμά τις πολύ ξηρές. Συνεπώς, για εργασίες γενικής πρόβλεψης ή εποχικής τάσης η απόδοση είναι σχετικά αξιοπρεπής, αλλά για χρήσεις όπου η ακρίβεια στα άκρα (πλημμυρικός κίνδυνος, διαστασιολόγηση υποδομών) είναι κρίσιμη, χρειάζεται σημαντική ενίσχυση.



Εικόνα 125: Σύγκριση πραγματικής σειράς DAN, Reweight_EVT και Reweight_META προβλέψεων στα δεδομένα συνολικών μηνιαίων βροχοπτώσεων.

Συνολικά, και τα τρία μοντέλα αποδίδουν σχετικά καλά το υπόβαθρο της μηνιαίας βροχόπτωσης (~60–150 mm), αλλά δυσκολεύονται στις πολύ μεγάλες αιχμές (≥ 200 –600 mm). Το Reweight_EVT αποτελεί την πιο ομαλή καμπύλη καθώς τείνει στην υποεκτίμηση ισχυρών επεισοδίων, ελαφρά υπερεκτίμηση πολύ ξηρών μηνών. Το DAN κρατά μεγαλύτερο πλάτος και ακολουθεί καλύτερα μέτριες εξάρσεις (μέχρι τα 300 mm) ακολουθώντας πολύ πιστά την διακύμανση των πραγματικών τιμών αποτυγχάνοντας όμως στις πολύ υψηλές βροχές. Το Reweight-META είναι το πιο ευαίσθητο στις απότομες μεταβολές και σε αρκετά διαστήματα προσεγγίζει καλά τις αιχμές, αλλά παρουσιάζει μεγαλύτερη διασπορά και ορισμένα μη ρεαλιστικά dips (ακόμη και κάτω από το μηδέν), ένδειξη ότι χρειάζεται περιορισμός μη αρνητικότητας. Συνοψίζοντας το DAN εμφανίζει την πιο ισορροπημένη πρόβλεψη επιτυγχάνοντας ένα συνδυασμό σημαντικής διασποράς τιμών και πιστής απεικόνισης της εποχικότητας της σειράς.

	Μέγιστες Μηνιαίες Θερμοκρασίες		Μέγιστες Μηνιαίες Σεισμικές Εντάσεις		Συνολική Μηνιαία Βροχόπτωση	
	RMSE	MAE	RMSE	MAE	RMSE	MAE
ARIMA	1.75	1.40	0.95	0.77	90.22	65.91
SARIMA	1.22	0.94	0.95	0.77	89.07	64.23
CNN	1.22	0.95	0.95	0.74	91.38	66.86
GRU	1.34	1.05	0.97	0.72	89.39	65.59
DAN	1.39	0.98	0.95	0.74	92.85	73.02
Reweight_EVT	1.26	0.98	0.97	0.74	89.61	66.72
Reweight_META	1.32	1.03	1.05	0.82	92.87	68.95

Πίνακας 1: Συγκεντρωτικός πίνακας αποδόσεων των μοντέλων στα διαφορετικά σύνολα δεδομένων.

Παρατηρώντας το συγκεντρωτικό πίνακα αποτελεσμάτων των μετρικών των μοντέλων για κάθε σύνολο δεδομένων, συμπεραίνουμε πως αν και οι μετρικές RMSE και MAE δίνουν μια σαφή ένδειξη της μέσης ακρίβειας των προβλέψεων, σε ορισμένες περιπτώσεις μπορεί να οδηγήσουν σε παραπλανητικά συμπεράσματα. Για παράδειγμα, παρατηρείται ότι μοντέλα όπως το SARIMA σε συγκεκριμένα σύνολα δεδομένων εμφανίζουν χαμηλότερες τιμές στις μετρικές, κάτι που θα μπορούσε να εκληφθεί ως ανώτερη συνολική απόδοση. Ωστόσο, η φαινομενική αυτή βελτίωση οφείλεται στο γεγονός ότι το μοντέλο τείνει να προβλέπει τιμές κοντά στον μέσο όρο της χρονοσειράς, στρατηγική που μειώνει το συνολικό σφάλμα στις συνηθισμένες τιμές αλλά αδυνατεί να αποτυπώσει τη φυσική μεταβλητότητα της σειράς και κυρίως τις ακραίες εξάρσεις.

Το φαινόμενο αυτό προκύπτει επειδή οι RMSE και MAE είναι μετρικές που δίνουν μεγαλύτερη βαρύτητα στις συχνές παρατηρήσεις γύρω από τον μέσο όρο, ενώ οι λίγες και σπάνιες ακραίες τιμές έχουν μικρή συνεισφορά στο συνολικό σφάλμα. Έτσι, ένα «συντηρητικό» μοντέλο που εξομαλύνει τις διακυμάνσεις επιτυγχάνει αριθμητικά καλύτερες επιδόσεις, χωρίς ωστόσο να παράγει ποιοτικά πιο χρήσιμες προβλέψεις. Αυτό είναι ιδιαίτερα κρίσιμο στις περιβαλλοντικές χρονοσειρές, όπου η πρόβλεψη ακραίων γεγονότων (π.χ. έντονες βροχοπτώσεις, υψηλές θερμοκρασίες, ισχυροί σεισμοί) έχει πολύ μεγαλύτερη σημασία από την πρόβλεψη των μέσων τιμών. Συνεπώς, απαιτείται η συμπληρωματική χρήση ειδικών τεχνικών ή και μετρικών προσαρμοσμένων στις ουρές της κατανομής, ώστε

να αξιολογείται με μεγαλύτερη ακρίβεια η ικανότητα των μοντέλων να εντοπίζουν και να προβλέπουν ακραίες καταστάσεις.

Κεφάλαιο 6: Συμπεράσματα

Η παρούσα διπλωματική εργασία εστίασε στη συγκριτική αξιολόγηση παραδοσιακών στατιστικών μοντέλων πρόβλεψης χρονοσειρών, απλών μοντέλων βαθιάς μάθησης και σύγχρονων προσεγγίσεων βαθιάς μάθησης, με εφαρμογή σε τρία διαφορετικά περιβαλλοντικά σύνολα δεδομένων: τις μέγιστες μηνιαίες θερμοκρασίες στο Χονγκ Κονγκ, τις μέγιστες μηνιαίες σεισμικές εντάσεις στην Καλιφόρνια και τις μηνιαίες βροχοπτώσεις στο Σίδνεϊ. Ο κύριος στόχος ήταν να εξεταστεί η ικανότητα των μοντέλων να αποτυπώνουν βασικά χαρακτηριστικά των χρονοσειρών (τάση, εποχικότητα, μεταβλητότητα) αλλά και να προβλέπουν ακραία γεγονότα, τα οποία συχνά αποτελούν το πιο κρίσιμο στοιχείο σε περιβαλλοντικές εφαρμογές. Τα αποτελέσματα των πειραμάτων ανέδειξαν μια σειρά από συμπεράσματα, τόσο σε επίπεδο συνολικής απόδοσης όσο και σε επίπεδο καταλληλότητας κάθε κατηγορίας μοντέλων για διαφορετικού τύπου δεδομένα.

Τα μοντέλα ARIMA και SARIMA λειτούργησαν ως ισχυρά baselines, παρέχοντας σχετικά ικανοποιητικά αποτελέσματα στις χρονοσειρές με έντονη περιοδικότητα, όπως οι θερμοκρασίες στο Χονγκ Κονγκ. Σε αυτά τα δεδομένα, οι μετρικές σφάλματος ήταν χαμηλές και η εποχικότητα αποτυπώθηκε με συνέπεια. Ωστόσο, ακόμη και εδώ, παρατηρήθηκε εξομάλυνση των αιχμών και αδυναμία πρόβλεψης των πιο αυξημένων θερμοκρασιών, γεγονός που αναδεικνύει τους περιορισμούς των γραμμικών μοντέλων.

Στις σεισμικές εντάσεις και στη βροχόπτωση, τα γραμμικά μοντέλα εμφάνισαν σαφώς χαμηλότερη απόδοση. Οι προβλέψεις τους περιορίστηκαν σε οριζόντιες καμπύλες γύρω από τον μέσο όρο, αποτυγχάνοντας να συλλάβουν τόσο τις έντονες διακυμάνσεις όσο και τις σπάνιες εξάρσεις. Η έλλειψη ισχυρής εποχικότητας στα σεισμικά δεδομένα και η μεγάλη στοχαστικότητα στις βροχοπτώσεις ανέδειξαν τους περιορισμούς της συγκεκριμένης κατηγορίας μοντέλων, υπογραμμίζοντας την ανάγκη για πιο ευέλικτες και μη γραμμικές προσεγγίσεις. Στα δεδομένα βροχόπτωσης, το μοντέλο ARIMA παρουσίασε περιορισμούς, καθώς οι προβλέψεις του συγκλίνουν γύρω από τον μέσο όρο και δεν ανταποκρίνονται στη μεγάλη μεταβλητότητα της χρονοσειράς. Αντίθετα, το μοντέλο SARIMA, αξιοποιώντας την ενσωμάτωση εποχικών παραμέτρων, κατόρθωσε να αποδώσει σε ικανοποιητικό βαθμό τα περιοδικά μοτίβα και τις επαναλαμβανόμενες αυξομειώσεις. Ωστόσο, παρά τη βελτιωμένη προσαρμογή του σε σχέση με το ARIMA, παρέμεινε αδύναμο στο να αναπαράγει τις έντονες ακραίες αιχμές, οι οποίες αποτελούν κρίσιμο χαρακτηριστικό της χρονοσειράς βροχόπτωσης.

Τα μοντέλα βαθιάς μάθησης (CNN, GRU) έδειξαν αισθητά καλύτερη ικανότητα προσαρμογής στις μη γραμμικές δυναμικές. Στα δεδομένα θερμοκρασίας, τόσο το CNN όσο

και το GRU κατόρθωσαν να αποδώσουν την εποχικότητα και το εύρος τιμών με σχετικά υψηλή ακρίβεια, με το CNN να αποδίδει ελαφρώς καλύτερα στις μέγιστες και ελάχιστες τιμές, ενώ το GRU να εμφανίζει πιο σταθερή αλλά συντηρητική συμπεριφορά, υποεκτιμώντας σε κάποιες περιπτώσεις τόσο τις μέγιστες τιμές αλλά κυρίως τις ελάχιστες. Στα δεδομένα σεισμικής έντασης και βροχόπτωσης, και τα δύο μοντέλα απέτυχαν να προβλέψουν με ακρίβεια τις πολύ σπάνιες και υψηλές ή χαμηλές αιχμές, αν και υπερείχαν σαφώς έναντι των γραμμικών μεθόδων καθώς παρουσίασαν μεγαλύτερο εύρος διακυμάνσεων και πιο ρεαλιστική κατανομή τιμών. Το CNN έδειξε πιο αυξημένη ευαισθησία σε τοπικές μεταβολές καταφέροντας να αποτυπώσει καλύτερη την διακυμανση των τιμών ιδιαίτερα στα δεδομένα βροχοπτώσεων αποτυπώνοντας καλύτερα τις εναλλαγές μεταξύ ξηρών και υγρών περιόδων. Ενώ το GRU παρουσίασε αρκετά πιο εξομαλυσμένες προβλέψεις αποτυπώνοντας μεν την μέση τάση έχοντας όμως σημαντική απόκλιση από τις πραγματικές τιμές.

Η αξιολόγηση των ειδικευμένων μοντέλων DAN, Reweight-EVT και Reweight-META έδειξε ότι όλα αποδίδουν σχετικά ικανοποιητικά τη γενική δομή των χρονοσειρών, με διαφορετικές όμως συμπεριφορές ως προς το εύρος και την πρόβλεψη ακραίων τιμών. Το DAN παρήγαγε πιο ομαλές και σταθερές προβλέψεις, αλλά συχνά υποεκτίμησε τις κορυφές και υπερεκτίμησε ορισμένα ελάχιστα. Το Reweight-EVT, αξιοποιώντας τη Θεωρία Ακραίων Τιμών, διατήρησε μεγαλύτερο εύρος και απέδωσε καλύτερα μέτριες και υψηλές εξάρσεις, αν και παρουσίασε μικρή τάση υπερεκτίμησης. Το Reweight-META, μέσω meta-learning, έδειξε την πιο ισορροπημένη και προσαρμοστική συμπεριφορά, αποτυπώνοντας σε αρκετές περιπτώσεις με μεγαλύτερη ακρίβεια τις διακυμάνσεις και τις αιχμές, αλλά με ορισμένα τεχνικά προβλήματα όπως υπερευαισθησία και μη ρεαλιστικές τιμές. Συνολικά, το DAN είναι καταλληλότερο για σταθερές προβλέψεις, το Reweight-EVT για πιο έντονες διακυμάνσεις, ενώ το Reweight-META εμφανίζει τις μεγαλύτερες δυνατότητες για μελλοντική βελτίωση. Στα δεδομένα θερμοκρασίας, και τα τρία μοντέλα απέδωσαν σωστά την ετήσια εποχικότητα, χωρίς υστέρηση φάσης με το Reweight-EVT να προσφέρει την πιο σωστή εικόνα προβλέψεων. Στα δεδομένα σεισμικών εντάσεων καμία προσέγγιση δεν απέδωσε ικανοποιητικά τις μεγάλες αιχμές με το Reweight-META να δείχνει ταχύτερη προσαρμογή στις διακυμάνσεις, χωρίς ωστόσο να αποδίδει καλά τις ακραίες τιμές φτάνοντας όμως πιο κοντά σε σχέση με τα υπόλοιπα μοντέλα αφού προβλέπει ακραίες τιμές χωρίς όμως να τις τοποθετεί σωστά χρονικά. Στα δεδομένα βροχόπτωσης τα τρία μοντέλα απέδωσαν σωστά το γενικό υπόβαθρο αλλά απέτυχαν στις πολύ στις ακραίες τιμές με το DAN να αποδίδει καλύτερα από όλα τα μοντέλα με μια πολύ καλή απόδοση της εποχικότητας σε συνδυασμό με μια ισορροπία στις τιμές πρόβλεψης.

Η παρούσα εργασία ανέδειξε ότι η πρόβλεψη χρονοσειρών με ακραία γεγονότα παραμένει ένα σύνθετο και απαιτητικό πρόβλημα. Παρά τις βελτιώσεις που προσφέρουν τα νευρωνικά δίκτυα και οι πιο πρόσφατες προσεγγίσεις reweighting, η ακριβής πρόβλεψη ακραίων τιμών

εξακολουθεί να αποτελεί πρόκληση. Παρόλα αυτά, η εφαρμογή μοντέλων βαθιάς μάθησης, και ιδιαίτερα τεχνικών όπως το Reweight-META και του DAN, δείχνει ότι υπάρχει σημαντική πρόοδος και δυνατότητα για πιο αξιόπιστες προβλέψεις στο μέλλον. Η συμβολή της εργασίας είναι ότι προσφέρει μια συγκριτική αποτίμηση πολλών μοντέλων σε διαφορετικά περιβαλλοντικά σύνολα δεδομένων, αναδεικνύοντας τα πλεονεκτήματα και τις αδυναμίες τους και δίνοντας κατευθύνσεις για περαιτέρω έρευνα.

Με βάση τα αποτελέσματα, προκύπτουν ορισμένες κατευθύνσεις για μελλοντική έρευνα. (1) Εμπλουτισμός των δεδομένων με περισσότερες μεταβλητές (πολυμεταβλητή πρόβλεψη), ώστε να ληφθούν υπόψη παράγοντες που επηρεάζουν τις σειρές (π.χ. κλιματικές συνθήκες για βροχοπτώσεις, γεωλογικά δεδομένα για σεισμούς). (2) Συνδυαστικά μοντέλα (hybrid models) που θα αξιοποιούν τη σταθερότητα των γραμμικών μεθόδων με την ευελιξία των νευρωνικών δικτύων. (3) Χρήση εναλλακτικών μετρικών αξιολόγησης που λαμβάνουν υπόψη το σχετικό μέγεθος και τη σπουδαιότητα των ακραίων τιμών, όπως το sMAPE ή εξειδικευμένες μετρικές για extreme events

Αναφορές

Aggarwal, C. C. (2017). Outlier Analysis. doi:10.1007/978-3-319-47578-3

Aggarwal, C. C. (2023). Neural Networks and Deep Learning : A Textbook (Second edition). Springer International Publishing. <https://doi.org/10.1007/978-3-031-29642-0>

Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Asari, V. K. (2019). A State-of-the-Art Survey on Deep Learning Theory and Architectures. Electronics, 8(3), 292. doi:10.3390/electronics8030292

Bauer, André. (2021). Automated Hybrid Time Series Forecasting: Design, Benchmarking, and Use Cases. 10.25972/OPUS-22025.

Bee Dagum, E., Bianconcini, S. (2016). Time Series Components. In: Seasonal Adjustment Methods and Real Time Trend-Cycle Estimation. Statistics for Social and Behavioral Sciences. Springer, Cham. https://doi.org/10.1007/978-3-319-31822-6_2

Bousnguar, H., Battou, A., & Najdi, L. (2023, March). Gated recurrent units (GRU) for time series forecasting in higher education. International Journal of Engineering Research & Technology (IJERT), 12(3). IJERTV12IS030091.

Cho, K., Merrienboer, B., Bahdanau, D., Bengio, Y.. (2014). On the Properties of Neural Machine Translation: Encoder-Decoder Approaches. 10.3115/v1/W14-4012.

Divya D., & Babu, S. S. (2016). Methods to detect different types of outliers. 2016 International Conference on Data Mining and Advanced Computing (SAPIENCE). doi:10.1109/sapience.2016.7684114

Galib, A., McDonald, A., Wilson, T., Luo, L., Tan, P.. (2022). DeepExtrema: A Deep Learning Approach for Forecasting Block Maxima in Time Series Data. 2955-2961. 10.24963/ijcai.2022/410.

Ghojogh, B., & Ghodsi, A. (2023). Recurrent Neural Networks and Long Short-Term Memory Networks: Tutorial and Survey. 10.48550/arXiv.2304.11461.

Gulnara, B., Ahmad, A., Mirzakulova, S., Ибраева, Жанар. (2022). TIME SERIES FORECASTING BY THE ARIMA METHOD. Scientific Journal of Astana IT University. 14-23. 10.37943/HFCH4395.

Han, J., Pei, J. and Kamber, M. (2011) Data Mining: Concepts and Techniques. Elsevier, Amsterdam.

Hochreiter, S., Schmidhuber, J. (1997). Long Short-Term Memory. Neural Computation. 9. 1735-1780. 10.1162/neco.1997.9.8.1735.

Hodson, Timothy. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. Geoscientific Model Development. 15. 5481-5487. 10.5194/gmd-15-5481-2022.

Hyndman, R.J., & Athanasopoulos, G. (2022), Forecasting: principles and practice, 3rd edition (Greek translation), Melbourne, Australia. ISBN: 9789605301835.

Jimoh, K. & Adediwura, A. & Adeyemi, A.. (2022). Model-Data Fit using Akaike Information Criterion (AIC), Bayesian Information Criterion (BIC), and The Sample-Size-Adjusted BIC. Square : Journal of Mathematics and Mathematics Education. 4. 10.21580/square.2022.4.1.11297

Kim, Jongseon, Kim, Hyungjoon, Kim, HyunGi, Lee, Dongjun, Yoon, Sungroh. (2024). A Comprehensive Survey of Time Series Forecasting: Architectural Diversity and Open Challenges. 10.48550/arXiv.2411.05793.

Kong, Y., Wang, Z., Nie, Y., Zhou, T., Zohren, S., Liang, Y., Sun, P., Wen, Q. (2024). Unlocking the Power of LSTM for Long Term Time Series Forecasting. 10.48550/arXiv.2408.10006.

Koprinska, I., Wu, D., Wang, Z., (2018). Convolutional Neural Networks for Energy Time Series Forecasting, International Joint Conference on Neural Networks (IJCNN), Rio de Janeiro, Brazil, 2018, pp. 1-8, doi: 10.1109/IJCNN.2018.8489399.

Kotu, V., & Deshpande, B. (2019). Time Series Forecasting. *Data Science*, 395–445. doi:10.1016/b978-0-12-814761-0.00012-5

Kumari S., & Muthulakshmi, P. (2023). SARIMA Model: An Efficient Machine Learning Technique for Weather Forecasting. *International Conference on Machine Learning and Data Engineering (ICMLDE 20)*. 10.1016/j.procs.2024.04.064

Lazcano de Rojas, A., Jaramillo-Morán, M., Sandubete, J. (2024). Back to Basics: The Power of the Multilayer Perceptron in Financial Time Series Forecasting. *Mathematics*. 12. 1920. 10.3390/math12121920.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. doi:10.1038/nature14539.

Li, Y., Xu, J., Anastasiu, D.. (2024). Learning from Polar Representation: An Extreme-Adaptive Model for Long-Term Time Series Forecasting. *Proceedings of the AAAI Conference on Artificial Intelligence*. 38. 171-179. 10.1609/aaai.v38i1.27768.

Lindemann, B., Müller, T., Vietz, H., Jazdi, N., Weyrich, M. (2021). A survey on long short-term memory networks for time series prediction. *Procedia CIRP*. 99. 650-655. 10.1016/j.procir.2021.03.088.

Mahesh, B. (2020) Machine Learning Algorithms—A Review. *International Journal of Science and Research*, 9, 381-386.

Mehrmolaei, S., & Keyvanpour, M. R., (2016) "Time series forecasting using improved ARIMA," 2016 Artificial Intelligence and Robotics (IRANOPEN), Qazvin, Iran, pp. 92-97, doi: 10.1109/RIOS.2016.7529496.

Nigam, S. (2024). Forecasting Time Series Using Convolutional Neural Network With Multiplicative Neuron. 10.2139/ssrn.4937335.

O'Shea, K., Nash, R. (2015). An Introduction to Convolutional Neural Networks. *ArXiv e-prints*.

Rana, D., Mir, N., Dwivedi, A., Nagpal, R., Mehrotra, D. (2023). Predicting the future trends for circular economy. 10.21203/rs.3.rs-3100112/v1.

Rasmussen, I. S., Mortensen, L. H., Krause, T. G., Nybo, Andersen. A-M. (2018). The association between seasonal influenza-like illness cases and foetal death: a time series analysis. *Epidemiology and Infection* 1–7. <https://doi.org/10.1017/S0950268818003254>

Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3).

Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117. doi:10.1016/j.neunet.2014.09.003.

Seri, E., Petitta, M., Cornaro, C. (2025). Sustainable Greenhouse Management: A Comparative Analysis of Recurrent and Graph Neural Networks. 10.48550/arXiv.2502.17371.

Shi, J., Shirali, A., Narasimhan, G. (2024). ReFine: Boosting Time Series Prediction of Extreme Events by Reweighting and Fine-tuning. 10.48550/arXiv.2409.14232.

Sirisha, U., Belavagi, M., Attigeri, G. (2022). Profit Prediction Using ARIMA, SARIMA and LSTM Models in Time Series Forecasting: A Comparison. *IEEE Access*. PP. 1-1. 10.1109/ACCESS.2022.3224938.

United States Geological Survey (USGS), United States Earthquakes, published annually by: Coast and Geodetic Survey from 1928-68; National Oceanic and Atmospheric Administration (NOAA) from 1969-72; NOAA/U.S. Geological Survey from 1973-80; and U.S. Geological Survey from 1981-1986 (2025). U.S. Earthquake Intensity Database (1638–1985) (NCEI Accession 0303634). NOAA National Centers for Environmental Information. <https://doi.org/10.25921/wa4z-d240>

Velastegui, R., Zhinin-Vera, Lu., Chang, O., Pilliza, G. (2020). Time Series Prediction by Using Convolutional Neural Networks. 10.1007/978-3-030-63128-4_38.

Wen, Xianyun & Li, Weibang. (2023). Time series prediction based on LSTM-attention-LSTM model. IEEE Access. PP. 1-1. 10.1109/ACCESS.2023.3276628.

Wibawa, A., Putra U., Agung B., Elmunsyah, H., Pujiyanto, U., Dwiyanto, F., Hernandez, L. (2022). Time-series analysis with smoothed Convolutional Neural Network. Journal of Big Data. 9. 44. 10.1186/s40537-022-00599-y.

Xin, Y., Kong, L., Liu, Z., Chen, Y., Li, Y., Zhu, H., ... Wang, C. (2018). Machine Learning and Deep Learning Methods for Cybersecurity. IEEE Access, 6, 35365–35381. doi:10.1109/access.2018.2836950.

Zhang, Y., Wu, R., Dascalu, S.M. et al. (2024) A novel extreme adaptive GRU for multivariate time series forecasting. Sci Rep 14, 2991. <https://doi.org/10.1038/s41598-024-53460-y>

Zhang, Z., & Moore, J. C. (2015). Autoregressive Moving Average Models. Mathematical and Physical Fundamentals of Climate Change, 239–290. doi:10.1016/b978-0-12-800066-3.00008-5.

Μπούτσικας, Μ. (2020), Εισαγωγή στην Ανάλυση Χρονοσειρών. Σημειώσεις παραδόσεων του μαθήματος «Ανάλυση Χρονολογικών Σειρών» ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ.