



ΠΑΝΕΠΙΣΤΗΜΙΟ
ΠΑΤΡΩΝ
UNIVERSITY OF PATRAS

Διδακτορική Διατριβή

**Σχεδίαση και Υλοποίηση Προηγμένων
Αλγορίθμων Μηχανικής Μάθησης για την
Ανάλυση και Πρόγνωση Χρονοσειρών**

Λιναρδάτος Παντελής

Επιβλέπων:

Κωτσιαντής Σωτήρης

Αναπληρωτής Καθηγητής

Τμήμα Μαθηματικών

Πάτρα 2024

Περίληψη

Η διατριβή αυτή επικεντρώνεται στην εφαρμογή και ανάπτυξη προηγμένων αλγορίθμων Μηχανικής Μάθησης για την ανάλυση και πρόβλεψη χρονοσειρών, με εφαρμογές σε διάφορους τομείς όπως οι έξυπνες πόλεις, η δημόσια υγεία και η χρηματοοικονομική τεχνολογία. Οι κύριοι στόχοι της διατριβής είναι η εφαρμογή υπαρχόντων τεχνικών Μηχανικής Μάθησης σε νέα σύνολα δεδομένων χρονοσειρών και η ανάπτυξη καινοτόμων αλγορίθμων για την βελτίωση της ανάλυσης και πρόβλεψης αυτών των δεδομένων.

Αρχίζει με μια εμπεριστατωμένη επισκόπηση των τεχνικών Βαθιάς Μηχανικής Μάθησης σε πολυμεταβλητές χρονοσειρές, εξερευνώντας εφαρμογές για έξυπνες πόλεις. Σ' αυτή τη μελέτη, κλείνεται ένα κενό στη βιβλιογραφία παρέχοντας μια σαφή εικόνα των ευκαιριών και των προκλήσεων που συναντώνται στην εφαρμογή αυτών των μεθόδων.

Η ανάλυση και πρόβλεψη της πανδημίας COVID-19 μέσω πολυμεταβλητών χρονοσειρών αποτελεί την επόμενη εστίαση. Μέσα από τη σύγκριση Παραδοσιακών Στατιστικών μεθόδων και προηγμένων μοντέλων Μηχανικής Μάθησης, η διατριβή προσφέρει μια βαθύτερη κατανόηση της δυνατότητας των αλγορίθμων στη διαχείριση των δεδομένων της υγείας.

Στον τομέα της χρηματοοικονομικής τεχνολογίας, η διατριβή εξετάζει την πρόβλεψη της τιμής του Bitcoin με την ενσωμάτωση ανάλυσης συναισθημάτων από tweets, παρουσιάζοντας τις δυνατότητες της Βαθιάς Μηχανικής Μάθησης στην ανάλυση σύνθετων και νέων πηγών δεδομένων.

Η διατριβή εστιάζει επιπλέον στην εφαρμογή της τεχνικής της Αλληλουχίας (Cascade) για την επεξεργασία δεδομένων χρονοσειρών με πολλαπλές μεταβλητές. Αυτή η προσέγγιση αποδεικνύεται ιδιαίτερα αποτελεσματική στη βελτίωση της ακρίβειας των προβλέψεων, συνδυάζοντας διάφορες μεθόδους Μηχανικής Μάθησης για να επιτύχει την καλύτερη δυνατή απόδοση.

Τέλος, η ανάπτυξη ενός Υβριδικού αλγορίθμου που συνδυάζει τη στατι-

στική μέθοδο ARIMA με τον προηγμένο αλγόριθμο Βαθιάς Μηχανικής Μάθησης Temporal Fusion Transformer αποδεικνύει την αξία της καινοτομίας στην ανάλυση περιβαλλοντικών δεδομένων και ενισχύει την εφαρμογή των τεχνικών Μηχανικής Μάθησης.

Η διατριβή αυτή παρουσιάζει μια συνολική προσπάθεια για τη βελτίωση της ικανότητας της Μηχανικής Μάθησης ν' αντιμετωπίζει πολύπλοκες και διαφορετικού τύπου χρονοσειρές, αξιοποιώντας υφιστάμενες τεχνικές και αναπτύσσοντας καινοτόμες λύσεις. Με την ενσωμάτωση προηγμένων μεθόδων ανάλυσης και τη δημιουργία νέων προσεγγίσεων, η εργασία αυτή επιχειρεί να επιφέρει σημαντικές βελτιώσεις στην πρόβλεψη και ερμηνεία των χρονοσειρών, προσφέροντας επιπλέον εφαρμογές στην πραγματική ζωή και βοηθώντας στην αντιμετώπιση πρακτικών προκλήσεων σε πολυάριθμους επιστημονικούς και τεχνολογικούς τομείς.

Abstract

This dissertation focuses on the application and development of advanced Machine Learning algorithms for the analysis and prediction of time series, with applications in various sectors such as smart cities, public health, and financial technology. The main objectives of the dissertation are the application of existing Machine Learning techniques to new time series datasets and the development of innovative algorithms to improve the analysis and prediction of these data.

It begins with a detailed overview of Deep Learning techniques in multivariate time series, exploring applications for smart cities. This study fills a gap in the literature by providing a clear picture of the opportunities and challenges encountered in applying these methods.

The analysis and prediction of the COVID-19 pandemic through multivariate time series is the next focus. Through the comparison of Traditional Statistical methods and advanced Machine Learning models, the dissertation offers a deeper understanding of the capabilities of these algorithms in managing health data.

In the field of financial technology, the dissertation examines Bitcoin price prediction by incorporating sentiment analysis from tweets, showcasing the capabilities of Deep Learning in analyzing complex and new data sources.

Additionally, the dissertation focuses on the application of the Cascade technique for processing multivariate time series data. This approach proves particularly effective in improving prediction accuracy, combining various Machine Learning methods to achieve the best possible performance.

Finally, the development of a Hybrid algorithm that combines the statistical ARIMA method with the advanced Deep Learning algorithm Temporal Fusion Transformer demonstrates the value of innovation in the analysis of environmental data and enhances the applicability of Machine Learning techniques.

This dissertation presents a comprehensive effort to improve the capability of Machine Learning to handle complex and diverse types of time series, leverag-

ing existing techniques and developing innovative solutions. By incorporating advanced analysis methods and creating new approaches, this work attempts to bring significant improvements in the prediction and interpretation of time series, offering additional real-life applications and helping to address practical challenges in numerous scientific and technological fields.

Στους γονείς μου

Περιεχόμενα

1	Εισαγωγή	19
1.1	Η Σημασία και οι Προκλήσεις της Πρόβλεψης Χρονοσειρών στα Διάφορα Διεπιστημονικά Πεδία και στην Καθημερινότητα	19
1.1.1	Τι Είναι οι Χρονοσειρές και η Σημασία τους	19
1.1.2	Χρονοσειρές και Οικονομία	21
1.1.3	Χρονοσειρές και Περιβάλλον	22
1.1.4	Χρονοσειρές και Έξυπνες Πόλεις	23
1.1.5	Χρονοσειρές και Υγεία	24
1.2	Μηχανική Μάθηση για την Πρόβλεψη Χρονοσειρών	26
1.2.1	Η Σημασία της Μηχανικής Μάθησης	26
1.2.2	Υποενότητες της Μηχανικής Μάθησης	27
1.2.3	Παραδοσιακή-Ρηχή και Βαθιά Μηχανική Μάθηση	28
1.2.4	Η Συμβολή της Μηχανικής Μάθησης στην Ανάλυση και Πρόβλεψη Χρονοσειρών	30
1.2.5	Εφαρμογές Μηχανικής Μάθησης σε Χρονοσειρές: Σημα- σία και Πρακτικές Εφαρμογές	31
1.3	Στόχοι και Κύριες Συνεισφορές της Διατριβής	33
1.3.1	Σκοπός και Στόχοι της Διατριβής	33
1.3.2	Μεθοδολογία Έρευνας	34
1.3.3	Κύριες Συνεισφορές και Πορίσματα της Διατριβής	35
1.3.4	Δομή του Κειμένου της Διατριβής	36
2	Επισκόπηση των Κύριων Κατηγοριών Μεθόδων Πρόβλεψης Χρο- νοσειρών	40
2.1	Περιγραφή Στατιστικών Μοντέλων Πρόβλεψης Χρονοσειρών . .	41

2.1.1	ARIMA: Αυτο-παλινδρόμενος Ολοκληρωμένος Κινητός Μέ- σος	41
2.1.2	Holt–Winters Additive Model (HWAAS): Εκθετική Εξομά- λυνση με Προσθετική Τάση και Προσθετική Εποχικότητα	45
2.1.3	TBAT	46
2.1.4	Prophet	47
2.2	Μοντέλα Παραδοσιακής Μηχανικής Μάθησης για Πρόβλεψη Χρο- νοσειρών	49
2.2.1	Παλινδρόμηση Διανύσματος Υποστήριξης	49
2.2.2	Τυχαίο Δάσος	49
2.2.3	Ενίσχυση Κλίσης	50
2.2.4	Δέντρα Ενισχυμένης Κλίσης & XGBoost	51
2.3	Αρχιτεκτονικές Βαθιάς Μηχανικής Μάθησης για την Πρόβλεψη Χρονοσειρών	53
2.3.1	Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNN)	53
2.3.2	Συνελκτικά Νευρωνικά Δίκτυα (CNN)	56
2.3.3	Μηχανισμός Προσοχής (Attention Mechanism)	59
2.3.4	Νευρωνικά Δίκτυα Γραφημάτων	61
2.3.5	Υβριδικές Προσεγγίσεις (Hybrid Approaches)	64
2.3.6	Αρχιτεκτονικές όπου θα Αξιοποιηθούν στην Διατριβή . . .	65
2.3.6.1	Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης (LSTM)	65
2.3.6.2	DeepAR: Πιθανοτική Πρόβλεψη με Επαναλαμ- βανόμενα Δίκτυα Αυτο-παλινδρόμησης	68
2.3.6.3	N-Beats: Ανάλυση Νευρωνικής Βάσης για Ερμη- νεύσιμη Πρόβλεψη Χρονοσειρών	69
2.3.6.4	Μετασχηματιστές Χρονικής Ένωσης (TFT) . . .	69

3 Προκλήσεις και Ευκαιρίες της Εφαρμογής Μεθόδων Βαθιάς Μη-

χανικής Μάθησης σε Δεδομένα Χρονοσειρών Πολλαπλών Μετα-	
βλητών για Έξυπνες Πόλεις	76
3.1 Εφαρμογές στο Πλαίσιο των Έξυπνων Πόλεων	82
3.1.1 Ποιότητα Αέρα	82
3.1.2 Πληρότητας Χώρων Στάθμευσης	91
3.1.3 Διαχείριση Ενεργειακής Ζήτησης	96
3.1.4 Ροή Επιβατών	102
3.1.5 Ροή Κυκλοφορίας	106
3.1.6 Ποιότητα Νερού	114
3.2 Προκλήσεις, Περιορισμοί και Μελλοντικές Κατευθύνσεις	120
3.2.1 Επιλογή Μοντέλου και Υπερπροσαρμογή	120
3.2.2 Ερμηνευσιμότητα	121
3.2.3 Δυνατότητα Μεταφοράς	122
3.2.4 Υπολογιστικοί Πόροι	123
3.2.5 Παρακολούθηση	124
3.2.6 Εναλλακτικές Βαθιάς Μηχανικής Μάθησης	124
3.2.7 Απόρρητο Δεδομένων (<i>Data Privacy</i>)	125
4 Ανάλυση και Σύγκριση Μεθόδων Χρονοσειρών για την Πρόβλεψη	
Ενεργών Κρουσμάτων COVID-19	127
4.1 Δεδομένα COVID-19: Θάνατοι, Κρούσματα, Ανάρρωση	132
4.2 Πειράματα και Αποτελέσματα	136
4.2.1 Διαδικασία Μοντελοποίησης	136
4.2.2 Απόδοση Μοντέλων	137
4.2.3 Σύγκριση Μεταξύ Χωρών	142
5 Αλγόριθμοι Μηχανικής Μάθησης για Πρόβλεψη της Τιμής του Bit-	
coin	144
5.1 Συλλογή Δεδομένων και Προτεινόμενη Μεθοδολογία	151

5.1.1	Συλλογή Δεδομένων και Προεπεξεργασία	151
5.1.1.1	Επεξεργασία Κειμένου	152
5.1.1.2	Συναισθηματική Ανάλυση	152
5.1.1.3	Σύνθεση του Τελικού Συνόλου Δεδομένων . . .	154
5.1.2	Προσεγγίσεις Μοντέλων Πρόβλεψης	156
5.2	Πειράματα, Αποτελέσματα και Σχολιασμός	158
5.2.1	Πειράματα και Αποτελέσματα	158
5.2.2	Σχολιασμός Αποτελεσμάτων	163
6	Εφαρμογή της Μεθόδου της Αλληλουχίας (Cascade) σε Δεδομένα Χρονοσειρών	164
6.0.1	Ψηφοφορία	166
6.0.2	Αλληλουχία	168
6.1	Προτεινόμενη Μεθοδολογία	172
6.1.1	Περιγραφή Δεδομένων και Προεπεξεργασία	173
6.1.1.1	Επισκόπηση Συνόλων Δεδομένων	173
6.1.1.2	Χρονικό Πλαίσιο και Παραγωγή Χαρακτηριστικών	174
6.1.2	Γενίκευση της Αλληλουχίας για την Πρόβλεψη Χρονοσειρών	175
6.1.3	Πειραματική Αξιολόγηση	179
6.2	Αποτελέσματα και Συζήτηση	182
6.2.1	Τεστ Friedman και post hoc ανάλυση	182
6.2.2	Ακατέργαστα Αποτελέσματα	183
6.2.2.1	Η Αλληλουχία υπερτερεί της Ψηφοφορίας . . .	184
6.2.2.2	Η Ψηφοφορία υπερτερεί της Αλληλουχίας . . .	187
6.2.2.3	Η Αλληλουχία και η Ψηφοφορία αποδίδουν εξίσου	189

7 Υβριδικό Μοντέλο ARIMA-TFT για Δεδομένα Διοξειδίου του Άνθρακα (CO₂)	193
7.1 Προτεινόμενη Μεθοδολογία	201
7.1.1 Περιγραφή και Προεπεξεργασία Δεδομένων	201
7.1.2 Προτεινόμενη Υβριδική Προσέγγιση	204
7.1.2.1 Κίνητρο	204
7.1.2.2 Βήμα 1: Πρόβλεψη με τον ARIMA	207
7.1.2.3 Βήμα 2: Πρόβλεψη με τον TFT	208
7.1.2.4 Βήμα 3: Υβριδική Μοντελοποίηση ARIMA-TFT	208
7.1.2.5 Ερμηνευσιμότητα	209
7.1.3 Άλλα Μοντέλα Χρονοσειρών που Χρησιμοποιούνται για Σύγκριση	210
7.1.4 Παρελθοντικές και Μελλοντικές Μεταβλητές	211
7.1.5 Μεθοδολογία Πειραμάτων	212
7.1.5.1 Παράθυρο Αναδρομής (Look-back Window) και Ορίζοντες Πρόβλεψη (Forecasting Horizons)	213
7.1.5.2 Διαχωρισμός Δεδομένων	214
7.1.5.3 Μεθοδολογία Εκπαίδευσης (με Επανεκπαίδευση vs Χωρίς Επανεκπαίδευση)	215
7.1.5.4 Μετρικές Αξιολόγησης	215
7.2 Αποτελέσματα Πειραμάτων	217
7.2.1 Βραχυπρόθεσμος Ορίζοντας Πρόβλεψης	217
7.2.2 Μεσοπρόθεσμος Ορίζοντας Πρόβλεψης	220
7.2.3 Μακροπρόθεσμος Ορίζοντας Πρόβλεψης	225
7.2.4 Friedman τεστ & Holm post-hoc τεστ	228
8 Συμπεράσματα και Μελλοντικές Επεκτάσεις	232

Κατάλογος σχημάτων

1.1	Παραδείγματα Χρονοσειρών με δεδομένα που προσομοιάζουν πραγματικά φαινόμενα. Πάνω αριστερά η πορεία ενός δείκτη μετοχών. Πάνω δεξιά η μηνιαία θερμοκρασία μιας πόλης. Κάτω αριστερά ο ημερήσιος αριθμός αυτοκινήτων σε μια πόλη. Κάτω δεξιά ο καρδιακός παλμός ανά λεπτό.	20
1.2	Κατηγορίες Μηχανικής Μάθησης	30
2.1	Ξεδιπλωμένο Επαναλαμβανόμενο Νευρωνικό Δίκτυο. Η εικόνα προέρχεται από τα Wikimedia Commons, διαθέσιμη κάτω από το CC BY-SA 4.0 license: Βλ. πρωτότυπη εδώ.	54
2.2	Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης (LSTM). Η εικόνα προέρχεται από τα Wikimedia Commons, διαθέσιμη κάτω από το CC BY-SA 4.0 license: Βλ. πρωτότυπη εδώ.	55
2.3	Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου (CNN) για Πρόβλεψη Πολυμεταβλητών Χρονοσειρών. Η εικόνα είναι προσαρμοσμένη από [66], διαθέσιμη κάτω από το CC BY-SA 4.0 license: Βλ. πρωτότυπη εδώ.	58
2.4	Μηχανισμοί Προσοχής:Εσωτερικό γινόμενο (αριστερά) έναντι πολλαπλών κεφαλών (δεξιά). Η εικόνα είναι προσαρμοσμένη από [439].	60
2.5	Συνελίξεις Γραφημάτων που εφαρμόζονται σε διαφορετικούς κόμβους ενός γραφήματος. Κάθε κόμβος συμβολίζεται με έναν αριθμό (0-5).	63
2.6	Μια Απλή Υβριδική Αρχιτεκτονική CNN-LSTM. Η εικόνα είναι προσαρμοσμένη από [142].	65

2.7	Ξεδιπλωμένο Επαναλαμβανόμενο Νευρωνικό Δίκτυο. Η εικόνα προέρχεται από τα Wikimedia Commons, διαθέσιμη κάτω από το CC BY-SA 4.0 license: Βλ. πρωτότυπη εδώ.	66
2.8	Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης (LSTM). Η εικόνα προέρχεται από τα Wikimedia Commons, διαθέσιμη κάτω από το CC BY-SA 4.0 license: Βλ. πρωτότυπη εδώ.	67
2.9	Αρχιτεκτονική του Μοντέλου TFT. Προσαρμογή από [233]	75
4.1	Αριθμός ενεργών κρουσμάτων ανά χώρα με χρήση λογαριθμικής κλίμακας	133
4.2	Κατανομή των συνολικών επιβεβαιωμένων κρουσμάτων COVID-19 ανά χώρα στις 4 Μαΐου 2020	134
4.3	Ποσοστό ενεργών κρουσμάτων σε σχέση με τον συνολικό πληθυσμό ανά χώρα χρησιμοποιώντας γραμμική κλίμακα.	135
4.4	Ποσοστό ενεργών κρουσμάτων σε σχέση με τον συνολικό πληθυσμό ανά χώρα. Για κάθε χώρα η στιγμή μηδέν, είναι το πρώτο επιβεβαιωμένο κρούσμα σε αυτήν τη χώρα.	135
4.5	Προβλέψεις για την Ρωσία.	141
4.6	Προβλέψεις για το Ηνωμένο Βασίλειο.	141
4.7	Προβλέψεις για την Γαλλία.	142
5.1	Δεδομένα για το Bitcoin από το Google Trends	155
5.2	Η πορεία της τιμής του Bitcoin από την 1η Ιανουαρίου 2017 έως την 31η Δεκεμβρίου 2018	155
5.3	Διάγραμμα ροής της διαδικασίας εκπαίδευσης και επικύρωσης των μοντέλων πρόβλεψης της τιμής του Bitcoin.	158
5.4	Αποτελέσματα προβλέψεων μοντέλου LSTM για το Bitcoin. . . .	160
5.5	Αποτελέσματα προβλέψεων μοντέλου Gradient Boosting για το Bitcoin.	161

5.6	Αποτελέσματα προβλέψεων μοντέλου XGBoost για το Bitcoin. . .	162
6.1	Προτεινόμενη Μεθοδολογία.	180
7.1	Κατανομή ακατέργαστων δεδομένων για κάθε μεταβλητή σε περίοδο τριών ημερών (αριστερά). Θηκόγραμμα για κάθε μεταβλητή την ίδια περίοδο 3 μηνών (δεξιά)	203
7.2	Υβριδική Μοντελοποίηση ARIMA-TFT	209
7.3	Προβλέψεις για τον Βραχυπρόθεσμο Ορίζοντα Πρόβλεψης (1 ώρα) έναντι των πραγματικών τιμών για το σετ δεδομένων δοκιμής· διαχωρισμός: 80-20.	218
7.4	Προβλέψεις για τον Βραχυπρόθεσμο Ορίζοντα Πρόβλεψης (1 ώρα) έναντι των πραγματικών τιμών για το σετ δεδομένων δοκιμής· διαχωρισμός: 90-10.	218
7.5	Συνεισφορά των χαρακτηριστικών για Βραχυπρόθεσμο Ορίζοντα Πρόβλεψης (1 ώρα). Διαχωρισμός: 80-20	221
7.6	Μεσοπρόθεσμος Ορίζοντας Πρόβλεψης: παράθυρο ανασκόπησης, πρόβλεψη και αξιολόγηση	222
7.7	Προβλέψεις για τον Μεσοπρόθεσμο Ορίζοντα Πρόβλεψης (24 ώρες) έναντι των πραγματικών τιμών για το σετ δεδομένων δοκιμής· Διαχωρισμός: 80-20.	222
7.8	Προβλέψεις για τον Μεσοπρόθεσμο Ορίζοντα Πρόβλεψης (24 ώρες) έναντι των πραγματικών τιμών για το σετ δεδομένων δοκιμής· Διαχωρισμός: 90-10.	224
7.9	Συνεισφορά των χαρακτηριστικών για Μεσοπρόθεσμο Ορίζοντα Πρόβλεψης (24 ώρες). Διαχωρισμός: 80-20	224
7.10	Προβλέψεις για τον Μακροπρόθεσμο Ορίζοντα Πρόβλεψης (168 ώρες) έναντι των πραγματικών τιμών για το σετ δεδομένων δοκιμής· διαχωρισμός: 80-20.	227

7.11 Συνεισφορά των χαρακτηριστικών για τον Μακροπρόθεσμο Ορί- ζοντα Πρόβλεψης (168 ώρες). Διαχωρισμός: 80-20	228
--	-----

Κεφάλαιο 1

Εισαγωγή

1.1 Η Σημασία και οι Προκλήσεις της Πρόβλεψης Χρονοσειρών στα Διάφορα Διεπιστημονικά Πεδία και στην Καθημερινότητα

Στο παρόν κεφάλαιο θα πραγματοποιηθεί περιληπτικά μια εισαγωγική ανάλυση των χρονοσειρών, η σημασία τους, καθώς και η ευρύτατη ποικιλία εφαρμογών στις οποίες ανταποκρίνονται στα διάφορα διεπιστημονικά πεδία, αλλά και στην καθημερινή ζωή.


1.1.1 Τι Είναι οι Χρονοσειρές και η Σημασία τους

Μια Χρονοσειρά [85] (Time Series) αποτελεί μια ακολουθία δεδομένων τα οποία συλλέγονται ή καταγράφονται σε τακτά χρονικά διαστήματα και περιγράφουν την εξέλιξη ενός μεγέθους στο χρόνο. Αυτού του είδους τα δεδομένα χαρακτηρίζονται από τη χρονολογική τους φύση, η οποία είναι ζωτικό στοιχείο για την ανάλυση και τον εντοπισμό τάσεων, εποχιακών παραλλαγών και προτύπων με την πάροδο του χρόνου.

Αυτός ο τύπος δεδομένων είναι θεμελιώδης για την αποτύπωση της δυναμικής διαφόρων φαινομένων και για αυτό βρίσκεται σε ένα ευρύ φάσμα πεδίων όπως ο Χρηματοοικονομικός Τομέας [132], η Μετεωρολογία [272], η Περιβαλλοντική Επιστήμη [162] και η Υγειονομική Περίθαλψη [191, 308].

Στον Χρηματοοικονομικό Τομέα, μια Χρονοσειρά θα μπορούσε να αντι-

προσωπεύει τις ημερήσιες τιμές κλεισίματος μιας μετοχής σε διάστημα ενός έτους, παρέχοντας στους επενδυτές μια λεπτομερή εικόνα της απόδοσης και της αστάθειας της μετοχής [170]. Στη Μετεωρολογία επίσης μια Χρονοσειρά θα μπορούσε να είναι οι ημερήσιες μέσες θερμοκρασίες μιας πόλης, που χρησιμοποιούνται για τη μελέτη των κλιματικών μεταβολών, την πρόβλεψη καιρικών συνθηκών και την κατανόηση της υπερθέρμανσης του πλανήτη [39]. Αυτά τα παραδείγματα απεικονίζουν τις ποικίλες εφαρμογές των δεδομένων Χρονοσειρών και υπογραμμίζουν τη σημασία τους για την αποτύπωση της χρονικής δυναμικής διαφόρων φαινομένων (Βλ. Εικόνα 1.1).



Σχήμα 1.1: Παραδείγματα Χρονοσειρών με δεδομένα που προσομοιάζουν πραγματικά φαινόμενα. Πάνω αριστερά η πορεία ενός δείκτη μετοχών. Πάνω δεξιά η μηνιαία θερμοκρασία μιας πόλης. Κάτω αριστερά ο ημερήσιος αριθμός αυτοκινήτων σε μια πόλη. Κάτω δεξιά ο καρδιακός παλμός ανά λεπτό.

1.1.2 Χρονοσειρές και Οικονομία

Η ανάλυση Χρονοσειρών αποτελεί ένα ιδιαίτερα χρήσιμο εργαλείο στις οικονομικές μελέτες και στις χρηματοπιστωτικές αγορές, συμπεριλαμβανομένων των αγορών μετοχών [170] και κρυπτονομισμάτων [64]. Αυτή η ανάλυση βοηθά τους οικονομολόγους, τους αναλυτές και τους επενδυτές να λαμβάνουν τεκμηριωμένες αποφάσεις κατανοώντας τις συμπεριφορές του παρελθόντος και προβλέποντας πιθανές μελλοντικές κινήσεις.

Τα δεδομένα Χρονοσειρών χρησιμοποιούνται για την ανάλυση διαφόρων οικονομικών δεικτών, όπως οι ρυθμοί αύξησης του ΑΕΠ (GDP Growth Rates), τα ποσοστά ανεργίας (Unemployment Rates) [190], τα ποσοστά πληθωρισμού (Inflation Rates) και τα επιτόκια (Interest Rates). Για παράδειγμα, εξετάζοντας τα δεδομένα Χρονοσειρών του ΑΕΠ, οι οικονομολόγοι μπορούν να εντοπίσουν περιόδους οικονομικής ανόδου ή ύφεσης. Ομοίως η ανάλυση των ρυθμών πληθωρισμού με την πάροδο του χρόνου βοηθά τις κεντρικές τράπεζες να λαμβάνουν αποφάσεις νομισματικής πολιτικής για τον έλεγχο του πληθωρισμού και τη σταθεροποίηση της οικονομίας.

Στην Χρηματιστηριακή Αγορά, η ανάλυση Χρονοσειρών χρησιμοποιείται για την εξέταση των ιστορικών τιμών των μετοχών (π.χ. ημερήσια τιμή κλεισίματος του Dow Jones Industrial Average) με σκοπό την πρόβλεψη των μελλοντικών κινήσεων των τιμών. Για παράδειγμα, ο Κινητός Μέσος Όρος (1.1):

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (1.1)$$

και ο Εκθετικός Κινητός Μέσος Όρος (1.2):

$$EMA_{today} = (Value_{today} \times (\frac{2}{1+N})) + EMA_{yesterday} \times (1 - (\frac{2}{1+N})) \quad (1.2)$$

είναι τεχνικές που χρησιμοποιούνται για την εξομάλυνση των βραχυπρόθεσμων διακυμάνσεων και την επισήμανση των πιο μακροπρόθεσμων τάσεων στις τιμές των μετοχών. Οι αναλυτές μπορούν να χρησιμοποιήσουν αυτά τα εργαλεία για να εντοπίσουν πιθανά σήματα αγοράς ή πώλησης π.χ. όταν η τιμή μιας μετοχής υπερβαίνει τον κινητό της μέσο όρο, αυτό θα μπορούσε να θεωρηθεί ως ανοδικό σήμα υποδηλώνοντας μια ανοδική τάση.

Στην Αγορά Κρυπτονομισμάτων [64] η ανάλυση Χρονοσειρών είναι εξίσου σημαντική. Δεδομένης της υψηλής μεταβλητότητας και της σχετικά σύντομης ιστορίας των κρυπτονομισμάτων σε σύγκριση με τα παραδοσιακά περιουσιακά στοιχεία, η ανάλυση δεδομένων Χρονοσειρών όπως η τιμή, ο όγκος συναλλαγών και η κεφαλαιοποίηση της αγοράς είναι μείζονος σημασίας για τους επενδυτές. Τεχνικοί Δείκτες όπως ο Δείκτης Σχετικής Ισχύος (RSI) (1.3):

$$RSI = 100 - \frac{100}{1 + RS} \quad (1.3)$$

και η Απόκλιση Κινούμενης Μέσης Σύγκλισης (1.4):

$$MACD = EMA_{fast} - EMA_{slow} \quad (1.4)$$

χρησιμοποιούνται ευρέως για την ανάλυση κρυπτονομισμάτων. Για παράδειγμα, μια τιμή του RSI πάνω από 70 μπορεί να δείχνει ότι ένα κρυπτονόμισμα είναι υπερτιμημένο και θα μπορούσε ενδεχομένως να αντιστρέψει την κατεύθυνσή του και να πέσει η τιμή του, ενώ ένα RSI κάτω από 30 να δηλώνει μια πιθανή ανοδική κίνηση.

1.1.3 Χρονοσειρές και Περιβάλλον

Η ανάλυση Χρονοσειρών παίζει καθοριστικό ρόλο στην κατανόηση του καιρού και την πρόβλεψη περιβαλλοντικών φαινομένων, συμπεριλαμβανομένων των επιπτώσεων της κλιματικής αλλαγής και της ρύπανσης του πλανήτη. Αυτά

τα δεδομένα μπορούν να αντικατοπτρίζουν διάφορους περιβαλλοντικούς παράγοντες όπως θερμοκρασία, βροχόπτωση, επίπεδα ρύπανσης, συγκέντρωσης αερίων και την εξέλιξή τους στον χρόνο. Η ανάλυση αυτή βοηθά τους επιστήμονες, τους ερευνητές και τους πολιτικούς υπεύθυνους στην λήψη αποφάσεων σχετικά με τη διαχείριση περιβαλλοντικών προκλήσεων, τη σχεδίαση και υλοποίηση δράσεων για τη μετρίαση των αρνητικών επιπτώσεων της κλιματικής αλλαγής και την προστασία του φυσικού περιβάλλοντος.

Με την ανάλυση Χρονοσειρών, οι ειδικοί μπορούν να εκτιμήσουν πως η αύξηση της συγκέντρωσης διοξειδίου του άνθρακα στην ατμόσφαιρα επηρεάζει την θερμοκρασία και κατ' επέκταση τα κλιματικά μοτίβα σε παγκόσμιο επίπεδο. [366] Αυτή η γνώση μπορεί να βοηθήσει στην δημιουργία στρατηγικών για τη μείωση των εκπομπών αερίων που συμβάλλουν στο φαινόμενο του θερμοκηπίου και την προσαρμογή στις αλλαγές του κλίματος που δεν μπορούν να αποφευχθούν καθώς επίσης να γίνουν μετρήσεις των ηλιακών κηλίδων.

Επιπλέον, η ανάλυση Χρονοσειρών συμβάλλει στην κατανόηση των επιπτώσεων των ακραίων καιρικών φαινομένων, πλημμύρες, καταιγίδες, ξηρασίες, τα ύψη των παλιρροιών των ωκεανών [265], καθώς και στην εκτίμηση της συχνότητας και της έντασής τους στο μέλλον. Αυτό είναι καίριας σημασίας για την ετοιμότητα και την ανταπόκριση σε φυσικές καταστροφές με στόχο την προστασία της ανθρώπινης ζωής, τη μείωση των οικονομικών και κοινωνικών επιπτώσεων, καθώς και για την προστασία του φυσικού περιβάλλοντος και ιδίως του δασικού πλούτου, συμπεριλαμβανομένης και της πολιτιστικής κληρονομιάς μέσα σε αυτόν.

1.1.4 Χρονοσειρές και Έξυπνες Πόλεις

Οι Έξυπνες Πόλεις είναι προηγμένα αστικά συστήματα που χρησιμοποιούν τεχνολογίες όπως το Διαδίκτυο των Πραγμάτων (Internet of Things, IoT), την Τεχνητή Νοημοσύνη (AI) και τη Ανάλυση Μεγάλων Δεδομένων (Big Data Analysis)

για να βελτιώσουν τη ζωή των πολιτών, να αυξήσουν την αποδοτικότητα των αστικών λειτουργιών, των υπηρεσιών και να ενισχύσουν την αειφορία. [77] Η ενσωμάτωση συσκευών IoT, όπως συνδεδεμένοι αισθητήρες, έξυπνα φώτα, μετρητές και άλλα, επιτρέπει τη συλλογή μαζικών ποσοτήτων δεδομένων από το αστικό περιβάλλον. Αυτά τα δεδομένα, που συχνά παρουσιάζονται σε μορφή Χρονοσειρών, αναλύονται για να παρέχουν την εικόνα της τρέχουσας κατάστασης, να προβλέπουν μελλοντικές τάσεις και να προτείνουν δράσεις ανταπόκρισης.

Η ανάλυση δεδομένων Χρονοσειρών είναι κρίσιμης σημασίας στο πλαίσιο των έξυπνων πόλεων για την κατανόηση και τη διαχείριση της αστικής δυναμικής. Χρησιμοποιείται για την παρακολούθηση της ποιότητας του αέρα, της κίνησης, της κατανάλωσης ενέργειας, των προτύπων χρήσης νερού και πολλών άλλων παραμέτρων. Με την εφαρμογή αλγορίθμων Μηχανικής Μάθησης και Τεχνητής Νοημοσύνης στα δεδομένα αυτά, οι έξυπνες πόλεις μπορούν να προβλέψουν μελλοντικά γεγονότα ή καταστάσεις, όπως τα πιθανά μποτιλιαρίσματα στο δρόμο [42], τις αλλαγές στην ποιότητα του αέρα, ή τις αυξήσεις στη ζήτηση ενέργειας. Αυτό επιτρέπει στις πόλεις να λαμβάνουν προληπτικά μέτρα, όπως τη ρύθμιση των φωτεινών σηματοδοτών για τη βελτίωση της κυκλοφορίας ή την εφαρμογή περιορισμών στη χρήση νερού κατά τη διάρκεια περιόδων ξηρασίας.

1.1.5 Χρονοσειρές και Υγεία

Η ανάλυση Χρονοσειρών αποτελεί μέγιστης σημασίας στον τομέα της υγείας, προσφέροντας πολύτιμες πληροφορίες για την παρακολούθηση, την κατανόηση, την πρόβλεψη και την πρόληψη διαφόρων υγειονομικών συνθηκών και επιδημιών. Μέσω της συλλογής και της ανάλυσης δεδομένων που καταγράφονται σε συνεχείς χρονικές περιόδους, οι ειδικοί στον τομέα της υγείας μπορούν να ανακαλύψουν μοτίβα, τάσεις και συσχετίσεις, βελτιώνοντας την ποιότητα της φροντίδας και την αποτελεσματικότητα των θεραπειών. [191, 308]

Στην Ιατρική, η ανάλυση χρονοσειρών αποτελεί ουσιαστικό βήμα στην παρακολούθηση και διαχείριση χρόνιων νοσημάτων, προσφέροντας σημαντικές δυνατότητες στην πρόληψη και τον έλεγχο τους. Γιατροί και ειδικοί υγείας συλλέγουν τακτικά δεδομένα σχετικά με τη συγκέντρωση γλυκόζης στο αίμα των διαβητικών ασθενών ή τις αρτηριακές πιέσεις των ασθενών με υπέρταση [324, 45]. Αυτή η συνεχής παρακολούθηση βοηθά στην ανίχνευση τυχόν αποκλίσεων και επιτρέπει την έγκαιρη προσαρμογή των θεραπειών για την αποφυγή πιθανών επιπλοκών.

Αξιοποιείται σημαντικά στην ανάλυση δεδομένων από ηλεκτροεγκεφαλογράφημα, προσφέροντας ένα πολύτιμο εργαλείο στη διάγνωση νευρολογικών διαταραχών. Μέσω της συνεχούς καταγραφής της ηλεκτρικής δραστηριότητας του εγκεφάλου, είναι δυνατή η ανίχνευση ανωμαλιών που σχετίζονται με επιληπτικές κρίσεις, η παρακολούθηση της προόδου νευρολογικών παθήσεων και η εκτίμηση της παρουσίας ογκωδών σχηματισμών στον εγκέφαλο. Αυτή η μέθοδος είναι ιδιαίτερα σημαντική για την ακριβή διάγνωση και την αποτελεσματική θεραπευτική παρέμβαση, καθώς επιτρέπει τη λεπτομερή ανάλυση της εγκεφαλικής λειτουργίας σε πραγματικό χρόνο.

Άλλο σημαντικό παράδειγμα είναι η χρήση της ανάλυσης Χρονοσειρών στην επιδημιολογική έρευνα. Οι επιδημιολόγοι αναλύουν δεδομένα χρονοσειρών για την παρακολούθηση και την πρόβλεψη της διάδοσης λοιμωδών νοσημάτων, όπως η γρίπη ή ο COVID-19 [210]. Η ανάλυση λοιπόν επιτρέπει την εκτίμηση της εποχικότητας των νόσων, την αναγνώριση των παραγόντων κινδύνου και την ανάπτυξη στρατηγικών πρόληψης και ελέγχου.

Τέλος, η ανάλυση χρονοσειρών βρίσκει εφαρμογή και στην παρακολούθηση υπνικών διαταραχών. Μέσω της καταγραφής δεδομένων από παρακολούθηση ύπνου, οι ειδικοί μπορούν να αναλύσουν τα πρότυπα ύπνου, να ανιχνεύσουν διαταραχές όπως η άπνοια και να προσαρμόσουν τις θεραπείες ανάλογα.

1.2 Μηχανική Μάθηση για την Πρόβλεψη Χρονοσειρών

Στην ενότητα αυτή, θα αποτυπωθούν κάποιες βασικές έννοιες της Μηχανικής Μάθησης (Machine Learning) καθώς και η συμβολή της στον τομέα της ανάλυσης και πρόβλεψης δεδομένων χρονοσειρών.

1.2.1 Η Σημασία της Μηχανικής Μάθησης

Η Μηχανική Μάθηση αποτελεί ένα υποπεδίο της επιστήμης των υπολογιστών η οποία ασχολείται με τη μελέτη και την κατασκευή αλγορίθμων ικανών να μαθαίνουν, να κάνουν προβλέψεις και να λαμβάνουν αποφάσεις με βάση δεδομένα [249].

Οι αλγόριθμοι Μηχανικής Μάθησης έχουν επιφέρει σημαντικές καινοτομίες σε διάφορους τομείς, ενισχύοντας την αποδοτικότητα και προσφέροντας προηγμένες λύσεις ζωτικής σημασίας σε τομείς της καθημερινότητας.

Κάποιες από τις πιο εμβληματικές υπολογιστικές εφαρμογές αφορούν την αναγνώριση προτύπων (pattern recognition) σε πινακοποιημένα δεδομένα, την αναγνώριση ομιλίας [90], την επεξεργασία φυσικής γλώσσας [219] καθώς και την υπολογιστική όραση (computer vision) σε δεδομένα εικόνας ή βίντεο [194].

Συγκεκριμένα στον τομέα της υγείας [343], χρησιμοποιούνται στην ανάπτυξη διαγνωστικών εργαλείων με μεγαλύτερη ακρίβεια και αποτελεσματικότητα καθώς και στην προσαρμογή θεραπειών στις ανάγκες του κάθε ασθενούς. Στα πλαίσια του χρηματοοικονομικού τομέα [94], οι αλγόριθμοι Μηχανικής Μάθησης, εξοπλίζουν τους επαγγελματίες με εργαλεία για πιο αποτελεσματική διαχείριση ρίσκου και επενδύσεων. Τέλος όσον αφορά την προστασία του φυσικού περιβάλλοντος [364], οι αλγόριθμοι Μηχανικής Μάθησης συμβάλλουν στην κατανόηση και πρόβλεψη περιβαλλοντικών αλλαγών, καθώς και φυσικών κατα-

στροφών βοηθώντας στην ανάπτυξη βιώσιμων λύσεων, για την αποφυγή ή την έγκαιρη αντιμετώπισή τους.

1.2.2 Υποενότητες της Μηχανικής Μάθησης

Τα Συστήματα Μηχανικής Μάθησης μπορούν να χωριστούν σε τρεις κύριες κατηγορίες: Εποπτευόμενη Μάθηση, μη Εποπτευόμενη Μάθηση και Ενισχυτική Μάθηση, ανάλογα με τον τρόπο που τα συστήματα αυτά αποκτούν τη γνώση τους.

► **Εποπτευόμενη Μάθηση (Supervised Learning):** Η Εποπτευόμενη Μάθηση [179] είναι μια προσέγγιση στην Τεχνητή Νοημοσύνη, όπου το μοντέλο εκπαιδεύεται σε ένα σύνολο δεδομένων που περιλαμβάνει τα δεδομένα εισόδου (input data) και τις αντίστοιχες στοχευμένες εξόδους (output data). Αυτό επιτρέπει στον αλγόριθμο να αναπτύξει μια συνάρτηση που συσχετίζει τα δεδομένα εισόδου με τις επιθυμητές εξόδους, προβλέποντας την έξοδο για νέα δεδομένα. Η εποπτευόμενη μάθηση χρησιμοποιείται σε ποικίλες εφαρμογές όπως η αναγνώριση μοτίβων, η διάγνωση από ιατρικές εικόνες και η πρόβλεψη οικονομικών δεικτών. Οι δυο κύριες κατηγορίες της εποπτευόμενης μάθησης είναι:

- **Ταξινόμηση (Classification):** Η Ταξινόμηση [427] αναφέρεται στην κατάταξη των δεδομένων εισόδου (input data) σε ειδικές κατηγορίες ή κλάσεις. Παραδείγματα περιλαμβάνουν την κατηγοριοποίηση των email σε «επιθυμητά» ή «ανεπιθύμητα» και την κατηγοριοποίηση εικόνων σε «γάτα» ή «σκύλος».
- **Παλινδρόμηση (Regression):** Η Παλινδρόμηση προορίζεται για την πρόβλεψη ενός συνεχούς αριθμητικού τιμήματος από τα δεδομένα εισόδου (input data). Αυτό μπορεί να σημαίνει την πρόβλεψη της αξίας ενός ακινήτου ή την εκτίμηση της ζήτησης ενός προϊόντος.

- **Μη Εποπτευόμενη Μάθηση (Unsupervised Learning):** Αυτή η κατηγορία δεν χρησιμοποιεί επισημασμένα σύνολα δεδομένων [116]. Το μοντέλο αναλύει ακατέργαστα δεδομένα χωρίς στοχευμένες εξόδους (output data) για να ανακαλύψει δομές ή μοτίβα, εφαρμόζοντας αλγορίθμους όπως η συσταδοποίηση (clustering) και η μείωση διαστάσεων (PCA), με εφαρμογές στην ανάλυση κοινωνικών δικτύων και την οργάνωση δεδομένων.
- **Ενισχυτική Μάθηση (Reinforcement Learning):** Στην Ενισχυτική Μάθηση [26], ένας πράκτορας (agent) μαθαίνει να λαμβάνει αποφάσεις μέσω μιας διαδικασίας πολλαπλών δοκιμών και αξιολόγησης των λαθών (trial and error), βασιζόμενος σε ανταμοιβές ή τιμωρίες, με σκοπό την επίτευξη ενός στόχου. Αυτή η μορφή μάθησης εφαρμόζεται σε τομείς όπως η ρομποτική, τα παιχνίδια και η αυτόνομη οδήγηση.

Καθεμιά από αυτές τις προσεγγίσεις έχει τις δικές της προκλήσεις και απαιτεί διαφορετικές μεθοδολογίες και τεχνικές. Η επιλογή της κατάλληλης κατηγορίας εξαρτάται από τη φύση του προβλήματος, τη διαθεσιμότητα, την ποιότητα των δεδομένων, καθώς και από τους στόχους της εφαρμογής.

1.2.3 Παραδοσιακή-Ρηχή και Βαθιά Μηχανική Μάθηση

Μια πρόσθετη διακριτική κατηγορία που μπορεί να θεωρηθεί στο πεδίο της Μηχανικής Μάθησης είναι ο διαχωρισμός ανάμεσα στις Παραδοσιακές ή Ρηχές Μεθόδους και τη Βαθιά Μηχανική Μάθηση.

Μια επιπλέον κατηγοριοποίηση που μπορεί να γίνει στον τομέα της Μηχανικής Μάθησης αποτελεί αυτή του διαχωρισμού των Παραδοσιακών ή Ρηχών, όπως αλλιώς θα μπορούσαν να χαρακτηριστούν, αλγορίθμων Μηχανικής Μάθησης με τους αλγορίθμους Βαθιάς Μηχανικής Μάθησης [174], όπου στην πλειοψηφία τους απαρτίζονται από Νευρωνικά Δίκτυα.

Με την ραγδαία εξέλιξη της υπολογιστικής ισχύος και των καρτών γραφι-


κών (GPU), μια συγκεκριμένη μερίδα αλγορίθμων Μηχανικής Μάθησης που μπορούν να εκμεταλλευτούν αυτή την ισχύ, απέκτησαν πολύ μεγάλη δημοτικότητα την τελευταία δεκαετία. Ο λόγος είναι επειδή οι αλγόριθμοι αυτοί, κατάφεραν να φέρουν επαναστατικά αποτελέσματα σε εφαρμογές ζωτικής σημασίας, όπως η Υπολογιστική Όραση (Computer Vision) [194], η Μηχανική Μετάφραση [80] και η δημιουργία Τεχνητής Νοημοσύνης (Generative AI) [59].

Η Βαθιά Μηχανική Μάθηση, όπως είναι προφανές, αποτελεί ένα υποσύνολο της Μηχανικής Μάθησης και επίσης ως κατηγορία δεν αποτελεί κάποια διαφορετική υποδιαίρεση σε σχέση με τις προαναφερθείσες. Δηλαδή ένας αλγόριθμος Βαθιάς Μηχανικής Μάθησης μπορεί να είναι ταυτόχρονα ένας αλγόριθμος Ταξινόμησης, Επιβλεπόμενης μάθησης (Βλ. Εικόνα 1.2). Για παράδειγμα, ένα Νευρωνικό Δίκτυο που χρησιμοποιείται για την αναγνώριση εικόνων σε εφαρμογές υπολογιστικής όρασης μπορεί να κατατάσσεται τόσο στην κατηγορία της Βαθιάς Μηχανικής Μάθησης όσο και στην κατηγορία της Επιβλεπόμενης Μάθησης.

Παραδείγματα εφαρμογών της Βαθιάς Μηχανικής Μάθησης αποτελούν η αυτόνομη οδήγηση [359], όπου τα Νευρωνικά Δίκτυα ταξινομούν, συγκεντρώνουν και επεξεργάζονται μεγάλο όγκο δεδομένων, από αισθητήρες και κάμερες για να πάρουν αποφάσεις στη στιγμή. Η αναγνώριση ομιλίας, όπου Μοντέλα Βαθιάς Μηχανικής Μάθησης μετατρέπουν το ηχητικό κύμα σε κείμενο, και η αυτόματη μετάφραση, η οποία επιτρέπει την άμεση μετάφραση του λόγου ή του κειμένου από τη μία γλώσσα σε άλλη με υψηλή ακρίβεια, καθιστώντας τα χρήσιμα σε κλάδους όπως οι virtual assistants. Σημαντικές εφαρμογές βρίσκουμε επίσης στην υγεία, όπως η διάγνωση ασθενειών μέσω ανάλυσης ιατρικών εικόνων, όπου αλγόριθμοι Βαθιάς Μηχανικής Μάθησης αναγνωρίζουν μοτίβα που δεν είναι εμφανή στο ανθρώπινο μάτι.

Συνοψίζοντας, οι αλγόριθμοι Βαθιάς Μηχανικής Μάθησης είναι αλγόριθμοι που εκμεταλλεύονται την μεγάλη υπολογιστική ισχύ των σύγχρονων υπο-

λογιστών και προσφέρουν αποτελέσματα αιχμής (state of the art) σε πληθώρα τομέων της πραγματικής ζωής.



Σχήμα 1.2: Κατηγορίες Μηχανικής Μάθησης

1.2.4 Η Συμβολή της Μηχανικής Μάθησης στην Ανάλυση και Πρόβλεψη Χρονοσειρών

Ο τομέας της ανάλυσης και πρόβλεψης των χρονοσειρών είναι ένας κλάδος ο οποίος, όπως αναφέρθηκε στην προηγούμενη ενότητα, εμφανίζει ένα πολύ μεγάλο επιστημονικό ενδιαφέρον σε πολλούς τομείς. Ωστόσο, μέχρι πρόσφατα, οι περισσότερες τεχνικές που αξιοποιούνταν σ' αυτόν τον τομέα ήταν οι Παραδοσιακές Στατιστικές μέθοδοι.

Πρόσφατα, η μεγάλη άνθηση του τομέα της Μηχανικής Μάθησης και ειδικότερα της Βαθιάς Μηχανικής Μάθησης έχει οδηγήσει τους ερευνητές στην εφαρμογή της και στον τομέα των χρονοσειρών [371, 235]. Τα αποτελέσματα φαί-

νονται να είναι ιδιαίτερα ενθαρρυντικά και σε πολλές περιπτώσεις ξεπερνούν τις επιδόσεις των Παραδοσιακών Στατιστικών Μεθόδων.

Πλέον, αρχίζουν να δημιουργούνται αλγόριθμοι Μηχανικής Μάθησης, σχεδιασμένοι εξ' ολοκλήρου από την αρχή, με σκοπό την εφαρμογή τους σε προβλήματα χρονοσειρών [257]. Επιπρόσθετα, παλαιότεροι αλγόριθμοι εφαρμόζονται αυτούσιοι ή με παραλλαγές σε μεγάλη ποικιλία από δεδομένα χρονοσειρών και παρέχουν σημαντικές δυνατότητες για την ανάλυση και την πρόβλεψη χρονοσειρών σε διάφορους τομείς.

1.2.5 Εφαρμογές Μηχανικής Μάθησης σε Χρονοσειρές: Σημασία και Πρακτικές Εφαρμογές

Η ενσωμάτωση τεχνικών Μηχανικής Μάθησης στην ανάλυση χρονοσειρών έχει ανοίξει νέους δρόμους για την κατανόηση και την πρόβλεψη τους, όπου εξελίσσονται διαρκώς με τον χρόνο. Η αποτελεσματικότητα αυτών των μεθόδων έχει επαληθευτεί σε πληθώρα πρακτικών εφαρμογών, από την οικονομική ανάλυση μέχρι την πρόγνωση καιρού και την ανίχνευση ασθενειών. Μερικά παραδείγματα είναι τα εξής:

- ▶ **Οικονομική Πρόγνωση:** Χρησιμοποιώντας χρονοσειρές μετοχών ή άλλων χρηματοοικονομικών δεικτών [305], οι αλγόριθμοι Μηχανικής Μάθησης μπορούν να προβλέψουν μελλοντικές τιμές και τάσεις, βοηθώντας τους επενδυτές να λαμβάνουν πιο ενημερωμένες αποφάσεις.
- ▶ **Πρόγνωση Καιρού:** Μοντέλα Μηχανικής Μάθησης αξιοποιούνται για την πρόβλεψη μετεωρολογικών φαινομένων, αναλύοντας τεράστιες ποσότητες δεδομένων από δορυφορικές εικόνες, ανιχνευτές και μετεωρολογικούς σταθμούς [159, 151].
- ▶ **Βιοϊατρική Έρευνα και Υγειονομική Παρακολούθηση:** Στον τομέα της υγείας, οι χρονοσειρές από ιατρικές μετρήσεις (π.χ., καρδιογραφήματα)

μπορούν να αναλυθούν για την πρόγνωση ιατρικών εξελίξεων ή την έγκαιρη ανίχνευση παθήσεων σε πρώιμο στάδιο και συστάσεις θεραπείας [4, 360].

- **Ενεργειακή Διαχείριση:** Προβλέψεις ζήτησης και προσφοράς ενέργειας με βάση την ανάλυση χρονοσειρών μπορούν να βελτιστοποιήσουν την παραγωγή και διανομή της, μειώνοντας το κόστος και τις εκπομπές CO₂ [75, 87].
- **Εμπορική Ανάλυση:** Ανάλυση τάσεων αγορών, πρόβλεψη ζήτησης προϊόντων και βελτιστοποίηση των αποθεμάτων είναι μερικές από τις εφαρμογές στον τομέα του εμπορίου, βοηθώντας τις επιχειρήσεις να ανταποκρίνονται καλύτερα στις συμπεριφορές των αγοραστών [269, 238].

1.3 Στόχοι και Κύριες Συνεισφορές της Διατριβής

Στην ενότητα αυτή, θα παρουσιαστούν οι στόχοι, τα ερευνητικά ερωτήματα, η μεθοδολογία, οι κύριες συνεισφορές και τα κύρια πορίσματα της διδακτορικής διατριβής.

1.3.1 Σκοπός και Στόχοι της Διατριβής

Όπως προαναφέρθηκε, η εφαρμογή αλγορίθμων Μηχανικής Μάθησης σε δεδομένα χρονοσειρών αποτελεί ένα πεδίο με εκτεταμένες προκλήσεις και ευκαιρίες για έρευνα. Παρά την υπάρχουσα πρόοδο, πολλές πτυχές παραμένουν αχαρτογράφητες καθώς μέχρι πρόσφατα, η πλειοψηφία των εφαρμοσμένων τεχνικών στα δεδομένα χρονοσειρών βασίζονταν σε παραδοσιακές στατιστικές μεθόδους. Αυτό έχει δημιουργήσει μια επιτακτική ανάγκη για περαιτέρω έρευνα και ανάπτυξη στον τομέα. Για το λόγο αυτό η παρούσα διατριβή εστιάζει σε δύο βασικούς στόχους:

1. **Εφαρμογή Αλγορίθμων Μηχανικής Μάθησης σε Πρωτότυπα Δεδομένα Χρονοσειρών:** Ο πρώτος στόχος της διατριβής αποτελεί την αξιοποίηση ήδη υπαρχόντων τεχνικών Μηχανικής Μάθησης σε νέα σύνολα δεδομένων, τα οποία αντιπροσωπεύουν διαφορετικά ερευνητικά ενδιαφέροντα. Δεδομένα από τον τομέα της υγείας, περιβαλλοντικά δεδομένα, οικονομικά καθώς και δεδομένα για έξυπνες πόλεις είναι μερικά από αυτά. Φυσικά, αυτή η διαδικασία περιλαμβάνει την προσαρμογή των αλγορίθμων για να ανταποκριθούν στις ιδιαίτερες προκλήσεις που παρουσιάζουν τα καινοτόμα αυτά δεδομένα χρονοσειρών.
2. **Ανάπτυξη Καινοτόμων Αλγορίθμων Μηχανικής Μάθησης για Εφαρμογή σε Δεδομένα Χρονοσειρών:** Ο δεύτερος στόχος αφορά την ανάπτυξη νέων, υπερσύγχρονων αλγορίθμων που θα είναι ικανοί να αναλύουν

και να εξάγουν σημαντικές πληροφορίες από δεδομένα χρονοσειρών με μεγαλύτερη ακρίβεια και αποτελεσματικότητα. Στόχος είναι η επίτευξη καλύτερων αποδόσεων από τις ήδη υπάρχουσες τεχνικές Μηχανικής Μάθησης και η προσφορά προηγμένων λύσεων σε σύνθετα προβλήματα ανάλυσης δεδομένων χρονοσειρών, αυξάνοντας έτσι την εφαρμογή της Μηχανικής Μάθησης σε διάφορους τομείς.

Μέσα από αυτούς τους δύο στόχους, η διατριβή επιδιώκει να συμβάλει σημαντικά στην εξέλιξη του τομέα της μηχανικής μάθησης, ειδικά σε ό,τι αφορά την επεξεργασία και ανάλυση δεδομένων χρονοσειρών. Η διατριβή αποσκοπεί στην κατανόηση και την αντιμετώπιση των προκλήσεων που παρουσιάζουν αυτά τα είδη δεδομένων, αξιοποιώντας υφιστάμενες μεθόδους και αναπτύσσοντας νέες προσεγγίσεις.

1.3.2 Μεθοδολογία Έρευνας

Η εν λόγω διατριβή ακολουθεί μια συστηματική και ολοκληρωμένη μεθοδολογία έρευνας για την εξέταση και ανάλυση της εφαρμογής αλγορίθμων Μηχανικής Μάθησης σε δεδομένα χρονοσειρών, καθώς και για την ανάπτυξη καινοτόμων τεχνικών στον ίδιο τομέα. Η προσέγγιση που ακολουθείται είναι πολυδιάστατη και καλύπτει τα εξής βασικά στάδια:

- **Βιβλιογραφική Έρευνα:** Εκτεταμένη ανάλυση και επισκόπηση της υφιστάμενης βιβλιογραφίας για να κατανοηθούν οι τρέχουσες μέθοδοι και προκλήσεις.
- **Εντοπισμός Τομέων Δράσης:** Επιλογή των συγκεκριμένων τομέων (π.χ. υγεία, περιβάλλον, οικονομία, έξυπνες πόλεις) για την εφαρμογή των πειραμάτων.
- **Επιλογή και Συλλογή Δεδομένων:** Διαδικασία συλλογής και προετοιμασίας των δεδομένων χρονοσειρών για κάθε επιλεγμένο τομέα.

- ▶ **Προσαρμογή και Εφαρμογή Ύπαρχουσών Τεχνικών:** Προσαρμογή και εφαρμογή υφιστάμενων αλγορίθμων Μηχανικής Μάθησης στα επιλεγμένα δεδομένα.
- ▶ **Ανάπτυξη Καινοτόμων Αλγορίθμων:** Δημιουργία και εφαρμογή νέων αλγορίθμων προσαρμοσμένων στις ανάγκες των ειδικών δεδομένων χρονοσειρών.
- ▶ **Αξιολόγηση Πειραμάτων:** Σύγκριση και ανάλυση των αποτελεσμάτων για να εκτιμηθεί η αποτελεσματικότητα των προτεινόμενων μεθόδων.

1.3.3 Κύριες Συνεισφορές και Πορίσματα της Διατριβής

Προκειμένου να επιτευχθεί ο σκοπός και οι ερευνητικοί στόχοι της παρούσας διδακτορικής διατριβής, πραγματοποιήθηκαν πέντε σημαντικές δημοσιεύσεις που συμβάλλουν στην προάσπιση και επέκταση της γνώσης στον τομέα της Μηχανικής Μάθησης εφαρμοσμένης σε δεδομένα χρονοσειρών.

1. Η πρώτη δημοσίευση προσφέρει μια εκτενή επισκόπηση των τεχνικών Βαθιάς Μηχανικής Μάθησης εφαρμοσμένων σε δεδομένα χρονοσειρών πολλαπλών μεταβλητών, με ειδική έμφαση σε εφαρμογές για έξυπνες πόλεις, κλείνοντας ένα κενό στην υφιστάμενη βιβλιογραφία.
2. Η δεύτερη δημοσίευση αφορά την εφαρμογή Στατιστικών Μεθόδων, προηγμένων μοντέλων Μηχανικής Μάθησης, καθώς και Βαθιάς Μηχανικής Μάθησης, σε δεδομένα σχετικά με την πανδημία του COVID-19. Ένα σύνολο δεδομένων εξαιρετικά καινοφανές καθώς τη στιγμή που έγιναν οι πειραματισμοί, ο ιός είχε εμφανιστεί μόλις λίγες εβδομάδες.
3. Η τρίτη δημοσίευση εξετάζει την εφαρμογή Μοντέλων Βαθιάς Μηχανικής Μάθησης στα δεδομένα της τιμής του Bitcoin, ενσωματώνοντας ανάλυση

συναισθημάτων (sentiment analysis) από tweets για την πρόβλεψη της τιμής του, εκμεταλλευόμενοι μια σχετικά νέα πηγή δεδομένων, καθώς το Bitcoin είναι μια τεχνολογία που υπάρχει μόλις τα τελευταία 15 χρόνια.

4. Η τέταρτη δημοσίευση αναλύει τη χρήση της τεχνικής συνδυασμού μεθόδων Μηχανικής Μάθησης, της αλληλουχίας (cascade), για την επεξεργασία δεδομένων χρονοσειρών πολλαπλών μεταβλητών. Αυτή η τεχνική θα εφαρμοστεί σε πολλά είδη δεδομένων και θα συγκριθεί με την ψηφοφορία ως μια καλύτερη τεχνική συνδυασμού μεθόδων Μηχανικής Μάθησης.
5. Η πέμπτη και τελευταία δημοσίευση εισάγει έναν καινοτόμο υβριδικό αλγόριθμο που συνδυάζει την Παραδοσιακή Στατιστική μέθοδο ARIMA με έναν προηγμένο αλγόριθμο Βαθιάς Μηχανικής Μάθησης, τον Temporal Fusion Transformer, με σκοπό την εφαρμογή του σε πρωτότυπα περιβαλλοντικά δεδομένα σχετικά με την περιεκτικότητα του διοξειδίου του άνθρακα στην ατμόσφαιρα (CO₂).

1.3.4 Δομή του Κειμένου της Διατριβής

Παρακάτω συνοψίζεται η δομή της διδακτορικής διατριβής, που θα παρουσιαστεί στα επόμενα κεφάλαια:

Κεφάλαιο 1, Εισαγωγή: Το κεφάλαιο αυτό παρείχε μια εισαγωγή στον τομέα των χρονοσειρών και της Μηχανικής Μάθησης, τόνισε την αξία τους στον επιστημονικό κόσμο και σε διάφορους τομείς της καθημερινότητας και περιέγραψε τον στόχο και τη συνεισφορά της διατριβής.

Κεφάλαιο 2, Επισκόπηση των Κύριων Κατηγοριών Μεθόδων Πρόβλεψης Χρονοσειρών: Στο Κεφάλαιο δύο της διατριβής γίνεται επισκόπηση των κύριων κατηγοριών μεθόδων πρόβλεψης χρονοσειρών. Αρχικά, παρουσιάζονται οι Παραδοσιακές Στατιστικές Μέθοδοι, οι οποίες έχουν κερδίσει με-

γάλη δημοτικότητα για την αποδοτικότητά τους στην ανάλυση και πρόβλεψη χρονοσειρών. Εν συνεχεία αναλύονται οι μέθοδοι της Παραδοσιακής Μηχανικής Μάθησης, οι οποίες επιτρέπουν την αναγνώριση περίπλοκων μοτίβων μέσω της εκπαίδευσης σε μεγάλα σύνολα δεδομένων, βελτιώνοντας την ακρίβεια των προβλέψεων. Τέλος εξετάζονται οι μέθοδοι Βαθιάς Μηχανικής Μάθησης, οι οποίες έχουν αποδειχθεί ιδιαίτερα υποσχόμενες για την πρόβλεψη χρονοσειρών, χάρη στην ικανότητά τους να αναλύουν πολύπλοκες δομές δεδομένων με υψηλή ακρίβεια.

Κεφάλαιο 3, Προκλήσεις και Ευκαιρίες της Εφαρμογής Μεθόδων Βαθιάς Μηχανικής Μάθησης σε Δεδομένα Χρονοσειρών Πολλαπλών Μεταβλητών για Έξυπνες Πόλεις: Στο τρίτο κεφάλαιο πραγματοποιείται μια εκτενής ανάλυση της βιβλιογραφίας που αφορά την εφαρμογή μοντέλων Βαθιάς Μηχανικής Μάθησης σε δεδομένα χρονοσειρών για έξυπνες πόλεις. Επιπλέον, παρέχεται μια ταξινόμηση της εν λόγω βιβλιογραφίας σε υποκατηγορίες σχετικά με έξυπνες πόλεις, προσφέροντας μια σαφή επισκόπηση των προκλήσεων και των ευκαιριών που συνεπάγεται η εφαρμογή αυτών των μεθόδων.

Κεφάλαιο 4, Ανάλυση και Σύγκριση Μεθόδων Χρονοσειρών για την Πρόβλεψη Ενεργών Κρουσμάτων COVID-19: Το τέταρτο κεφάλαιο περιέχει λεπτομερή ανάλυση και σύγκριση διαφόρων στατιστικών μεθόδων, προηγμένων μοντέλων Μηχανικής Μάθησης και τεχνικών Βαθιάς Μηχανικής Μάθησης που εφαρμόστηκαν σε δεδομένα σχετικά με την πανδημία του COVID-19, με σκοπό την πρόβλεψη του αριθμού των ενεργών κρουσμάτων. Το περιεχόμενο του κεφαλαίου επικεντρώνεται στην παρουσίαση της μεθοδολογίας, στην επεξεργασία και ανάλυση του εξαιρετικά καινοφανούς συνόλου δεδομένων και στην αξιολόγηση της αποτελεσματικότητας κάθε προσέγγισης. Επιπροσθέτως, προσδιορίζονται οι προκλήσεις που παρου-

σιάστηκαν κατά τη διάρκεια των πειραματισμών λόγω της νεότητας του ιού και της δυναμικής φύσης της πανδημίας.

Κεφάλαιο 5, Αλγόριθμοι Μηχανικής Μάθησης για Πρόβλεψη της Τιμής

του Bitcoin: Στο κεφάλαιο αυτό διεξάγεται ανάλυση των πειραμάτων που πραγματοποιήθηκαν στο πλαίσιο της διατριβής, σχετικά με την εφαρμογή αλγορίθμων Μηχανικής Μάθησης για την πρόβλεψη της τιμής του Bitcoin. Επικεντρώνεται στην παρουσίαση της μεθοδολογίας, των δεδομένων που χρησιμοποιήθηκαν, των τεχνικών προσαρμογής μοντέλων και της αξιολόγησης των αποτελεσμάτων, προσφέροντας συνεκτικές εικασίες σχετικά με την αποδοτικότητα διαφόρων αλγορίθμων στο συγκεκριμένο πεδίο.

Κεφάλαιο 6, Εφαρμογή της Μεθόδου της Αλληλουχίας (Cascade) σε Δεδο-

μένα Χρονοσειρών: Στο έκτο κεφάλαιο, παρουσιάζεται η εφαρμογή της τεχνικής της αλληλουχίας σε ποικίλα είδη δεδομένων καθώς και η αξιολόγησή της, σε σχέση με άλλες τεχνικές συνδυασμού μεθόδων Μηχανικής Μάθησης. Αναλύονται οι μεθοδολογίες που ακολουθήθηκαν, οι προκλήσεις που αντιμετωπίστηκαν κατά την εφαρμογή, και τα αποτελέσματα που επιτεύχθηκαν, καταλήγοντας στο συμπέρασμα ότι η μέθοδος της αλληλουχίας αποτελεί μια υποσχόμενη προσέγγιση για τη βελτίωση της ακρίβειας προβλέψεων σε δεδομένα χρονοσειρών.

Κεφάλαιο 7, Υβριδικό μοντέλο ARIMA-TFT για Δεδομένα Διοξειδίου Διο-

ξειδίου του άνθρακα (CO₂): Στο κεφάλαιο επτά, αναλύεται η διαδικασία σχεδίασης και υλοποίησης του υβριδικού μοντέλου, περιγράφεται η επιλογή και επεξεργασία των δεδομένων, και παρουσιάζονται τα αποτελέσματα των πειραματικών εφαρμογών. Η αξιολόγηση της αποδοτικότητας του μοντέλου σε σχέση με τις προβλέψεις της περιεκτικότητας CO₂ δίνει σημαντικές ενδείξεις για την υπεροχή της υβριδικής προσέγγισης σε σύγκριση με παραδοσιακές τεχνικές, προσφέροντας πολύτιμες προοπτικές

για την περαιτέρω έρευνα στον τομέα της πρόβλεψης περιβαλλοντικών δεδομένων.

Κεφάλαιο 8, Συμπεράσματα και Συζήτηση: Το τελευταίο κεφάλαιο της διδακτορικής διατριβής περιλαμβάνει τα κύρια ευρήματα της έρευνας, συζητούνται οι συνέπειές τους και προτείνονται κατευθύνσεις για μελλοντική έρευνα.

Κεφάλαιο 2

Επισκόπηση των Κύριων Κατηγοριών Μεθόδων Πρόβλεψης Χρονοσειρών

Το κεφάλαιο αυτό έχει ως σκοπό να ορίσει το πλαίσιο εντός του οποίου θα εξεταστούν οι μέθοδοι πρόβλεψης χρονοσειρών. Δίνεται έμφαση στην κατηγοριοποίηση των διαφόρων προσεγγίσεων από παραδοσιακές στατιστικές μεθόδους μέχρι πιο πρόσφατες τεχνολογίες, βασισμένες στη Παραδοσιακή καθώς και Βαθιά Μηχανική Μάθηση. Είναι απαραίτητο για τον αναγνώστη να κατανοεί τις βασικές αρχές και τις διακριτές χαρακτηριστικές ιδιότητες κάθε μεθόδου, ώστε να αποκτήσει μια ολοκληρωμένη άποψη για τις επόμενες ενότητες, οι οποίες παρουσιάζουν τα πειράματα και τα ευρήματα της διατριβής.

Το εν λόγω κεφάλαιο χωρίζεται σε τρεις υποενότητες, καθεμία από τις οποίες είναι αφιερωμένη σε μια διαφορετική κατηγορία μεθόδων πρόβλεψης χρονοσειρών. Η υποενότητα 2.1 επικεντρώνεται στις κλασικές στατιστικές μεθόδους, οι οποίες έχουν παίξει έναν θεμελιώδη ρόλο στο πεδίο της πρόβλεψης χρονοσειρών. Η υποενότητα 2.2 αναλύει τις Παραδοσιακές μεθόδους Μηχανικής Μάθησης, οι οποίες έχουν προσαρμοστεί για την αντιμετώπιση των προκλήσεων που προκύπτουν στην ανάλυση χρονοσειρών. Τέλος η υποενότητα 2.3 εστιάζει στις μεθόδους Βαθιάς Μηχανικής Μάθησης, οι οποίες έχουν κερδίσει εκτεταμένη δημοτικότητα τα τελευταία έτη και εμφανίζονται να προσφέρουν τις πιο υποσχόμενες προοπτικές.

2.1 Περιγραφή Στατιστικών Μοντέλων Πρόβλεψης Χρονοσειρών

Στην παρούσα ενότητα, παρουσιάζονται και αναλύονται τέσσερις στατιστικές μέθοδοι πρόβλεψης χρονοσειρών όπου χρησιμοποιήθηκαν στα πλαίσια της διδακτορικής διατριβής και αποτελούν κάποιες από τις πιο δημοφιλείς επιλογές στον χώρο: ARIMA [56], το Προσθετικό Μοντέλο Holt-Winters (HWAAS) [67], TBATS [86] και ο Prophet του Facebook [368].

2.1.1 ARIMA: Αυτο-παλινδρόμενος Ολοκληρωμένος Κινητός Μέσος

Στην υποενότητα αυτή, εξετάζεται μία από τις πλέον διαδεδομένες οικογένειες μοντέλων για την ανάλυση χρονοσειρών: τα μοντέλα ARIMA, δηλαδή τα μοντέλα Αυτο-παλινδρόμενου Ολοκληρωμένου Κινητού Μέσου. Αναπτύχθηκαν αρχικά για τομείς με οικονομικό ενδιαφέρον [56] [418], ενώ οι στατιστικές τους ιδιότητες, η εφαρμογή της καθιερωμένης μεθοδολογίας Box-Jenkins κατά το στάδιο εκπαίδευσης των μοντέλων [273], και η δυνατότητά τους να υιοθετούν ποικίλες μορφές εκθετικής εξομάλυνσης έχουν συμβάλλει στην ευρεία δημοτικότητα και υιοθέτησή τους σε ποικίλους τομείς [418, 259].

Η βασική προϋπόθεση πίσω από τη χρήση των μοντέλων ARIMA είναι ότι οι μελλοντικές τιμές της χρονοσειράς μπορούν να προβλεφθούν μέσω μιας γραμμικής συνάρτησης που συνδέει προηγούμενες παρατηρήσεις με τα σφάλματα. Το μοντέλο ARIMA συνθέτεται από τρεις κύριους συντελεστές: Αυτοπαλινδρόμηση («AR»), Ολοκλήρωση («I»), και Κινητός Μέσος («MA»), με κάθε συνιστώσα να παρέχει μια ξεχωριστή διάσταση ανάλυσης και μοντελοποίησης των δεδομένων.

Το συστατικό «AR», το οποίο σημαίνει «AutoRegressive», αναφέρεται στη μοντελοποίηση της μεταβλητής ως γραμμικού συνδυασμού των προηγόμε-

νων τιμών της. Σ' ένα χρονικό σημείο t , η τιμή της μεταβλητής στόχου y_t μπορεί να εκφραστεί μέσω της εξίσωσης 2.1:

$$y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \dots + \beta_p y_{t-p} + \epsilon_t \quad (2.1)$$

όπου $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ αντιπροσωπεύουν τις προηγούμενες τιμές της μεταβλητής στα χρονικά διαστήματα $t-1, t-2, \dots, t-p$ αντίστοιχα, $\beta_0, \beta_1, \dots, \beta_p$ είναι οι παράμετροι της παλινδρόμησης, και ϵ_t είναι λευκός θόρυβος στο χρονικό σημείο t . Η παράμετρος p καθορίζει τον μέγιστο αριθμό των χρονικών καθυστερήσεων (lags) και αναφέρεται ως η τάξη του μοντέλου. Για παράδειγμα, ένα μοντέλο AR(p) υποδηλώνει ένα Αυτο-παλινδρόμενο μοντέλο τάξης p .

Το συστατικό «I», το οποίο σημαίνει «Integrated», αναφέρεται στη διαδικασία διαφοροποίησης των δεδομένων της χρονοσειράς. Η διαφοροποίηση είναι ένας μετασχηματισμός που εφαρμόζεται σ' ένα σύνολο δεδομένων χρονοσειράς για να το καταστήσει στάσιμο (stationary), δηλαδή να εξαλείψει τις τάσεις και την εποχικότητα που περιέχει. Πραγματοποιείται αφαιρώντας την προηγούμενη τιμή από την τρέχουσα τιμή σε κάθε παρατήρηση και μπορεί να επαναληφθεί πολλές φορές δηλαδή, εφαρμόζοντας διαφοροποίηση στις ήδη διαφοροποιημένες τιμές μέχρι να εξαλειφθούν όλες οι χρονικές εξαρτήσεις. Ο όρος «βαθμός διαφοροποίησης» αναφέρεται στον αριθμό των φορών που έχει πραγματοποιηθεί η διαφοροποίηση. Ο λόγος για την εφαρμογή της διαφοροποίησης είναι ότι οι διαφοροποιημένες τιμές είναι πιο σταθερές σε σύγκριση με τις αρχικές, μη διαφοροποιημένες τιμές. Αυτό σημαίνει ότι οι στατιστικές ιδιότητες του μοντέλου που δημιουργείται, δεν εξαρτώνται από την περίοδο στην οποία λαμβάνεται το δείγμα. Κατά συνέπεια, τα μοντέλα που κατασκευάζονται με βάση στάσιμα δεδομένα είναι πιο αξιόπιστα. Έχοντας πραγματοποιήσει μία διαφοροποίηση πρώτης τάξης, η εξίσωση 2.1 μπορεί να αναδιατυπωθεί στην εξίσωση 2.2:

$$\begin{aligned}
y_t - y_{t-1} &= \beta_0 \\
&+ \beta_1(y_{t-1} - y_{t-2}) \\
&+ \beta_2(y_{t-2} - y_{t-3}) \\
&+ \dots \\
&+ \beta_p(y_{t-p} - y_{t-p-1}) \\
&+ \epsilon_t
\end{aligned} \tag{2.2}$$

Ο βαθμός της διαφοροποίησης προσδιορίζεται από την παράμετρο «d».

Το τμήμα «ΜΑ», που σημαίνει «Κινούμενος Μέσος Όρος» (Moving Average), αναφέρεται σε ένα μοντέλο όπου η μεταβλητή-στόχος εξαρτάται από τα προηγούμενα σφάλματα πρόβλεψης. Αυτό συνεπάγεται ότι το μοντέλο προβλέπει την μεταβλητή-στόχο ως έναν γραμμικό συνδυασμό των σφαλμάτων των προηγούμενων προβλέψεων που έκανε στα προηγούμενα χρονικά βήματα όπου ονομάζονται υπολείμματα. Σύμφωνα μ' ένα μοντέλο Κινουμένου Μέσου Όρου, στη χρονική στιγμή t , η τιμή της μεταβλητής στόχου y_t μπορεί να περιγραφεί μαθηματικά με την εξίσωση 2.3:

$$y_t = \mu + \epsilon_t + \theta_1\epsilon_{t-1} + \theta_2\epsilon_{t-2} + \dots + \theta_q\epsilon_{t-q} \tag{2.3}$$

όπου μ είναι η μέσος όρος της χρονοσειράς, ϵ_t είναι το σφάλμα (ή το υπόλειμμα) της πρόβλεψης στη χρονική στιγμή t , και $\theta_1, \theta_2, \dots, \theta_q$ είναι οι παράμετροι του μοντέλου που αντιστοιχούν στα βάρη των σφαλμάτων πρόβλεψης για τις προηγούμενες q περιόδους. Η παράμετρος q αντιπροσωπεύει την τάξη του ΜΑ μοντέλου και δείχνει τον αριθμό των προηγούμενων σφαλμάτων που λαμβάνονται υπόψιν στην πρόβλεψη.

Ένα μοντέλο ARIMA(p, d, q) χρησιμοποιεί έναν συνδυασμό των μοντέλων «AR» (AutoRegressive) και «MA» (Moving Average), των οποίων οι τάξεις ελέγχο-

νται από τις παραμέτρους p και q αντίστοιχα. Αυτό το συνδιαστικό μοντέλο μαζί με την διαφοροποίηση («I»), η τάξη της οποίας καθορίζεται από την παράμετρο d , επιτρέπει την δημιουργία ενός ισχυρού εργαλείου για ανάλυση χρονοσειρών.

Συνοπτικά, τα μοντέλα ARIMA βασίζονται στην υπόθεση μιας γραμμικής εξάρτησης μεταξύ των διαδοχικών τιμών μιας χρονοσειράς και αξιοποιούν τη γραμμική εξάρτηση αυτή, των παρατηρήσεων για την ανίχνευση τοπικών μοτίβων, προσπαθώντας ταυτόχρονα να εξαλείψουν τον θόρυβο που παρεμβάλλεται στα δεδομένα [3]. Αυτή η προσέγγιση προσφέρει δύο σημαντικά πλεονεκτήματα:

- ▶ Εξασφαλίζει ένα υψηλό επίπεδο ερμηνευσιμότητας επειδή βασιζόμενοι στις υποθέσεις του μοντέλου, η σχέση μεταξύ των ανεξάρτητων και εξαρτημένων μεταβλητών γίνεται εύκολα κατανοητή και επομένως εξηγείται με απλότητα. Τούτο επιτρέπει στους ερευνητές να αποκτήσουν βαθιά κατανόηση τόσο της σχέσης της τρέχουσας τιμής με τις προηγούμενες (ενδογενείς μεταβλητές), όσο και τυχόν επιδράσεων από εξωτερικούς παράγοντες (εξωγενείς μεταβλητές).
- ▶ Η διαδικασία επιλογής του καταλληλότερου μοντέλου ARIMA μπορεί να γίνει με αυτοματοποιημένο τρόπο, βελτιστοποιώντας έτσι την ακρίβεια των προβλέψεων [188].

Ένα επιπλέον πλεονέκτημα των μοντέλων ARIMA είναι η ικανότητά τους να προσαρμόζονται με χρονοσειρές που εξελίσσονται ραγδαία στον χρόνο καθώς ενημερώνονται εύκολα με τα πιο πρόσφατα δεδομένα για την πρόβλεψη της μελλοντικής συμπεριφοράς της χρονοσειράς [188].

Παρ'όλα αυτά, επειδή τα μοντέλα ARIMA δεν είναι ικανά να διαχειριστούν μη γραμμικά μοτίβα ή σχέσεις, η εφαρμογή τους σε σύνθετα προβλήματα και δυναμικές του πραγματικού κόσμου ενδέχεται να μην είναι πάντοτε αποτελεσματική [425].

2.1.2 Holt–Winters Additive Model (HWAAS): Εκθετική Εξομάλυνση με Προσθετική Τάση και Προσθετική Εποχικότητα

Το Προσθετικό Μοντέλο Holt-Winters αποτελεί επέκταση της μεθόδου Εκθετικής Εξομάλυνσης του Holt για την πρόβλεψη μονομεταβλητών χρονοσειρών. Η κύρια καινοτομία του είναι η ενσωμάτωση του παράγοντα εποχικότητας στις προβλέψεις, επιτρέποντας τη μοντελοποίηση δεδομένων με εμφανείς εποχικές διακυμάνσεις. Αν και απλό στην εφαρμογή, αποδεικνύεται ένα ισχυρό εργαλείο πρόβλεψης και αποτελεί δημοφιλή εναλλακτική στα μοντέλα ARIMA της οικογένειας Box-Jenkins. Ωστόσο, μελέτες υποδεικνύουν ότι αυτή η μέθοδος μπορεί να μην επιτυγχάνει την ίδια ακρίβεια πρόβλεψης με την πιο σύνθετη διαδικασία Box-Jenkins [67].

Η Εκθετική Εξομάλυνση αντιπροσωπεύει τη διαδικασία της διαρκούς αναβάθμισης μιας πρόβλεψης, λαμβάνοντας υπόψη τις τελευταίες παρατηρήσεις. Συγκεκριμένα, επιδιώκει την εκθετική μείωση της επιρροής των παλαιότερων παρατηρήσεων στην τελική πρόβλεψη, μειώνοντας τα βάρη τους. Αυτό σημαίνει, πως κατά την πρόβλεψη ενός νέου σημείου της χρονοσειράς, οι πιο πρόσφατες παρατηρήσεις θεωρούνται πιο σημαντικές σε σχέση με τις παλιότερες [187]. Το Προσθετικό Μοντέλο Holt-Winters αποδεικνύεται ιδανικό για δεδομένα που παρουσιάζουν τάσεις και εποχικότητα, οι οποίες δεν διαφοροποιούνται με τον χρόνο, προσφέροντας προβλέψεις που αποτυπώνουν τις εποχιακές διακυμάνσεις των δεδομένων. Ωστόσο, η εφαρμογή της μεθόδου φέρει πρακτικά ζητήματα, όπως η επιλογή των αρχικών τιμών, η αντιμετώπιση της ευαισθησίας του μοντέλου σε ασυνήθιστα γεγονότα ή ακραίες τιμές, καθώς και την διαμόρφωση των παραμέτρων εξομάλυνσης και την κανονικοποίηση των εποχιακών δεικτών [68] [128].

2.1.3 TBAT

Το Ακρωνύμιο TBAT αναφέρεται σε μια μέθοδο πρόβλεψης που βασίζεται σε τέσσερα κύρια συστατικά:

1. **Τριγωνομετρική εποχιακή διατύπωση (T):** Χρησιμοποιεί τριγωνομετρικές συναρτήσεις για να περιγράψει τις εποχιακές διακυμάνσεις στα δεδομένα, καταλληλότερες για περίπλοκα μοτίβα εποχικότητας.
2. **Μετασχηματισμός Box-Cox (B):** Μετατρέπει τα δεδομένα για να ακολουθούν πιο στενά την κανονική κατανομή, βελτιώνοντας την δυνατότητα ανάλυσης και πρόβλεψης.
3. **Σφάλματα ARMA (A):** Μοντελοποιεί τα δεδομένα βάσει των προηγούμενων τιμών και σφαλμάτων, προσφέροντας μια δυναμική κατανόηση της συμπεριφοράς των δεδομένων.
4. **Στοιχείο Τάσης (T):** Ενσωματώνει μια μακροπρόθεσμη κατεύθυνση ή τάση στα δεδομένα, π.χ. μια σταθερή αύξηση ή μείωση με το πέρασμα του χρόνου.

Όπως έχει αποδειχθεί από τρεις εμπειρικές μελέτες [86], η μέθοδος αυτή μπορεί να εφαρμοστεί επιτυχώς σε ποικίλα προβλήματα ανάλυσης χρονοσειρών.

Πέραν της υπολογιστικής αποδοτικότητας που προσφέρει για τους εκτιμητές μέγιστης πιθανότητας, η τριγωνομετρική διατύπωση του μοντέλου TBAT διευκολύνει την αποσύνθεση περίπλοκων εποχιακών χρονοσειρών. Αυτό το χαρακτηριστικό έχει αποδειχθεί ωφέλιμο για τον εντοπισμό και την εξαγωγή εποχιακών στοιχείων που διαφορετικά θα ήταν δυσδιάκριτα σε μια απλή γραφική απεικόνιση των χρονοσειρών [86].

Επιπλέον, το πλαίσιο μοντελοποίησης TBAT προσφέρει σημαντικά πλεονεκτήματα, όπως έναν εκτεταμένο χώρο παραμέτρων που ενισχύει τη δυνατότητα για πιο ακριβείς προβλέψεις [168], την ικανότητα διαχείρισης μη γραμμικών

χαρακτηριστικών, την ανάλυση αυτοσυσχέτισης καθώς και μια απλοποιημένη αλλά αποδοτική διαδικασία εκτίμησης [86].

2.1.4 Prophet

Ο Prophet, είναι ένα μοντέλο που αναπτύχθηκε από το Facebook, με στόχο την αντιμετώπιση επιχειρηματικών προκλήσεων στην πρόβλεψη χρονοσειρών. Ενώ οι μέθοδοι πρόβλεψης είναι πολυάριθμοι, πολλά επιχειρηματικά προβλήματα διακρίνονται από ορισμένα κοινά χαρακτηριστικά όπως τα εποχιακά μοτίβα [368].

Ο Prophet, βασίζεται σε ένα μοντέλο που μπορεί εύκολα να αποσυνθεθεί [148], συνδυάζοντας τρία βασικά στοιχεία: την τάση, την εποχικότητα και τις αργίες. Καρδιά του συστήματος, είναι ένα παλινδρομικό μοντέλο με ερμηνεύσιμες παραμέτρους, το οποίο συχνά παρέχει ικανοποιητικές προβλέψεις με τις προεπιλεγμένες τιμές του, ενώ προσφέρει ταυτόχρονα τη δυνατότητα στους χρήστες να κάνουν διαισθητικές επιλογές για τα στοιχεία που είναι σχετικά με το πρόβλημα πρόβλεψής τους και να προβούν εύκολα στις αναγκαίες προσαρμογές [368].

Για την πρόβλεψη της τάσης, ο προφήτης χρησιμοποιεί δύο μοντέλα: ένα μοντέλο κορεσμού ανάπτυξης και ένα γραμμικό μοντέλο κατά κομμάτια. Το μοντέλο κορεσμού ανάπτυξης, βασίζεται σε μοντέλα παρόμοια με αυτά που περιγράφουν την αύξηση του πληθυσμού σε φυσικά οικοσυστήματα [166], όπου η ανάπτυξη είναι μη γραμμική και φτάνει σ' ένα σημείο κορεσμού. Σε περιπτώσεις όπου το σημείο κορεσμού δεν είναι εφικτό, το γραμμικό μοντέλο κατά κομμάτια προσφέρει μια αποτελεσματική εναλλακτική για σταθερούς ρυθμούς ανάπτυξης. Για την καταγραφή της εποχικότητας, ο Prophet, εφαρμόζει τη σειρά Fourier ως ένα ευέλικτο μοντέλο για την περιοδικότητα των δεδομένων [149]. Επιπλέον, για να συμπεριλάβει τις αργίες, απαιτείται η χρήση μιας προκαθορισμένης λίστας γνωστών παρελθοντικών και προβλεπόμενων συμβάντων. Οι επιδράσεις των αργιών υποτίθεται ότι είναι ανεξάρτητες, κάνοντας την ενσωμάτωσή τους στο μο-

ντέλο μια σχετικά απλή διαδικασία [368].

2.2 Μοντέλα Παραδοσιακής Μηχανικής Μάθησης για Πρόβλεψη Χρονοσειρών

2.2.1 Παλινδρόμηση Διανύσματος Υποστήριξης

Ο Αλγόριθμος Παλινδρόμηση Διανύσματος Υποστήριξης, (Support Vector Regressor - SVR) [97] αναπτύσσεται βάσει των Μηχανών Διανυσμάτων Υποστήριξης (Support Vector Machines - SVM). Σε αντίθεση από τις παραδοσιακές μεθόδους παλινδρόμησης, ο SVR επιδιώκει τον εντοπισμό ενός υπερεπιπέδου, που αποτυπώνει με την μεγαλύτερη δυνατή ακρίβεια την σχέση μεταξύ των χαρακτηριστικών εισαγωγής και των τιμών εξαγωγής, ενώ παράλληλα λαμβάνει υπόψιν ένα επιτρεπόμενο περιθώριο ανοχής. Ο στόχος του SVR είναι η ελαχιστοποίηση των σφαλμάτων εντός αυτού του περιθωρίου, καθιστώντας τον εξαιρετικά αποτελεσματικό στην καταγραφή περίπλοκων σχέσεων σε χώρους υψηλών διαστάσεων. Το SVR, ξεχωρίζει σε περιπτώσεις με μη γραμμικά μοτίβα ή σε σενάρια με ακραίες τιμές. Η διαχείριση της μη γραμμικότητας επιτυγχάνεται μέσω της εφαρμογής συναρτήσεων πυρήνα, δίνοντας τη δυνατότητα στο SVR να αποτυπώσει τα δεδομένα εισόδου σε χώρους υψηλότερων διαστάσεων. Ωστόσο, η ακριβής ρύθμιση των παραμέτρων, ιδιαίτερα για την επιλογή των παραμέτρων του πυρήνα και την κανονικοποίηση, είναι ουσιώδης για την επίτευξη της βέλτιστης απόδοσης. Συνοπτικά, το SVR παρουσιάζεται ως ένα ισχυρό εργαλείο για εργασίες παλινδρόμησης, παρέχοντας ευελιξία και στιβαρότητα στην καταγραφή περίπλοκων μοτίβων στα δεδομένα.

2.2.2 Τυχαιο Δάσος

Το Τυχαιο Δάσος, (Random Forest - RF) [58] αντιπροσωπεύει μια από τις πλέον ισχυρές συνδυαστικές μεθόδους εκμάθησης, δημιουργώντας πολυάριθμα δέντρα απόφασης κατά την περίοδο εκπαίδευσης και προβαίνοντας στην εξα-

γωγή ως αποτέλεσμα της πιο συχνής κλάσης για ταξινόμηση ή την μέση πρόβλεψη για παλινδρόμηση. Ενσωματώνει έναν παράγοντα τυχαιότητας στην διαδικασία δημιουργίας μοντέλου, χρησιμοποιώντας δείγματα από το σύνολο δεδομένων εκπαίδευσης και εξετάζοντας μόνο ένα υποσύνολο των χαρακτηριστικών σε κάθε διαχωρισμό. Αυτή η προσέγγιση, βελτιώνει την ποικιλομορφία μεταξύ των διαφόρων δέντρων, μειώνοντας την πιθανότητα υπερπροσαρμογής και ενισχύοντας την ακρίβεια των προβλέψεων μέσω του μέσου όρου ή της διαδικασίας ψηφοφορίας. Το Τυχαίο Δάσος επίσης, είναι γνωστό για την ευελιξία του, την ικανότητά του να διαχειρίζεται μεγάλα σύνολα δεδομένων, καθώς και την ανθεκτικότητά του σε ακραίες τιμές και στοιχεία, τα οποία συμβάλλουν στην ευρεία εφαρμογή και την επιτυχία του σε πραγματικά σενάρια εφαρμογών.

2.2.3 Ενίσχυση Κλίσης

Η Ενίσχυση κλίσης, (Gradient Boosting - GB) [119, 120] αποτελεί μέλος της κατηγορίας των συνδυαστικών μεθόδων μάθησης [423], αντιπροσωπεύοντας μια προσέγγιση όπου διαδοχικά μοντέλα κατασκευάζονται με στόχο τη διόρθωση των σφαλμάτων των προηγούμενων μοντέλων. Η Ενίσχυση Κλίσης, ενσαρκώνει την ιδέα της σταδιακής ενίσχυσης απλών μοντέλων σ' ένα πιο ισχυρό προβλεπτικό μοντέλο.

Η διαδικασία ξεκινά με την κατασκευή ενός αρχικού μοντέλου, βασιζόμενου σ' ένα υποσύνολο των δεδομένων. Το μοντέλο αυτό, χρησιμοποιείται για να κάνει προβλέψεις σε ολόκληρο το σύνολο δεδομένων και στη συνέχεια υπολογίζεται το σφάλμα του. Οι προβλέψεις αυτές, δεν εφαρμόζονται αμέσως, αλλά το αρχικό μοντέλο προορίζεται να ενισχυθεί μέσω επόμενων επαναλήψεων. Για την Ενίσχυση Κλίσης, δημιουργείται ένα νέο μοντέλο, το οποίο στοχεύει τα σφάλματα του προηγούμενου μοντέλου ως τη νέα «Μεταβλητή Στόχο», με σκοπό τη διόρθωση αυτών των σφαλμάτων. Το νέο μοντέλο, ενσωματώνεται στη συνέχεια με τις προβλέψεις του προηγούμενου, βελτιώνοντας την συνολική απόδοση. Η

διαδικασία αυτή, επαναλαμβάνεται με κάθε νέο μοντέλο να προσαρμόζεται στα σφάλματα που απομένουν από το προηγούμενο, στοχεύοντας στη συνεχή βελτίωση και διόρθωση.

Αντίθετα, με τα παραδοσιακά μοντέλα που εκπαιδεύονται ανεξάρτητα, η Ενίσχυση Κλίσης, εστιάζει στην βελτιστοποίηση μιας συνάρτησης απώλειας, προσθέτοντας διαδοχικά «αδύναμα» μοντέλα (συνήθως δέντρα απόφασης), που διορθώνουν τα σφάλματα του προηγούμενου μοντέλου. Η χρήση της Κλίσης («gradient») στην παραπάνω διαδικασία, αναφέρεται στην ελαχιστοποίηση της κλίσης της συνάρτησης απώλειας (loss function) σε σχέση με τις προβλεπόμενες τιμές, με κάθε επόμενο μοντέλο να επικεντρώνεται στα σφάλματα που αφήνουν τα προηγούμενα.

Η επαναληπτική αυτή διαδικασία, συνεχίζεται μέχρις ότου να μην παρατηρείται περαιτέρω βελτίωση στην απόδοση του συστήματος ή μέχρι να επιτευχθεί ένας προκαθορισμένος αριθμός εκτιμητών, φέρνοντας τη διαδικασία σε ολοκλήρωση. Με τον τρόπο αυτό, η Ενίσχυση Κλίσης, αναδεικνύεται σε μία από τις πιο δυναμικές και αποτελεσματικές τεχνικές στον τομέα της Μηχανικής Μάθησης, προσφέροντας ισχυρές προβλεπτικές ικανότητες.

2.2.4 Δέντρα Ενισχυμένης Κλίσης & XGBoost

Τα Δέντρα Ενισχυμένης Κλίσης [71] αναδεικνύονται ως μια εξελιγμένη και ενισχυμένη εκδοχή της μεθοδολογίας Ενίσχυση Κλίσης, όπου τα χρησιμοποιούμενα αδύναμα μοντέλα είναι δέντρα απόφασης [119] και όπου υιοθετώντας τις βασικές αρχές της Ενίσχυση Κλίσης και προσθέτοντας πολλές καινοτομίες, επιτυγχάνει εντυπωσιακή απόδοση.

Η βασική πρόκληση κατά τη δημιουργία ενός δέντρου απόφασης, εντοπίζεται στην επιλογή του τρόπου διαχωρισμού ενός τρέχοντος φύλλου. Μία προσέγγιση, για την επίλυση αυτού του προβλήματος, είναι ο λεγόμενος «Άπληστος Τρόπος», ο οποίος απαιτεί τον υπολογισμό της νέας απώλειας για κάθε πιθανή

διάσπαση καθώς και την επιλογή της καλύτερης. Η τεχνική αυτή, παρά του ότι είναι άμεση, αποδεικνύεται αναποτελεσματική και οδηγεί σε πιο αργή εκπαίδευση των Δέντρων Ενισχυμένης Κλίσης.

Μία από τις ταχύτερες υλοποιήσεις των δέντρων Ενισχυμένης Κλίσης είναι το XGBoost [71], το οποίο προσφέρει σημαντικά βελτιωμένη αποδοτικότητα. Ενισχύεται από την προσθήκη ενός όρου τακτοποίησης στην αντικειμενική συνάρτηση, τη δυνατότητα εσωτερικής διαχείρισης ελλειπουσών τιμών και την εφαρμογή τεχνικών παραλληλοποίησης για τη βελτίωση της αποδοτικότητας υπολογισμού.

Επιπλέον, ο XGBoost, υιοθετεί μια προηγμένη στρατηγική κλαδέματος των δέντρων κατά την κατασκευή τους, προσφέροντας μια προστασία κατά της υπερπροσαρμογής και βελτιώνοντας την ικανότητα γενίκευσης του μοντέλου. Το XGBoost αναλύει την κατανομή των χαρακτηριστικών σε όλα τα δεδομένα ενός φύλλου και χρησιμοποιεί αυτήν την πληροφορία για να περιορίσει τον χώρο αναζήτησης για πιθανούς διαχωρισμούς, αντιμετωπίζοντας έτσι την αναποτελεσματικότητα η οποία προκύπτει κατά τη διαδικασία εκπαίδευσης των δέντρων με τον παραδοσιακό «άπληστο» τρόπο.

Οι εν λόγω προσθήκες καταστούν το XGBoost ιδιαίτερα επιθυμητό για ευρύ φάσμα εφαρμογών, όπου καταγράφεται μεγάλη επιτυχία όσον αφορά σε ταχύτητα, ακρίβεια και συνολική αποδοτικότητα. Η εξαιρετική ταχύτητα του XGBoost επιτρέπει την γρήγορη διερεύνηση πολλαπλών ρυθμίσεων υπερπαραμέτρων, καθιστώντας τον εξαιρετικά δημοφιλές και συχνά χρησιμοποιούμενο σε διαγωνισμούς και αγώνες δεδομένων, όπως είναι το Kaggle. Η υλοποίηση λοιπόν αυτή, διακρίνεται για την αποδοτικότητά της και την ευρεία αποδοχή της στην κοινότητα της Μηχανικής Μάθησης, αντικατοπτρίζοντας την ικανότητά της να διευκολύνει την ανάπτυξη υψηλής ακρίβειας προβλεπτικών μοντέλων.


2.3 Αρχιτεκτονικές Βαθιάς Μηχανικής Μάθησης για την Πρόβλεψη Χρονοσειρών

Οι αρχιτεκτονικές Βαθιάς Μηχανικής Μάθησης, εξετάζουν πολύπλοκες σχέσεις μέσω μιας δομής η οποία περιλαμβάνει πολλά μη γραμμικά επίπεδα. Κάθε ενδιάμεσο επίπεδο αποτελείται από κόμβους που ενσαρκώνουν την αναπαράσταση των χαρακτηριστικών των εισαγόμενων δεδομένων [46]. Στο πλαίσιο της ανάλυσης χρονοσειρών, οι εν λόγω αναπαραστάσεις, περιέχουν κρίσιμες χρονικές πληροφορίες μέχρι τη στιγμή που γίνεται η παρατήρηση. Η ενότητα αυτή, παρουσιάζει τους βασικότερους τύπους στοιχείων από τα οποία αποτελούνται οι αρχιτεκτονικές Βαθιάς Μηχανικής Μάθησης, ιδιαίτερα όσον αφορά την πρόβλεψη πολυμεταβλητών χρονοσειρών.

2.3.1 Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNN)

Τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα (Recurrent Neural Networks - RNNs) έχουν μια μακρά και εδραιωμένη παρουσία στον τομέα της πρόβλεψης χρονοσειρών [239], παρουσία, που συνεχίζεται μέχρι σήμερα. Το βασικό δομικό στοιχείο των RNN είναι τα κύτταρα RNN, τα οποία λειτουργούν ως εσωτερική κατάσταση μνήμης. Ο κύριος σκοπός τους, είναι να διατηρούν μια συμπυκνωμένη περίληψη των πληροφοριών του παρελθόντος, όπου το δίκτυο θεωρεί χρήσιμες για την πρόβλεψη των μελλοντικών τιμών. Σε κάθε χρονικό βήμα, στο δίκτυο παρουσιάζονται νέες παρατηρήσεις και τα κύτταρα ενημερώνονται αναλόγως με τη νέα πληροφορία. Η στάνταρ δομή ενός RNN και η ανεπτυγμένη στον χρόνο εκδοχή του, παρουσιάζονται στο Σχήμα 2.1. Στην περίπτωση των πολυμεταβλητών χρονοσειρών, οι είσοδοι x και οι έξοδοι t είναι πολυδιάστατες σε κάθε χρονικό βήμα.


Οι πρώτες εκδόσεις των RNN, αντιμετώπιζαν δυσκολίες στο να καταγρά-



Σχήμα 2.1: Ξεδιπλωμένο Επαναλαμβανόμενο Νευρωνικό Δίκτυο. Η εικόνα προέρχεται από τα Wikimedia Commons, διαθέσιμη κάτω από το CC BY-SA 4.0 license: Βλ. πρωτότυπη εδώ.

ψουν αποτελεσματικά μακροπρόθεσμες εξαρτήσεις, ένα ζήτημα που είναι ευρέως γνωστό ως το πρόβλημα των «Εκρηκτικών και Εξαφανιζόμενων Κλίσεων» [306]. Συγκεκριμένα, η απουσία ενός περιορισμού στο εύρος του παραθύρου αναδρομής, (look-back window) σημαίνει ότι τα κελιά RNN αδυνατούν να διατηρήσουν όλες τις σημαντικές πληροφορίες από την αρχή της ακολουθίας [47]. Η εισαγωγή των Νευρωνικών Δικτύων Μακροπρόθεσμης Μνήμης (Long Short-Term Memory - LSTMs) [155] και άλλων παραλλαγών, όπως τα Φραγμένα Επαναλαμβανόμενα Δίκτυα, (Gated Recurrent Units - GRUs) [76] έχουν συμβάλει σημαντικά στην αντιμετώπιση του προβλήματος των Εκρηκτικών και Εξαφανιζόμενων Κλίσεων, επιτρέποντας στην πιο ομαλή ροή των κλίσεων μέσα στο δίκτυο. Στο Σχήμα 2.2 απεικονίζονται τα κελιά που χρησιμοποιούνται στην αρχιτεκτονική του LSTM.

Ένας ακόμη περιορισμός των παραδοσιακών RNN, ήταν η αδυναμία τους να αξιοποιούν πληροφορίες από μελλοντικά χρονικά βήματα. Προκειμένου να ξεπεραστεί αυτή η πρόκληση, εισήχθη μια νέα αρχιτεκτονική, τα Αμφίδρομα Επαναλαμβανόμενα Νευρωνικά Δίκτυα (Bidirectional RNNs - BiRNNs), από τους Schuster και Paliwal [340]. Η καινοτομία των BiRNNs, έγκειται στη δυνατότητα να εκπαιδεύονται και στις δύο χρονικές κατευθύνσεις, προς τα εμπρός και προς τα πίσω, χρησιμοποιώντας ξεχωριστά κρυφά επίπεδα για κάθε κατεύθυνση. Σε μια εξέλιξη αυτής της ιδέας, οι Graves και Schmidhuber [135] ενσωμάτωσαν το



Σχήμα 2.2: Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης (LSTM). Η εικόνα προέρχεται από τα Wikimedia Commons, διαθέσιμη κάτω από το CC BY-SA 4.0 license: Βλ. πρωτότυπη εδώ.

κελί LSTM στην αρχιτεκτονική BiRNN, δημιουργώντας τη βελτιωμένη εκδοχή του Bidirectional LSTM (BiLSTM). Ακολουθώντας τις ίδιες αρχές, αυτή η διαδικασία μπορεί να εφαρμοστεί και στα GRU για τη δημιουργία των Bidirectional GRU (BiGRU) δικτύων.

Μια ιδιαίτερα δημοφιλής και ισχυρή προσέγγιση για τη μοντελοποίηση ακολουθιών, που χρησιμοποιεί τα LSTM, GRU, ή τις Bidirectional εκδοχές τους, είναι το πλαίσιο της «ακολουθίας, σε ακολουθία» (Sequence to Sequence - Seq2Seq) ή κωδικοποιητή-αποκωδικοποιητή [362]. Αρχικά εφαρμόστηκε με εξαιρετική επιτυχία σε εργασίες επεξεργασίας φυσικής γλώσσας όπως η αυτόματη μετάφραση, αλλά έχει επίσης τη δυνατότητα να εφαρμοστεί στην πρόβλεψη χρονοσειρών [98]. Στο πλαίσιο αυτό, ένα Νευρωνικό Δίκτυο (ο Κωδικοποιητής) κωδικοποιεί τα εισερχόμενα δεδομένα σ' ένα διάνυσμα σταθερού μεγέθους, ενώ ένα δεύτερο Νευρωνικό Δίκτυο (ο Αποκωδικοποιητής), χρησιμοποιεί αυτό το διάνυσμα για να παράγει την επιθυμητή ακολουθία εξόδου. Οι παραπάνω αρχιτεκτονικές RNN, μπορούν να υπηρετήσουν είτε ως Κωδικοποιητές είτε ως Αποκωδικοποιητές στο εν λόγω πλαίσιο. Όλες οι παραπάνω προσεγγίσεις και βελτιώσεις στην τεχνολογία των RNN, έχουν συμβάλει στην καθιέρωσή τους ως βασικό στοιχείο πολλών

σύγχρονων αρχιτεκτονικών για την πρόβλεψη πολυμεταβλητών χρονοσειρών, αποτελώντας τα κύρια δομικά τους στοιχεία [336, 323, 236, 387, 394].

Κατά τη χρήση των RNN και των παραλλαγών τους, είναι απαραίτητη η προσεκτική ρύθμιση των υπερπαραμέτρων, συγκεκριμένα των Κρυφών Μονάδων (Hidden Units) και Επιπέδων (Hidden Layers), του Ρυθμού Εκμάθησης (Learning Rate) και του Μεγέθους της Παρτίδας (Batch Size). Ο αριθμός των κρυφών μονάδων και επιπέδων, θα πρέπει να είναι συναφής με την πολυπλοκότητα του συνόλου δεδομένων. Γενικά, όσο πιο περίπλοκα είναι τα δεδομένα, τόσο μεγαλύτερη απαιτείται η διάσταση των Επιπέδων και των Νευρωνικών Δικτύων. Η χρήση τεχνικών Προσαρμοστικού Ρυθμού Εκμάθησης (Adaptive Learning Rate Techniques) μπορεί να αντιμετωπίσει την μη σταθερότητα, ενώ ένα κατάλληλο μέγεθος παρτίδας, μπορεί να εξασφαλίσει μια ομαλότερη διαδικασία εκμάθησης. Επίσης, για την επιτυχία των μοντέλων ζωτικής σημασίας είναι, το μήκος των ακολουθιών εισόδου να βρίσκεται συντονισμένο με τα χρονικά μοτίβα που πρέπει να αναγνωριστούν, ιδιαίτερα σε περιπτώσεις όπου στοχεύεται η κατανόηση σχέσεων που εκτείνονται σε μακρύ χρονικό διάστημα.

2.3.2 Συνελικτικά Νευρωνικά Δίκτυα (CNN)

Τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks), αρχικά εφαρμόστηκαν σε εργασίες Υπολογιστικής Όρασης. Μέσω της υιοθέτησης ισχυρών, αλλά γενικά ακριβών, υποθέσεων σχετικά με τη φύση των εικόνων - όπως η σταθερότητα των στατιστικών τους και η τοπική εξάρτηση μεταξύ των εικονοστοιχείων - τα CNN μπορούν να ανακαλύψουν σημαντικές σχέσεις και να εξάγουν ισχυρές αναπαραστάσεις [206].

Τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks) αποτελούνται κατά κανόνα από μια σειρά συνελικτικά στρώματα (convolutional layers) που ακολουθούνται από στρώματα συγκέντρωσης (pooling layers) και ένα ή περισσότερα πυκνά στρώματα (dense layers) προς το τέλος. Τα συνελικτικά


στρώματα, εφαρμόζουν μια λειτουργία συνέλιξης στα δεδομένα εισόδου τους μ' ένα φίλτρο (filter matrix), δημιουργώντας αναπαραστάσεις υψηλού επιπέδου. Η λειτουργία της συγκέντρωσης στοχεύει στη μείωση της διάστασης των αναπαραστάσεων, διατηρώντας ταυτόχρονα, όσο το δυνατόν περισσότερες από τις σημαντικές πληροφορίες.

Στο πλαίσιο των δεδομένων χρονοσειρών, τα CNN που αναφέρονται συχνά ως χρονικά CNN, εφαρμόζουν παρόμοιες υποθέσεις αναλλοίωτης μεταβλητότητας, όπως τα Παραδοσιακά CNN, αλλά με έμφαση στο χρόνο αντί για τον χώρο. Αυτό σημαίνει ότι διατηρούν το ίδιο σύνολο βαρών φίλτρου σε κάθε χρονικό βήμα. Για την προσαρμογή των CNN από την όραση υπολογιστών στην πρόβλεψη χρονοσειρών, απαιτούνται κάποιες τροποποιήσεις [292, 54]. Ένας βασικός περιορισμός είναι, ότι το παράθυρο αναδρομής (look-back window) των CNN περιορίζεται από το μέγεθος του φίλτρου τους, γνωστό ως Δεκτικό Πεδίο (Receptive Field). Ως εκ τούτου, η επιλογή του κατάλληλου μεγέθους φίλτρου, είναι κρίσιμη για την ικανότητα του δικτύου, να καταγράφει όλες τις σχετικές ιστορικές πληροφορίες και αυτή η διαδικασία συχνά αποτελεί μέρος της ρύθμισης υπερπαραμέτρων [54]. Επίσης, οι λεγόμενες αιτιώδεις συνελίξεις (causal convolutions), αναπτύχθηκαν για να διασφαλίζεται, ότι δεν υπάρχει διαρροή πληροφορίας από το μέλλον στο παρελθόν και ότι χρησιμοποιούνται μόνο παρελθοντικές πληροφορίες για προβλέψεις [292]. Τέλος, η αποτύπωση μακροπρόθεσμων χρονικών εξαρτήσεων, επιτυγχάνεται μέσω της χρήσης πολύ βαθιών δικτύων ενισχυμένων με υπολειμματικά στρώματα (residual layers) και διευρυμένες συνελίξεις (dilated convolutions) [54].

Ένα παράδειγμα αρχιτεκτονικής CNN για την πρόβλεψη πολυμεταβλητών χρονοσειρών φαίνεται στο Σχήμα 2.3. Η χρήση τυπικών συνελκτικών στρωμάτων μπορεί να είναι υπολογιστικά ακριβή, ειδικά όταν απαιτούνται ισχυρές μακροπρόθεσμες εξαρτήσεις, γεγονός που οδήγησε στην εφαρμογή διευρυμένων συνελίξεων σε νεότερες αρχιτεκτονικές για τη μείωση του υπολογιστικού φόρτου,

διατηρώντας παράλληλα τα επιθυμητά αποτελέσματα [292, 36].

Οι διευρυμένες συνελίξεις, μπορούν να περιγραφούν ως συνελίξεις ενός μειωμένου δείγματος των χαρακτηριστικών που προέρχονται από χαμηλότερα επίπεδα, μειώνοντας έτσι σημαντικά τον υπολογιστικό φόρτο, που απαιτείται για την επεξεργασία πληροφοριών από προηγούμενα χρονικά βήματα. Ο βαθμός της μείωσης δειγματοληψίας, ρυθμίζεται μέσω του ρυθμού διαστολής, ο οποίος εφαρμόζεται επιλεκτικά. Κατά συνέπεια, οι διευρυμένες συνελίξεις, είναι ικανές να συγκεντρώνουν πληροφορίες από ευρύτερα χρονικά διαστήματα, αυξάνοντας τον ρυθμό διαστολής κατά την προσέγγιση σε κάθε νέο επίπεδο, διευκολύνοντας έτσι την αποδοτικότερη χρήση ιστορικών δεδομένων [235].



Σχήμα 2.3: Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου (CNN) για Πρόβλεψη Πολυμεταβλητών Χρονοσειρών. Η εικόνα είναι προσαρμοσμένη από [66], διαθέσιμη κάτω από το CC BY-SA 4.0 license: Βλ. πρωτότυπη εδώ.

Κατά τη διαδικασία της ρύθμισης υπερπαραμέτρων, είναι σημαντικό να δίνεται προσοχή στην προσαρμογή του αριθμού των φίλτρων, του μεγέθους των φίλτρων, του αριθμού των συνελκτικών επιπέδων και των τεχνικών συγκέντρωσης στα ειδικά μοτίβα των δεδομένων [36]. Συγκεκριμένα, η ανάγκη για αυξημένο αριθμό φίλτρων και επιπέδων εντείνεται, όταν τα δεδομένα παρουσιάζουν υψηλό βαθμό πολυπλοκότητας και διαφοροποίησης. Μεγαλύτερες ακολουθίες, περιέχουν πιο πλούσιες πληροφορίες και ενδέχεται να απαιτούν μεγαλύτερα φίλτρα για την αποτελεσματική καταγραφή εκτεταμένων μοτίβων και εξαρτήσεων μέσα σε μακρύτερες περιόδους. Σε περιπτώσεις όπου τα δεδομένα έχουν θόρυβο, οι τεχνικές συγκέντρωσης, μπορούν να συμβάλλουν στη μείωση του θορύβου αυτού,

βελτιώνοντας έτσι την ικανότητα του μοντέλου να εστιάζει στα πιο σημαντικά χαρακτηριστικά.


2.3.3 Μηχανισμός Προσοχής (Attention Mechanism)

Αν και τα LSTM έλυσαν εν μέρει το πρόβλημα της Εξαφάνισης Κλίσεως, δεν κατάφεραν να το εξαλείψουν πλήρως. Παρά του ότι, τα LSTM θεωρητικά, μπορούν να διατηρούν πληροφορίες από παλαιότερες καταστάσεις, στην πράξη όμως, λόγω του φαινομένου των Εξαφανιζόμενων Κλίσεων, οι πληροφορίες που διατηρούνται σε μακρινές καταστάσεις, είναι συχνά ανεπαρκείς ή ανακριβείς.

Το πρόβλημα αντιμετωπίστηκε με την εισαγωγή του Μηχανισμού Προσοχής [35, 74], ο οποίος χρησιμοποιήθηκε αρχικά στις αρχιτεκτονικές Μετασχηματιστών (Transformer) για αυτόματη μετάφραση [91, 379, 83]. Η Προσοχή, επιτρέπει στα Νευρωνικά Δίκτυα, να εστιάζουν στα πιο σημαντικά μέρη των δεδομένων εισόδου, δίνοντας περιορισμένη σημασία στα λιγότερο σημαντικά. Το δίκτυο ανακαλύπτει από τα ίδια τα δεδομένα εισόδου ποια στοιχεία είναι πιο σημαντικά. Ο Μηχανισμός Προσοχής, καθιστώντας διαθέσιμες όλες τις παρελθοντικές πληροφορίες, επιτρέπει την πρόσβαση και αξιολόγησή τους με βάση τη σχετικότητα, διασφαλίζοντας ότι οι κρίσιμες πληροφορίες από το παρελθόν ενισχύουν την πρόβλεψη.

Εκτός από εφαρμογές επεξεργασίας φυσικής γλώσσας, η Προσοχή έχει αποδειχθεί ωφέλιμη και στην πρόβλεψη χρονοσειρών, επιτυγχάνοντας εξαιρετικές επιδόσεις [108, 228, 234]. Οι δύο κυριότερες τεχνικές Προσοχής που χρησιμοποιούνται, είναι η Προσοχή με Εσωτερικό Γινόμενο (Dot-Product Attention) και η Προσοχή Πολλαπλών Κεφαλών (Multi-Head Attention). Η πρώτη, υπολογίζει την Προσοχή μέσω του γινομένου μεταξύ των διανυσμάτων, ενώ η δεύτερη, εφαρμόζει πολλαπλούς μηχανισμούς Προσοχής παράλληλα, με κάθε μηχανισμό να παράγει μια ανεξάρτητη έξοδο Προσοχής, και στη συνέχεια συνδυάζονται και μετασχηματίζονται για την παραγωγή της τελικής εξόδου. Αυτοί οι δύο τύποι

Προσοχής παρουσιάζονται στο Σχήμα 2.4.



Σχήμα 2.4: Μηχανισμοί Προσοχής:Εσωτερικό γινόμενο (αριστερά) έναντι πολλαπλών κεφαλών (δεξιά). Η εικόνα είναι προσαρμοσμένη από [439].

Η διαδικασία επιλογής υπερπαραμέτρων, στα μοντέλα Προσοχής που χρησιμοποιούνται για την πρόβλεψη χρονοσειρών, επηρεάζεται σημαντικά από τις ιδιαιτερότητες των δεδομένων [393]. Για παράδειγμα, το μήκος των ακολουθιών δεδομένων μπορεί να καθορίσει τον αριθμό των κεφαλών Προσοχής και το μέγεθος του παραθύρου Προσοχής που χρειάζεται. Μεγαλύτερες ακολουθίες, ενδέχεται να απαιτούν μεγαλύτερο αριθμό κεφαλών Προσοχής, για να αναλύσουν διαφορετικούς τύπους εξαρτήσεων, καθώς και ευρύτερα παράθυρα Προσοχής για την επεξεργασία μακροπρόθεσμων μοτίβων. Η Εποχικότητα στα δεδομένα, μπορεί να ωθήσει προς τη χρήση εξειδικευμένων μηχανισμών Προσοχής ή ειδικά διαμορφωμένων διαστημάτων Προσοχή, για την εστίαση σε επαναλαμβανόμενα μοτίβα, ενώ μη σταθερές χρονοσειρές, μπορεί να επωφεληθούν από προσαρμοστικούς μηχανισμούς Προσοχής που ανταποκρίνονται στις διακυμάνσεις των δεδομένων. Επιπλέον, η επιλογή του είδους του μηχανισμού Προσοχής μπορεί να βασί-

ζεται στις συγκεκριμένες ανάγκες του συνόλου δεδομένων. Μηχανισμοί Αυτοπροσοχής, όπως εκείνοι που εντοπίζονται στους Μετασχηματιστές (Transformers), αναδεικνύονται για τη δυνατότητά τους να αναγνωρίζουν περίπλοκες εξαρτήσεις και να ερμηνεύουν πολύπλοκα μοτίβα.


2.3.4 Νευρωνικά Δίκτυα Γραφημάτων

Τα προβλήματα χρονοσειρών μπορούν να είναι ιδιαίτερα περίπλοκα, ειδικότερα όταν περιλαμβάνουν σύνθετες χρονικές και χωρικές εξαρτήσεις. Ενώ τα RNN και τα χρονικά CNN, είναι αποτελεσματικά στο να μοντελοποιούν χρονικές εξαρτήσεις, αντιμετωπίζουν δυσκολίες στην ανάδειξη χωρικών διασυνδέσεων. Αντίθετα, τα κανονικά CNN έχουν την δυνατότητα να μοντελοποιούν τις τοπικές χωρικές πληροφορίες, αλλά αυτό περιορίζεται σε δεδομένα με Ευκλείδεια Δομή. Για την αντιμετώπιση των μη Ευκλείδειων Δομών, τα Νευρωνικά Δίκτυα Γραφημάτων (Graph Neural Networks - GNN) προσφέρουν μια εναλλακτική προσέγγιση, καθώς είναι σχεδιασμένα να εκμεταλλεύονται τις ιδιότητες των γραφημάτων, επιτρέποντας την καταγραφή των χωρικών εξαρτήσεων σε σενάρια, όπως η πρόβλεψη Ροής της κυκλοφορίας [180].

Οι προσεγγίσεις GNN, διακρίνονται σε Φασματικές και μη Φασματικές. Οι Φασματικές Μέθοδοι, απαιτούν μια συγκεκριμένη δομή γραφήματος, καθιστώντας δύσκολη την εφαρμογή ενός GNN το οποίο έχει εκπαιδευτεί σ' ένα συγκεκριμένο γράφημα, σε άλλα γραφήματα με διαφορετική δομή [402]. Αντίθετα, οι μη Φασματικές Μέθοδοι, εφαρμόζουν τις λειτουργίες τους απευθείας στο γράφημα, εστιάζοντας σε χωρικές ομάδες κοντινών γειτόνων, μέσω της δειγματοληψίας μιας γειτονιάς σταθερού μεγέθους, για κάθε κόμβο και την εφαρμογή συναρτήσεων συνάθροισης πάνω στην επιλεγμένη γειτονιά [381]. Με τον τρόπο αυτό, οι μεταβλητές από πολυμεταβλητές χρονοσειρές, μετατρέπονται σε κόμβους ενός γραφήματος, όπου η κατάσταση ενός κόμβου, επηρεάζεται από τις καταστάσεις των γειτονικών κόμβων, αποκαλύπτοντας έτσι τις χωρικές σχέσεις μεταξύ τους.

Για την καταγραφή των χωρικών εξαρτήσεων μεταξύ των κόμβων, τα Νευρωνικά Δίκτυα Γραφημάτων (Graph Neural Networks - GNN) ενσωματώνουν μια ειδική μορφή λειτουργίας Συνέλιξης, γνωστή ως Συνέλιξη Γραφήματος [402]. Αυτή η λειτουργία, έχει βασικές ομοιότητες με τις Παραδοσιακές Συνελίξεις, που χρησιμοποιούνται στην επεξεργασία εικόνας, όπου ένα φίλτρο εφαρμόζεται πάνω σε μια τοπική περιοχή της εικόνας, δημιουργώντας μια νέα τιμή για κάθε εικονοστοιχείο μέσα σ' αυτήν την περιοχή. Κατ' αναλογία, οι Συνελίξεις Γραφημάτων εφαρμόζουν ένα φίλτρο σε μια τοπική γειτονιά κόμβων ενός γραφήματος, υπολογίζοντας μια νέα τιμή για κάθε κόμβο, βασισμένη στα χαρακτηριστικά των γειτόνων του. Η διαδικασία αυτή, επιτρέπει την ενημέρωση της αναπαράστασης κάθε κόμβου, μέσω της συγκέντρωσης πληροφοριών από τους γειτονικούς του κόμβους. Τυπικά, οι συνελίξεις Γραφημάτων υλοποιούνται μέσω ενός σχήματος μετάδοσης μηνυμάτων, το οποίο διαχέει πληροφορίες σε όλο το γράφημα [401]. Στο Σχήμα 2.5, παρουσιάζονται παραδείγματα τέτοιων Συνελικτικών Λειτουργιών σε Διαφορετικούς Κόμβους ενός Γραφήματος.

Στην ανάλυση των χρονικών σχέσεων, ορισμένες αρχιτεκτονικές Νευρωνικών Δικτύων Γραφημάτων (Graph Neural Networks - GNN) ενδέχεται να ενσωματώνουν τη χρήση Επαναλαμβανόμενων Νευρωνικών Δικτύων (RNN) ή Συνελικτικών Νευρωνικών Δικτύων (Convolutional Neural Networks - CNN) για την ανάλυση χρονικών δυναμικών [417, 231]. Άλλες προσεγγίσεις, αναζητούν την ταυτόχρονη μοντελοποίηση χρονικών μοτίβων και διασυνδέσεων μεταξύ διαφορετικών μεταβλητών [63]. Εισήχθη επίσης ένας καινοτόμος τύπος GNN το Δίκτυο Προσοχής Γραφημάτων (Graph Attention Network - GAT) από τους Veličković et al. [381], το οποίο ενσωματώνει τον Μηχανισμό Προσοχής. Η αρχιτεκτονική αυτή, επιτρέπει την αναπαράσταση κάθε κόμβου ως σταθμισμένο μέσο των μετασχηματισμένων χαρακτηριστικών των γειτονικών του κόμβων, χρησιμοποιώντας τους συντελεστές Προσοχής για την αξιολόγηση της σημασίας κάθε γείτονα. Αυτό το σύστημα επιτρέπει την εφαρμογή διαφορετικών βαρών σε διάφορους κόμβους



Σχήμα 2.5: Συνελίξεις Γραφημάτων που εφαρμόζονται σε διαφορετικούς κόμβους ενός γραφήματος. Κάθε κόμβος συμβολίζεται με έναν αριθμό (0-5).


εντός της ίδιας γειτονιάς, απαλλάσσοντας από την ανάγκη προηγούμενης γνώσης της πλήρους δομής του γραφήματος. Παρά την υψηλή αποτελεσματικότητα των GNN σε μια σειρά εφαρμογών και τις πρόσφατες καινοτομίες, η χρήση τους στην πρόβλεψη χρονοσειρών δεν έχει μελετηθεί τόσο εκτεταμένα όσο στην περίπτωση των RNN ή CNN. [53].

Στην εφαρμογή των Νευρωνικών Δικτύων Γραφημάτων (Graph Neural Networks - GNN) σε δεδομένα χρονοσειρών που οργανώνονται ως γραφήματα, μερικά κρίσιμα ζητήματα, σχετίζονται με την προσαρμογή των υπερπαραμέτρων. Αυτά περιλαμβάνουν, τον καθορισμό των αναπαραστάσεων των κόμβων και των ακμών, την επιλογή του αριθμού των επιπέδων διάδοσης μηνυμάτων, για τη διαχείριση των χρονικών εξαρτήσεων, την επιλογή των συναρτήσεων συγκέντρωσης, για τη συλλογή πληροφοριών από γειτονικούς κόμβους, και την προσαρμογή σε μεταβαλλόμενες δομές γραφημάτων που χαρακτηρίζουν τις χρονοσειρές [185].

Λόγου χάρη, απλούστερα μοντέλα GNN με λιγότερα επίπεδα, ενδέχεται να θεωρούνται επαρκή για μικρές ακολουθίες, ενώ μεγαλύτερες ακολουθίες, συνήθως απαιτούν βαθύτερα GNN για να αντλήσουν εκτενείς εξαρτήσεις. Η υψηλή μεταβλητότητα στα δεδομένα, μπορεί να καταστήσει αναγκαία τη χρήση πιο περίπλοκων δομών GNN, ενώ η εποχικότητα ενδέχεται να απαιτεί την εφαρμογή εξειδικευμένων συναρτήσεων συγκέντρωσης. Επιπρόσθετα, η δομή του γραφήματος πρέπει να αντανακλά σωστά τις σχέσεις μεταξύ των μεταβλητών της χρονοσειράς, είτε αυτές είναι κατευθυνόμενες, είτε σταθμισμένες ή έχουν κάποια άλλη μορφή, ώστε να επιτρέπουν την αποτελεσματική διάδοση πληροφοριών στο δίκτυο.

2.3.5 Υβριδικές Προσεγγίσεις (Hybrid Approaches)

Οι Υβριδικές Προσεγγίσεις, ενσωματώνουν διάφορες αρχιτεκτονικές Βαθιάς Μηχανικής Μάθησης, συνδυάζοντας τα πλεονεκτήματά τους για τη δημιουργία πιο ισχυρών μοντέλων πρόβλεψης. Ειδικότερα, η ένταξη πολλαπλών μοντέλων μάθησης σε μία αρχιτεκτονική, έχει αποδείξει ότι αυξάνει την ευρωστία και την προγνωστική δυνατότητα σε σύγκριση με τη χρήση ενός μόνο μοντέλου. Η βελτιωμένη ευρωστία, προέρχεται από την ικανότητα των υβριδικών μοντέλων, ν' αντέχουν καλύτερα σε θόρυβο και ελλιπή δεδομένα, μαθαίνοντας πιο γενικευμένες αναπαραστάσεις. Επίσης, ο συνδυασμός διαφόρων ειδών Νευρωνικών Δικτύων, αυξάνει την ευελιξία του μοντέλου, διευκολύνοντάς το, να προσαρμόζεται στα ειδικά χαρακτηριστικά και μοτίβα των δεδομένων χρονοσειρών. Μία διαδεδομένη Υβριδική Τεχνική στην πρόβλεψη χρονοσειρών, περιλαμβάνει τον συνδυασμό μοντέλων τα οποία είναι ικανά στην εξαγωγή χαρακτηριστικών, όπως τα CNN ή οι αυτοκωδικοποιητές (autoencoders), με μοντέλα που επιδεικνύουν ικανότητα στην κατανόηση χρονικών εξαρτήσεων μεταξύ αυτών των χαρακτηριστικών, όπως τα LSTM, GRU, ή BiLSTM. Στο Σχήμα 2.6 παρουσιάζεται μια συνηθισμένη Υβριδική Αρχιτεκτονική CNN–LSTM.



Σχήμα 2.6: Μια Απλή Υβριδική Αρχιτεκτονική CNN-LSTM. Η εικόνα είναι προσαρμοσμένη από [142].


Παρά τα σημαντικά τους πλεονεκτήματα, τα Υβριδικά Μοντέλα εμπεριέχουν συχνά μεγαλύτερες υπολογιστικές απαιτήσεις, οδηγώντας σε αυξημένους χρόνους εκπαίδευσης και ανάγκη για περισσότερους υπολογιστικούς πόρους. Η διαδικασία συντονισμού των υπερπαραμέτρων, γίνεται πιο σύνθετη λόγω της αυξημένης πολυπλοκότητας του μοντέλου και της ανάγκης για βελτιστοποίηση πολλαπλών παραμέτρων ταυτόχρονα. Εν τέλει, η εφαρμογή Υβριδικών Μοντέλων, θα πρέπει να εξετάζεται κυρίως σε περιπτώσεις, όπου τα πιο απλά μοντέλα δεν παρέχουν την απαιτούμενη απόδοση.

2.3.6 Αρχιτεκτονικές όπου θα Αξιοποιηθούν στην Διατριβή

2.3.6.1 Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης (LSTM)

Ένας από τους σημαντικούς περιορισμούς των Παραδοσιακών Νευρωνικών Δικτύων, έγκειται στην αδυναμία τους να διαχειρίζονται σειρές δεδομένων με χρονική συνέχεια. Τα δίκτυα αυτά, εξετάζουν μόνο το τρέχον δείγμα που τους παρουσιάζεται, χωρίς να λαμβάνουν υπόψη προηγούμενα δεδομένα. Για να ξεπεραστεί αυτός ο περιορισμός, αναπτύχθηκε μια νέα αρχιτεκτονική: τα Επανα-

λαμβανόμενα Νευρωνικά Δίκτυα [122] (RNN). Όπως προαναφέρθηκε, τα RNN διαθέτουν την ικανότητα, να αναγνωρίζουν μοτίβα σε ακολουθίες δεδομένων, αποθηκεύοντας πληροφορίες από προηγούμενα δεδομένα και επιτρέποντας στις αποφάσεις τους να επηρεάζονται από αυτό το ιστορικό. (Βλ. Εικόνα 2.7)




Σχήμα 2.7: Ξεδιπλωμένο Επαναλαμβανόμενο Νευρωνικό Δίκτυο. Η εικόνα προέρχεται από τα Wikimedia Commons, διαθέσιμη κάτω από το CC BY-SA 4.0 license: Βλ. πρωτότυπη εδώ.

Ωστόσο, κατά την ανάλυση δεδομένων με μακροχρόνιες σχέσεις, τα RNN αντιμετωπίζουν δυσκολίες. Το φαινόμενο αυτό, γνωστό ως «Μακροχρόνια Εξάρτηση» παρουσιάζεται όταν δεδομένα που είναι χωρικά απομακρυσμένα στη σειρά συνδέονται μεταξύ τους. Ενώ θεωρητικά τα RNN εμφανίζονται να έχουν τη δυνατότητα να χειριστούν την πρόκληση αυτή, στην πράξη αποδεικνύεται δύσκολο να διατηρήσουν τις εν λόγω τις μακροχρόνιες εξαρτήσεις. [48, 154]

Η ανωτέρω δυσκολία οδηγεί στο πρόβλημα της Εξαφάνισης της Κλίσης [153], όπου οι ενημερώσεις των βαρών κατά τη διαδικασία της εκπαίδευσης γίνονται τόσο μικρές, που δεν επιτρέπουν πραγματική μάθηση για μακροχρόνιες εξαρτήσεις. Για ν' αντιμετωπιστεί το πρόβλημα αυτό οι Sepp Hochreiter και Jürgen Schmidhuber ανέπτυξαν το 1997 μια ειδική αρχιτεκτονική RNN, τα Δίκτυα Μακροπρόθεσμης Μνήμης (LSTM) [156], η οποία σχεδιάστηκε ειδικά για την αποφυγή του προβλήματος της Εξαφάνισης της Κλίσης, ενισχύοντας την ικανότητα των δικτύων να μαθαίνουν από μακροχρόνιες εξαρτήσεις.

Τα Δίκτυα Μακροπρόθεσμης Μνήμης (LSTM), διαθέτουν την ιδιαίτερη

ικανότητα να συνδέουν πληροφορίες από το παρελθόν σε μεταγενέστερες στιγμές, επιτρέποντας τη διατήρηση πληροφοριών για εκτεταμένες χρονικές περιόδους. Η δυνατότητα των LSTM, να διατηρούν πληροφορίες εκτός της τυπικής ροής επεξεργασίας ενός Επαναλαμβανόμενου Δικτύου, επιτυγχάνεται μέσω της χρήσης μιας μοναδικής δομής, γνωστής ως Κλειστό Κελί. Αυτό το Κελί, λειτουργεί σαν ένας μεταφορικός ιμάντας που μεταφέρει πληροφορίες και καθορίζει πότε και ποια δεδομένα θ' αποθηκευτούν, θα διαβαστούν ή θα διαγραφούν, χρησιμοποιώντας ειδικές δομές, τις πύλες, που μπορούν να ανοίξουν ή να κλείσουν. (Βλ. Εικόνα 2.8)



Σχήμα 2.8: Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης (LSTM). Η εικόνα προέρχεται από τα Wikimedia Commons, διαθέσιμη κάτω από το CC BY-SA 4.0 license: Βλ. πρωτότυπη εδώ.

Η αρχιτεκτονική των LSTM, τα καθιστά ιδιαίτερος χρήσιμα και δημοφιλή, στον τομέα των Επαναλαμβανόμενων Νευρωνικών Δικτύων, με εφαρμογές που εκτείνονται σε πολλά πεδία. Αναγνωρίζονται, ως μία από τις προτιμώμενες επιλογές για την αντιμετώπιση προκλήσεων που συνδέονται με διαδοχικά δεδομένα, αποδεικνύοντας την ικανότητά τους να χειρίζονται πολύπλοκες χρονοσειρές, κείμενο, ομιλία, γονιδιώματα και δεδομένα από αισθητήρες, με αξιοσημείωτη ακρίβεια και αποδοτικότητα.

2.3.6.2 DeepAR: Πιθανοτική Πρόβλεψη με Επαναλαμβανόμενα Δίκτυα Αυτο-παλινδρόμησης

Το DeepAR, αποτελεί μια προσέγγιση πρόβλεψης, χρησιμοποιώντας Αυτο-παλινδρομικά Επαναλαμβανόμενα Νευρωνικά Δίκτυα για τη δημιουργία πιθανοτικών προβλέψεων. Η μέθοδος αυτή, αντιμετωπίζει την πρόκληση της πρόβλεψης μέσω της ενσωμάτωσης στατιστικών πιθανοτήτων, τις οποίες συνδυάζει με μη γραμμικές μεθόδους μετασχηματισμού δεδομένων, μαθαίνοντας μέσω της εκπαίδευσης ενός Βαθέος Νευρωνικού Δικτύου. [336].

Η μέθοδος DeepAR, ενσωματώνει μια αρχιτεκτονική Επαναλαμβανόμενων Νευρωνικών Δικτύων, που βασίζεται στην τεχνολογία της μακροπρόθεσμης μνήμης (LSTM), όπως περιγράφεται στην εργασία του [157]. Η παραπάνω προσέγγιση, είναι εμπνευσμένη από προηγούμενες μελέτες πάνω στη Βαθιά Μηχανική Μάθηση για δεδομένα χρονοσειρών [134, 293, 421], εξερευνώντας την πιθανολογική πρόβλεψη. Βαθύτερες νευρωνικές αρχιτεκτονικές, όπως αυτές που περιγράφονται στην έρευνα [220], προσφέρουν περισσότερο αφηρημένες αναπαραστάσεις των δεδομένων μέσω πολύπλοκων μετασχηματισμών, παρέχοντας συχνά πλεονεκτήματα έναντι των πιο απλών Νευρωνικών Δικτύων.

Το DeepAR ξεχωρίζει για τρεις βασικούς λόγους: Πρώτον, παρέχει πιθανολογικές προβλέψεις μέσω δειγμάτων Monte Carlo, επιτρέποντας την ακριβή ποσοτική εκτίμηση διαφορετικών σεναρίων εντός του εύρους της πρόβλεψης. Δεύτερον, αντί να βασίζεται σε υποθέσεις για Γκαουσιανό Θόρυβο, υποστηρίζει πολλαπλές συναρτήσεις πιθανότητας, δίνοντας τη δυνατότητα στον χρήστη να επιλέξει την πιο κατάλληλη συνάρτηση για τα δεδομένα του. Και τρίτον, ως μια προσέγγιση που βασίζεται στη Βαθιά Μηχανική Μάθηση, είναι ικανή να αναγνωρίζει και να μαθαίνει εποχιακά μοτίβα και περίπλοκες σχέσεις με ελάχιστη παρέμβαση από τον χρήστη [336].

2.3.6.3 N-Beats: Ανάλυση Νευρωνικής Βάσης για Ερμηνεύσιμη Πρόβλεψη Χρονοσειρών

Το N-Beats, είναι ένα μοντέλο για την πρόβλεψη χρονοσειρών που επικεντρώνεται σε μια Βαθιά Νευρωνική Δομή, συνδυάζοντας υπολειπόμενους συνδέσμους και μια πλήρως συνδεδεμένη στοίβα στρωμάτων. Η δομή αυτή, επιτρέπει την αποτελεσματική ανάλυση και πρόβλεψη περίπλοκων χρονοσειρών, με τρόπο παρόμοιο με τις παραδοσιακές μεθόδους αποσύνθεσης, όπως είναι οι προσεγγίσεις για την ανάλυση της εποχιακής τάσης [295].

Η αρχιτεκτονική του N-Beats, χαρακτηρίζεται από δύο ξεχωριστές στοίβες: μία για την ανάλυση της τάσης και μία για την ανάλυση της εποχικότητας, με κάθε στοίβα να αποτελείται από πολλαπλά μπλοκ συνδεδεμένα μέσω υπολειπόμενων συνδέσεων. Χρησιμοποιώντας την αρχή πρόβλεψης/ανασκόπησης, αυτή η διακριτή διάταξη, επιτρέπει την ανεξάρτητη εξαγωγή των στοιχείων τάσης και εποχικότητας πριν από την ολοκλήρωση της επεξεργασίας στην επόμενη στοίβα. Έτσι, οι μερικές προβλέψεις για την τάση και την εποχικότητα παρέχονται ως ανεξάρτητες έξοδοι, εμπλουτίζοντας το μοντέλο με ερμηνευσιμότητα [295].

Πέραν από τα πλεονεκτήματα σε ερμηνεία και ακρίβεια, που έχουν καταγραφεί σε πλήθος γνωστών συνόλων δεδομένων, το μοντέλο N-Beats διακρίνεται, για την ταχύτητα εκπαίδευσής του και την ικανότητά του να εφαρμοστεί ευρύτατα σε διάφορους τομείς με ελάχιστες προσαρμογές [295].

2.3.6.4 Μετασχηματιστές Χρονικής Ένωσης (TFT)

Ο TFT, αποτελεί ένα κορυφαίο μοντέλο Βαθιάς Μηχανικής Μάθησης, ειδικά σχεδιασμένο για την αποδοτική μοντελοποίηση δεδομένων χρονοσειρών. Η σύνθετη αρχιτεκτονική του, όπως παρουσιάζεται στην Εικόνα 2.9, περιλαμβάνει επίπεδα κωδικοποίησης LSTM και ερμηνεύσιμα επίπεδα μετασχηματιστή με Μηχανισμό Προσοχής, προσφέροντας προηγμένες δυνατότητες, σε σχέση με προηγούμενες αρχιτεκτονικές Βαθιάς Μηχανικής Μάθησης για χρονοσειρές. Τα βα-

σικά συστατικά του TFT, που συνθέτουν την πυρήνα της αρχιτεκτονικής του, περιγράφονται παρακάτω:

1. **Μηχανισμοί Πύλης (Gated Mechanisms):** Η ανάγκη για μέτρηση του βαθμού της απαραίτητης μη γραμμικής επεξεργασίας, μπορεί να διαφέρει ανάλογα με την πολυπλοκότητα του συνόλου δεδομένων και το περιβάλλον εφαρμογής. Υπάρχουν περιπτώσεις όπου απλούστερα μοντέλα ενδέχεται να είναι προτιμότερα, ιδίως σε σύνολα δεδομένων με μικρό μέγεθος ή υψηλό θόρυβο. Ο TFT, αντιμετωπίζει τέτοιες προκλήσεις με τη χρήση περιφραγμένων Νευρωνικών Δικτύων (Gated Residual Networks - GRN), όπως περιγράφεται από τον Tan et al. [365]. Ένα GRN λαμβάνει ως είσοδο ένα βασικό σήμα a και ένα προαιρετικό διάνυσμα c , παράγοντας έξοδο σύμφωνα με τις παρακάτω εξισώσεις 2.4, 2.5 και 2.6:

$$\text{GRN}_\omega(a, c) = \text{LayerNorm}(a + \text{GLU}_\omega(\eta_1)), \quad (2.4)$$

$$\eta_1 = W_{1,\omega}\eta_2 + b_{1,\omega}, \quad (2.5)$$

$$\eta_2 = \text{ELU}(W_{2,\omega}a + W_{3,\omega}c + b_{2,\omega}), \quad (2.6)$$

όπου η ELU (Exponential Linear Unit), είναι η συνάρτηση ενεργοποίησης [78], $\eta_1 \in \mathbb{R}^{d_{\text{model}}}$, $\eta_2 \in \mathbb{R}^{d_{\text{model}}}$ είναι ενδιάμεσα στρώματα, το LayerNorm είναι η κανονικοποίηση επιπέδου [33], και το ω είναι ένας δείκτης κατανομής βάρους. Επιπλέον, οι περιφραγμένες Γραμμικά Μονάδες (Gated Linear Units - GLUs) [84], πάνω στις οποίες βασίζονται τα επίπεδα πύλης, επιτρέπουν τη δυνατότητα παράκαμψης οποιονδήποτε στοιχείων δεν είναι χρήσιμα για την μοντελοποίηση ενός συγκεκριμένου συνόλου δεδομένων. Η έξοδος ενός GLU που δέχεται $\gamma \in \mathbb{R}^{d_{\text{model}}}$ ως είσοδο μπορεί να εκφραστεί όπως φαίνεται στην εξίσωση 2.7:

$$\text{GLU}_\omega(\gamma) = \sigma(W_{4,\omega}\gamma + b_{4,\omega}) \odot (W_{5,\omega}\gamma + b_{5,\omega}), \quad (2.7)$$

όπου σ είναι η Σιγμοειδής Συνάρτηση Ενεργοποίησης, $W \in \mathbb{R}^{d_{model} \times d_{model}}$ είναι το Σύνολο των Βαρών, $b \in \mathbb{R}^{d_{model}}$ είναι το Σύνολο των Προκαταλήψεων - Προτιμήσεων (Biases), το $\odot$ είναι το Γινόμενο Hadamard (στοιχείο προς στοιχείο) και το μέγεθος του κρυφού επιπέδου d_{model} , το οποίο είναι κοινό σε ολόκληρη την αρχιτεκτονική. Συνοπτικά, το GLU επιτρέπει στον TFT να ρυθμίσει κατά πόσο το GRN συνεισφέρει στην αρχική είσοδο α . Στην ακραία περίπτωση, είναι σε θέση ακόμα και να παραλείψει εντελώς ένα επίπεδο αν είναι απαραίτητο, μηδενίζοντας έτσι τυχόν μη γραμμικά αποτελέσματα.

2. **Δίκτυα Επιλογής Μεταβλητών (Variable Selection Networks):** Είναι συχνά δύσκολο να προκαθορίσουμε ποιοι παράγοντες θα είναι σημαντικοί, για ένα σύνολο δεδομένων/πρόβλημα. Για ν' αντιμετωπιστεί αυτό, ο TFT προσφέρει την δυνατότητα επιλογής χαρακτηριστικών, τόσο για στατικές όσο και για εξαρτώμενες από το χρόνο μεταβλητές. Όχι μόνο τα δίκτυα επιλογής μεταβλητών, ρίχνουν φως στο ποια χαρακτηριστικά συμβάλλουν κυρίως στις προβλέψεις του TFT, αλλά του επιτρέπουν επίσης να απαλλαγεί από τυχόν θορυβώδεις εισόδους που θα μπορούσαν ενδεχομένως να παρεμποδίσουν την απόδοσή του.

Ο TFT, υπολογίζει τα βάρη επιλογής μεταβλητών όπως περιγράφεται στην εξίσωση 2.8:

$$v_{\chi_t} = \text{Softmax}(\text{GRN}_{v_{\chi}}(\Xi_t, c_s)) \quad (2.8)$$

όπου $\Xi_t = [\xi_t^{(1)\top}, \dots, \xi_t^{(\mu_{\chi})\top}]^\top$ είναι ο πεπλατυσμένος πίνακας όλων των προηγούμενων δεδομένων την χρονική στιγμή t , επίσης $\xi_t^{(j)} \in \mathbb{R}^{d_{model}}$ είναι η μετασχηματισμένη είσοδος της μεταβλητής j -th τη στιγμή t και c_s είναι ένα διάνυσμα που υπολογίζεται από έναν στατικό κωδικοποιητή μεταβλητών. Κάθε $\xi_t^{(j)}$ περνά επίσης από το δικό του GRN, όπως φαίνεται στην

εξίσωση 2.9, παράγοντας έναν άλλο μη γραμμικό μετασχηματισμό $\tilde{\xi}_t^{(j)}$.

$$\tilde{\xi}_t^{(j)} = \text{GRN}_{\tilde{\xi}_{(j)}}(\xi_t^{(j)}) \quad (2.9)$$

Αυτοί οι μετασχηματισμοί στη συνέχεια σταθμίζονται, για να παραχθεί η τελική συνεισφορά όπως φαίνεται στην εξίσωση 2.10:

$$\tilde{\xi}_t = \sum_{j=1}^{\mu_x} v_{\chi_t}^{(j)} \tilde{\xi}_t^{(j)} \quad (2.10)$$

όπου $v_{\chi_t}^{(j)}$ είναι το j -th στοιχείο του διανύσματος v_{χ_t} .

3. Κωδικοποίηση Στατικών Μεταβλητών (Static Covariate Encoding):

Από σχεδίαση του, ο TFT δίνει ιδιαίτερη προσοχή στα στατικά μετα - δεδομένα δημιουργώντας τέσσερα διαφορετικά διανύσματα. Πιο συγκεκριμένα, πρόκειται για διανύσματα που αφορούν (1) την επεξεργασία των χρονικών πληροφοριών, (2) την ενίσχυση των χρονικών πληροφοριών με στατικά χαρακτηριστικά, καθώς και (3) την επιλογή των χρονικών χαρακτηριστικών. Τα διανύσματα αυτά, που παράγονται από διαφορετικούς κωδικοποιητές GRN και τοποθετούνται στρατηγικά σε διαφορετικά μέρη της αρχιτεκτονικής όπου η επίδραση των στατικών μεταβλητών μπορεί να αποδειχθεί σημαντική.

4. **Χρονική Επεξεργασία (Temporal processing):** Για να βελτιώσει την ερμηνευτικότητα του μοντέλου και να κατανοήσει καλύτερα τις μακροπρόθεσμες σχέσεις μεταξύ των διαφόρων χρονικών βημάτων, ο TFT κάνει χρήση του Μηχανισμού Προσοχής, πολλαπλών κεφαλών του δικτύου των μετασχηματιστών. Όπως κάθε τυπικός Μηχανισμός Προσοχής, υπολογίζει τις τιμές $V \in \mathbb{R}^{N \times d_v}$ με βάση τις σχέσεις μεταξύ των κλειδιών (keys) $K \in \mathbb{R}^{N \times d_{\text{attention}}}$ και των ερωτήσεων (queries) $Q \in \mathbb{R}^{N \times d_{\text{attention}}}$ όπως φαίνεται

στην εξίσωση 2.11:

$$\text{Attention}(Q, K, V) = A(Q, K)V \quad (2.11)$$

, όπου $A(Q, K) = \text{Softmax}(\frac{QK^T}{\sqrt{d_{\text{attention}}}})$. Η Προσοχή Πολλαπλών Κεφαλών, χρησιμοποιεί διαφορετικές Κεφαλές Προσοχής για διαφορετικούς χώρους αναπαράστασης, οι οποίοι αντικατοπτρίζονται μαθηματικά από την εξίσωση 2.12.

$$\text{Multihead}(Q, K, V) = [H_1, \dots, H_{m_H}]W_H \quad (2.12)$$

, όπου $H_h = \text{Attention}(QW_Q^{(h)}, KW_K^{(h)}, VW_V^{(h)})$ και $W_Q^{(h)} \in \mathbb{R}^{d_{\text{model}} \times d_{\text{attention}}}$, $W_K^{(h)} \in \mathbb{R}^{d_{\text{model}} \times d_{\text{attention}}}$, $W_V^{(h)} \in \mathbb{R}^{d_{\text{model}} \times d_V}$ είναι βάρη ειδικά για την κεφαλή όπου αφορούν τα ερωτήματα (queries), τα κλειδιά (keys) και τις τιμές (values) αντίστοιχα, ενώ οι έξοδοι όλων των κεφαλών τα H_h συνδυάζονται γραμμικά με τα βάρη $W_H \in \mathbb{R}^{(m_H \cdot d_V) \times d_{\text{model}}}$. Εφόσον σε κάθε κεφαλή υπολογίζονται διαφορετικές τιμές, τα Βάρη Προσοχής δεν μπορούν να εξηγήσουν επαρκώς τη συμβολή μιας συγκεκριμένης μεταβλητής. Για το σκοπό αυτό, το TFT προσαρμόζει τον Μηχανισμό Προσοχής Πολλαπλών Κεφαλών ώστε να μοιράζει τις τιμές σε κάθε κεφαλή. Οι εξισώσεις στη συνέχεια τροποποιούνται όπως φαίνεται στην εξίσωση 2.13:

$$\begin{aligned} \tilde{H} &= \tilde{A}(Q, K)VW_V \\ &= \frac{\sum_{h=1}^{m_H} A(QW_Q^{(h)}, KW_K^{(h)})}{H} VW_V \\ &= \frac{\sum_{h=1}^{m_H} \text{Attention}(QW_Q^{(h)}, KW_K^{(h)}, VW_V)}{H} \end{aligned} \quad (2.13)$$

, όπου $W_V \in \mathbb{R}^{d_{\text{model}} \times d_V}$ υποδηλώνει τη διάταξη βαρών που μοιράζονται οι διαφορετικές κεφαλές και $W_H \in \mathbb{R}^{d_{\text{attention}} \times d_{\text{model}}}$ αντιπροσωπεύει τον τελικό γραμμικό μετασχηματισμό.

5. **Διαστήματα Προβλέψεων και Συναρτήσεις Απώλειας (Predictions Intervals and Loss Functions):** Εκτός από την πρόβλεψη μεμονωμένων σημείων στο χρόνο, το TFT παράγει επίσης προβλέψεις για ολόκληρα διαστήματα. Αυτό επιτυγχάνεται, με την πρόβλεψη διαφορετικών εκατοστημορίων ή ποσοστών, όπως το 10ο, το 50ο και το 90ο. Οι προβλέψεις αυτές διαστημάτων παράγονται ταυτόχρονα σε κάθε χρονικό βήμα μετατρέποντας γραμμικά την έξοδο ενός αποκωδικοποιητή σύμφωνα με την εξίσωση 2.14:


$$\hat{y}(q, t, \tau) = W_q \tilde{\psi}(t, \tau) + b_q \quad (2.14)$$

, όπου $W_q \in \mathbb{R}^{1 \times d}$, $b_q \in \mathbb{R}$ είναι οι συντελεστές για μια δεδομένη ποσότητα q .

Όσον αφορά την εκπαίδευσή του, ο TFT μαθαίνει βελτιστοποιώντας την αθροιστική απώλεια ποσοστού σε όλες τις ποσοστιαίες εξόδους, όπως φαίνεται στην εξίσωση 2.15:

$$\text{Loss}(\Omega, W) = \sum_{y_t \in \Omega} \sum_{q \in Q} \sum_{\tau=1}^{\tau_{\max}} \frac{QL(y_t, \hat{y}(q, t-\tau, \tau), q)}{M \tau_{\max}} \quad (2.15)$$

, όπου $QL(y, \hat{y}, q) = q \max(0, y - \hat{y}) + (1 - q) \max(0, \hat{y} - y)$, το Ω υποδηλώνει τον τομέα του συνόλου εκπαίδευσης, το W τα βάρη του μοντέλου, το Q το σύνολο των ποσοστών π.χ. $Q = \{0.1, 0.9\}$ και M ο αριθμός των δειγμάτων στο σετ εκπαίδευσης.



Σχήμα 2.9: Αρχιτεκτονική του Μοντέλου TFT. Προσαρμογή από [233]

Κεφάλαιο 3

Προκλήσεις και Ευκαιρίες της Εφαρμογής Μεθόδων Βαθιάς Μηχανικής Μάθησης σε Δεδομένα Χρονοσειρών Πολλαπλών Μεταβλητών για Έξυπνες Πόλεις

Όπως ειπώθηκε και στο προηγούμενο κεφάλαιο, στα πλαίσια της διατριβής έγινε μια εκτενής επισκόπηση των τεχνικών Βαθιάς Μηχανικής Μάθησης εφαρμοσμένων σε δεδομένα χρονοσειρών πολλαπλών μεταβλητών, με ειδική έμφαση σε εφαρμογές για έξυπνες πόλεις. Επιπροσθέτως, δημιουργήθηκε μια ταξινόμια πάνω στο συγκεκριμένο υποπεδίο της Μηχανικής Μάθησης. Αυτό συνέβη για δύο λόγους. Ο πρώτος, είναι το γεγονός ότι υπήρχε ένα πολύ μεγάλο κενό στην βιβλιογραφία και μια τέτοια ταξινόμια απουσίαζε. Δεύτερο λόγο, αποτελεί το γεγονός ότι αυτή η επισκόπηση σε αυτό το υποπεδίο θα φέρει τον αναγνώστη της διατριβής σε επαφή με πολλές τεχνικές, αλγορίθμους και έννοιες που θα τον βοηθήσουν να κατανοήσει τα επόμενα κεφάλαια. Τί είναι όμως μια Έξυπνη Πόλη?

Μια Έξυπνη Πόλη αποτελεί έναν χώρο, όπου οι παραδοσιακές δομές και υπηρεσίες αναβαθμίζονται μέσω της υιοθέτησης και εφαρμογής σύγχρονων τεχνολογικών καινοτομιών, επιδιώκοντας την ευημερία των κατοίκων της. [317] Οι

Έξυπνες Πόλεις, αναπτύσσονται γρήγορα για να ανταποκριθούν στις αυξανόμενες ανάγκες του πληθυσμού στις αστικές περιοχές, προσφέροντας ένα βελτιωμένο βιοτικό επίπεδο.

Πέρα από την αξιοποίηση των ψηφιακών τεχνολογιών, για αποδοτικότερη χρήση των πόρων και μείωση των εκπομπών, η ανάπτυξη των Έξυπνων Πόλεων, συμπεριλαμβάνει επίσης τη βελτίωση των δικτύων αστικών μεταφορών, τη δημιουργία πιο αποτελεσματικών και διαδραστικών συστημάτων διαχείρισης, την ενίσχυση της παροχής νερού και των εγκαταστάσεων διάθεσης αποβλήτων, τη βελτίωση των συστημάτων φωτισμού και θέρμανσης κτιρίων, την αύξηση της ασφάλειας στους δημόσιους χώρους και πολλά άλλα. Για την επίτευξη αυτών των στόχων, οι Έξυπνες Πόλεις ενσωματώνουν συσκευές του Διαδικτύου των Πραγμάτων (IoT), όπως συνδεδεμένοι αισθητήρες και έξυπνοι μετρητές, για τη συλλογή δεδομένων σε τακτικά διαστήματα. Τα δεδομένα αυτά αναλύονται προκειμένου να βελτιωθεί η υποδομή και οι υπηρεσίες, βελτιώνοντας έτσι την ποιότητα ζωής των πολιτών. [300]

Οι αλγόριθμοι Βαθιάς Μηχανικής Μάθησης (Deep Learning), που έχουν την ιδιότητα να ανιχνεύουν σύνθετα μοτίβα από περίπλοκα σύνολα δεδομένων, έχουν καταδείξει εξαιρετική ικανότητα στην αντιμετώπιση των πολυδιάστατων (multivariate) δεδομένων χρονοσειρών που είναι χαρακτηριστικά των εφαρμογών IoT στις Έξυπνες Πόλεις. Ο σχεδιασμός τους, επιτρέπει την καταγραφή της δυναμικής πλήθους χρονοσειρών παράλληλα, εκμεταλλευόμενοι τις αλληλεπιδράσεις μεταξύ τους, προσφέροντας έτσι βελτιωμένες προβλέψεις. Ενδεικτικά, οι τεχνικές αυτές έχουν εφαρμοστεί σε ποικίλες εφαρμογές προβλέψεων χρονοσειρών, αγκαλιάζοντας διάφορους τομείς όπως το εμπόριο [55], η υγειονομική περίθαλψη [192], η βιολογία [223], η ιατρική [247], η αεροναυπηγία [384], η ενέργεια [256], η μελέτη του κλίματος [270], η αυτοκινητοβιομηχανία [284] και τα χρηματοοικονομικά [341]. Αυτό το ευρύ φάσμα τομέων επιβεβαιώνει την πολυμορφικότητα και την ευελιξία των αλγορίθμων Βαθιάς Μηχανικής Μάθησης, κα-

θιστώντας τους καθοριστικούς στην προώθηση της τεχνολογικής προόδου στον 21ο αιώνα.

Μερικά εντυπωσιακά παραδείγματα εφαρμογής αυτών των τεχνολογιών, περιλαμβάνουν την πρωτοβουλία Smart Nation της Σιγκαπούρης, η οποία εστιάζει στην πρόβλεψη της κυκλοφοριακής ροής, το πρόγραμμα Green Horizon του Γραφείου Περιβαλλοντικής Προστασίας του Πεκίνου, το έργο πρόβλεψης της ποιότητας του αέρα «Πρόβλεψη του αέρα που αναπνέουμε» στην πόλη του Λος Άντζελες και η πρωτοβουλία SunShot του Υπουργείου Ενέργειας των Ηνωμένων Πολιτειών για την πρόβλεψη της παραγωγής ανανεώσιμων πηγών ενέργειας. Συγκεκριμένα, στη Σιγκαπούρη, η Αρχή Χερσαίων Μεταφορών, έχει αναπτύξει ένα σύστημα διαχείρισης της κυκλοφορίας υποστηριζόμενο από Τεχνητή Νοημοσύνη, το οποίο αναλύει δεδομένα σε πραγματικό χρόνο για τη βελτιστοποίηση της ροής κυκλοφορίας και τη μείωση της συμφόρησης. Στο Πεκίνο της Κίνας, το Εργαστήριο Ερευνών της IBM, έχει αναπτύξει ένα από τα πλέον προηγμένα συστήματα πρόβλεψης της ποιότητας του αέρα παγκοσμίως, ενώ σε αρκετές πόλεις των Ηνωμένων Πολιτειών, η IBM πραγματοποιεί προβλέψεις για τη ζήτηση και την προσφορά ανανεώσιμων πηγών ενέργειας.

Η ενσωμάτωση τεχνολογιών Βαθιάς Μηχανικής Μάθησης και Τεχνητής Νοημοσύνης, στις δομές των Έξυπνων Πόλεων, υπερβαίνει τα αμιγώς τεχνικά οφέλη, αγγίζοντας έντονα τον κοινωνικοοικονομικό και περιβαλλοντικό ιστό των αστικών περιοχών και των κατοίκων τους [6]. Πιο συγκεκριμένα, η εφαρμογή αυτών των τεχνολογιών έχει τη δυναμική να ενισχύσει την οικονομική ανάπτυξη, προσελκύοντας ταλέντα και επιχειρηματίες, μετατρέποντας τις πόλεις σε κέντρα καινοτομίας. Η διαδικασία αυτή, μπορεί να οδηγήσει σε δημιουργία νέων θέσεων εργασίας και να ενισχύσει την οικονομική ανταγωνιστικότητα [24]. Μέσα από την οικονομική ανθρότητα, η πρόσβαση στην υγειονομική περίθαλψη και στην εκπαίδευση γίνεται ευρύτερη και πιο ισότιμη, αναδεικνύοντας πολίτες πιο αφοσιωμένους και ενδυναμωμένους, κάτι που συμβάλλει σημαντικά στην κοινωνική

συνοχή και στη συνολική ευημερία [277]. Επιπλέον, οι βελτιώσεις στην αποδοτική διαχείριση των πόρων μέσω της Τεχνητής Νοημοσύνης, μπορούν να συμβάλλουν στην περιβαλλοντική βιωσιμότητα των πόλεων, αντιμετωπίζοντας παγκόσμια ζητήματα όπως η κλιματική αλλαγή [372].

Έχει πραγματοποιηθεί εκτεταμένη έρευνα για την εφαρμογή της Βαθιάς Μηχανικής Μάθησης στην πρόβλεψη χρονοσειρών, τόσο από θεωρητική [235] όσο και από πειραματική [216] σκοπιά. Αναγνωρίζοντας τη σημασία της στο πλαίσιο των έξυπνων πόλεων, η Βαθιά Μηχανική Μάθηση έχει εφαρμοστεί σε διάφορους τομείς. Ωστόσο, δεδομένου ότι αυτό αποτελεί ένα σχετικά νέο πεδίο εφαρμογής, μόνο λίγες έρευνες έχουν εστιάσει στη μελέτη των σύγχρονων πρωτοπόρων μοντέλων και τεχνικών στο εν λόγω το πλαίσιο. Μερικές από αυτές τις έρευνες, όπως το [129, 266], προσεγγίζουν τη Βαθιά Μηχανική Μάθηση ως μέρος του ευρύτερου πεδίου της Μηχανικής Μάθησης και περιορίζονται σε έναν μικρό αριθμό μοντέλων. Άλλες μελέτες, που επικεντρώνονται στη Βαθιά Μηχανική Μάθηση, καλύπτουν μια πληθώρα τύπων δεδομένων, όπως κείμενα και/ή εικόνες [29, 77, 70, 271], ή ασχολούνται με εργασίες πέρα από την απλή πρόβλεψη, όπως η ταξινόμηση, και επομένως δεν προσφέρουν μια εξαντλητική επισκόπηση της εφαρμογής της Βαθιάς Μηχανικής Μάθησης στην πρόβλεψη χρονοσειρών IoT εντός του πλαισίου των έξυπνων πόλεων. Το πιο σημαντικό είναι ότι λείπει μια ενδελεχής ανάλυση των σύγχρονων αρχιτεκτονικών Βαθιάς Μηχανική Μάθησης (Βλ. Πίνακα 3.1). Η παρούσα μελέτη επιχειρεί να καλύψει αυτό το κενό, παρέχοντας μια επικαιροποιημένη και συγκεντρωτική ανάλυση του πώς οι μέθοδοι Βαθιάς Μηχανικής Μάθησης ενισχύουν τις έξυπνες πόλεις μέσω της μοντελοποίησης και πρόβλεψης δεδομένων πολυμεταβλητών χρονοσειρών IoT.

Οι τομείς εφαρμογής των Έξυπνων Πόλεων κατηγοριοποιούνται σε έξι βασικές κατηγορίες: έξυπνο περιβάλλον, έξυπνη κινητικότητα, έξυπνα κτίρια, έξυπνη διακυβέρνηση, έξυπνη διαβίωση, και έξυπνη οικονομία και κοινωνία [277]. Η παρούσα εργασία, εστιάζει στους τομείς του έξυπνου περιβάλλοντος και της

έξυπνης κινητικότητας, οι οποίοι έχουν επιδείξει μεγάλη αποδοχή μεθόδων Βαθιάς Μηχανικής Μάθησης, όπως παρουσιάζεται στον Πίνακα 3.1. Συγκεκριμένα, αναλύονται έξι σημαντικές εφαρμογές: η ποιότητα του αέρα, η διαχείριση της ποιότητας του νερού, της ενεργειακής ζήτησης στο πλαίσιο του έξυπνου περιβάλλοντος, της πληρότητας των χώρων στάθμευσης, της παρακολούθηση της κυκλοφοριακής ροής και της ροής επιβατών στο πεδίο της έξυπνης κινητικότητας.

Άρθρο	Πεδίο	Τύποι Δεδομένων	Αλγόριθμοι Βαθιάς Μηχανικής Μάθησης	Τομέας Έξυπνης Πόλης
[129]	ML + DL	Χρονοσειρές, Εικόνες	RNN	Περιβάλλον, Κινητικότητα, Ζωή
[266]	ML + DL	Χρονοσειρές, Εικόνες	-	Περιβάλλον
[29]	DL	Χρονοσειρές, Εικόνες, Κείμενο	CNN, RNN, Hybrid	Περιβάλλον, Κινητικότητα, Κτίρια, Ζωή
[70]	DL	Χρονοσειρές, Εικόνες, Κείμενο	CNN, RNN, Hybrid	Περιβάλλον, Κινητικότητα, Ζωή
[271]	DL	Χρονοσειρές, Εικόνες, Κείμενο	CNN, RNN, Hybrid	Περιβάλλον, Κινητικότητα, Ζωή
Η παρούσα εργασία	DL	Χρονοσειρές	CNN, RNN, Attention, GNN, Hybrid	Περιβάλλον, Κινητικότητα

Πίνακας 3.1: Σύγκριση σημαντικών ερευνητικών εργασιών.

Η δομή αυτού του κεφαλαίου οργανώνεται σε δύο ενότητες: Την ενότητα 3.1 που διερευνά τις εφαρμογές των μοντέλων αυτών στις περιοχές του έξυπνου περιβάλλοντος και της έξυπνης κινητικότητας, εξετάζοντας τα χαρακτηριστικά, την

δημοτικότητα και την αποτελεσματικότητά τους. Καθώς και την ενότητα 3.2 που επισημαίνει τις προκλήσεις και τους περιορισμούς της σχετικής βιβλιογραφίας, παρέχοντας μια βάση για τη συζήτηση πάνω στις μελλοντικές κατευθύνσεις.

3.1 Εφαρμογές στο Πλαίσιο των Έξυπνων Πόλεων

Στην ενότητα αυτή, εξετάζονται μελέτες που εφαρμόζουν αλγόριθμους Βαθιάς Μηχανικής Μάθησης, σε προβλήματα πρόβλεψης πολυμεταβλητών χρονοσειρών στο πλαίσιο των έξυπνων πόλεων. Ο όρος «Έξυπνη Πόλη» αναφέρεται σ' ένα προηγμένο αστικό πλαίσιο, τεχνολογικά ενισχυμένο, με σκοπό την αντιμετώπιση των σύγχρονων προκλήσεων, που παρουσιάζονται από την κλιματική αλλαγή και την αυξανόμενη αστικοποίηση. Οι Έξυπνες Πόλεις, προβλέπουν ένα τεχνολογικά προηγμένο μέλλον, όπου οι τεχνολογικές καινοτομίες και οι διασυνδεδεμένες έξυπνες λύσεις, θα παρέχουν αυξημένη αποδοτικότητα πόρων, βιωσιμότητα, οικονομική ανάπτυξη, και βελτιωμένη ποιότητα ζωής [299]. Στην ενότητα λοιπόν, αυτή, αναδεικνύονται έξι βασικοί τομείς στο πεδίο των Έξυπνων Πόλεων: ποιότητα αέρα, πληρότητα χώρων στάθμευσης, διαχείριση ενεργειακής ζήτησης, ροή επιβατών, ροή κυκλοφορίας και ποιότητα νερού.

3.1.1 Ποιότητα Αέρα

Η ανάπτυξη της βιομηχανίας, η αστικοποίηση και η αυξημένη κυκλοφορία έχουν οδηγήσει σε σημαντική μείωση της ποιότητας του αέρα, επηρεάζοντας αρνητικά την ανθρώπινη υγεία και την περιβαλλοντική βιωσιμότητα, ιδίως στις ανεπτυγμένες χώρες. Επομένως, η βελτίωση της ποιότητας αέρα αποτελεί πρωταρχικό στόχο στην ανάπτυξη έξυπνων πόλεων. Οι κύριοι ρύποι που συμβάλουν στην ατμοσφαιρική ρύπανση, περιλαμβάνουν το μονοξείδιο του άνθρακα (CO), το διοξείδιο του αζώτου (NO₂), το διοξείδιο του θείου (SO₂), το όζον (O₃) και τα σωματίδια (PM₁₀ και PM_{2.5}). Στη σύγχρονη εποχή, τα δεδομένα ποιότητας του αέρα σε πραγματικό χρόνο, καταγεγραμμένα από αισθητήρες, είναι ευρέως διαθέσιμα μέσω διεπαφών προγραμματισμού εφαρμογών (API). Η διαθεσιμότητα αυτή ευνοεί την ταχεία ανάπτυξη και τον πειραματισμό με προγνωστικά μοντέλα, τα οποία μπορούν να προσφέρουν προηγμένες προβλέψεις για περιβαλλοντικές

τάσεις. Αυτό διευκολύνει την πρόληψη επικίνδυνων συμβάντων και τον σχεδιασμό μέτρων μείωσης, συμβάλλοντας στη διατήρηση υψηλών ποιοτικών προτύπων της ατμοσφαιρικής ποιότητας σε αστικά περιβάλλοντα [420]. Στον τομέα της πρόβλεψης ποιότητας αέρα με χρήση Βαθιάς Μηχανικής Μάθησης, τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα, όπως RNN, LSTM και GRU, κυριαρχούν στην ανασκόπηση της βιβλιογραφίας, ενώ οι πιο πρόσφατες μελέτες ενσωματώνουν επίσης τον Μηχανισμό Προσοχής. Τα τελευταία χρόνια υπάρχουν πολλές μελέτες, που χρησιμοποιούν τέτοια μοντέλα, είτε αυτόνομα είτε σε υβριδικά περιβάλλοντα με άλλα μοντέλα όπως CNN.

Σχετικά με τις προσεγγίσεις Επαναλαμβανόμενων Νευρωνικών Δικτύων, στο [118] αναπτύχθηκε ένα μοντέλο LSTM, το οποίο χρησιμοποίησε δεδομένα πολυμεταβλητών χρονοσειρών, που περιλάμβαναν χημικές και μετεωρολογικές παραμέτρους, καταγεγραμμένες από έναν σταθμό παρακολούθησης ποιότητας αέρα. Επίσης τα LSTM χρησιμοποιήθηκαν στο [98], όπου προτάθηκε μια αρχιτεκτονική αλληλουχίας, σε αλληλουχία βασισμένη σε LSTM για τη διαχείριση των δυναμικών, χωροχρονικών και μη γραμμικών χαρακτηριστικών των πολυμεταβλητών δεδομένων ποιότητας αέρα. Αντίστοιχες μελέτες που υιοθετούν LSTM για τη μοντελοποίηση των επιπέδων ατμοσφαιρικής ρύπανσης περιλαμβάνουν [31, 12, 369, 89, 349], ενώ στο [104], προτάθηκαν επίσης GRU. Το πρόβλημα των δεδομένων ποιότητας αέρα που λείπουν, αντιμετωπίστηκε στο [117], σχεδιάζοντας ένα πλαίσιο βασισμένο σε LSTM. Η έλλειψη χαρακτηριστικών με επίγνωση του πλαισίου σε πολλές μελέτες μοντελοποίησης ποιότητας αέρα, επισημάνθηκε και αντιμετωπίστηκε, με το σχεδιασμό ενός συστήματος ποιότητας αέρα βασισμένου σε LSTM με επίγνωση του περιβάλλοντος. Στο [143], ενσωματώθηκαν γνώσεις ενός συγκεκριμένου τομέα σε GRU με τη μορφή μιας κανονικοποιημένης συνάρτησης απώλειας για τη βελτίωση των προβλέψεων ποιότητας αέρα. Μια αρχιτεκτονική πολλαπλών εργασιών (multi-task), πολλαπλών καναλιών (multi-channel), εμφωλευμένη (nested) LSTM προτάθηκε για την ταυτόχρονη πρόβλεψη διαφορε-

τικών στοιχείων ποιότητας αέρα στο [186]. Το πρόβλημα της ποιότητας του αέρα σε εσωτερικούς χώρους, εξετάστηκε επίσης μέσω της χρήσης Επαναλαμβανόμενων Νευρωνικών Δικτύων, με LSTM και GRU ν' αναπτύσσονται στο [103], χρησιμοποιώντας πολλαπλούς δείκτες μικροκλίματος εσωτερικών χώρων, με GRU να δείχνουν υψηλότερη απόδοση.

Ένας δημοφιλής τρόπος, για τη βελτίωση των Επαναλαμβανόμενων Νευρωνικών Δικτύων, είναι η ενσωμάτωση του Μηχανισμού Προσοχής. Στο [240], μετά την αναγνώριση των περιορισμών των απλών επαναλαμβανόμενων αρχιτεκτονικών, στην πρόβλεψη ποιότητας αέρα, αναπτύχθηκε ένα μοντέλο Αλληλουχίας, σε αλληλουχία, βασισμένο στην Προσοχή, χρησιμοποιώντας ενσωματώσεις θέσης (positional embeddings) για βελτίωση. Ο Μηχανισμός Προσοχής, έχει επίσης χρησιμοποιηθεί σε περαιτέρω μελέτες: στο [102], συνδυάστηκε με αμφίδρομα LSTM, για την παροχή εύρωστων προβλέψεων και καλύτερης διαχείρισης τιμών που λείπουν, ενώ στο [73], συνδυάστηκε με αμφίδρομα GRU, για να επιτρέψει αμφίδρομη μετάδοση πληροφοριών με μικρότερο υπολογιστικό κόστος. Η προσθήκη χωροχρονικής προσοχής, σε αρχιτεκτονική κωδικοποιητή-αποκωδικοποιητή (encoder-decoder) LSTM, παρουσιάστηκε στο [441], όπου χρησιμοποιήθηκαν χρονοσειριακά δεδομένα σε συνδυασμό με μη χρονοσειριακά δεδομένα και χωρικές πληροφορίες, για την καταγραφή εξαρτήσεων και στους δύο τομείς. Πρόσφατα ένα μοντέλο βασισμένο σε Διπλή Προσοχή, δοκιμάστηκε σε πολλά πολυμεταβλητά σύνολα δεδομένων, συμπεριλαμβανομένης της ποιότητας αέρα στο [315].

Ένας άλλος τρόπος για τη βελτίωση της απόδοσης των μοντέλων, είναι οι Υβριδικές Προσεγγίσεις, που αναπτύχθηκαν για την πρόβλεψη της ποιότητας του αέρα. Οι πιο δημοφιλείς από αυτές, συνδυάζουν τα CNN με παραλλαγές Επαναλαμβανόμενων Νευρωνικών Δικτύων (RNN), ενώ κάποιες ενσωματώνουν επιπλέον τον Μηχανισμό Προσοχής. Η βασική ιδέα πίσω από τον συνδυασμό των CNN με LSTM, είναι η μοντελοποίηση των πολυμεταβλητών χρονοσειρών,

ως ακολουθίες χωροχρονικών εικόνων [338]. Επιπρόσθετα, ενώ τα LSTM είναι ικανά να συλλάβουν τις μακροχρόνιες ιστορικές χρονικές εξαρτήσεις, δυσκολεύονται στη μάθηση των αλληλεξαρτήσεων σε πολυμεταβλητά δεδομένα χρονοσειρών, ενώ τα CNN μπορούν να μάθουν αυτές τις σχέσεις αποτελεσματικά. Το μέγεθος του πυρήνα των CNN, μπορεί να ρυθμιστεί για την εκμάθηση σχέσεων, που αντικατοπτρίζουν είτε στενότερες είτε ευρύτερες δεδομένες εξαρτήσεις [298]. Περαιτέρω μελέτες που υιοθετούν τον συνδυασμό CNN–LSTM, περιλαμβάνουν τις [230, 44, 131]. Σε ορισμένες μελέτες, οι απλές εκδόσεις των RNN, αντικαταστάθηκαν με τις αμφίδρομες εκδόσεις τους, όπως αμφίδρομα LSTMs [100, 337, 136] ή αμφίδρομα GRU [367], παρέχοντας τη δυνατότητα διπλής κατεύθυνσης επεξεργασίας δεδομένων. Οι πιο πρόσφατες υβριδικές μέθοδοι, βασισμένες στον συνδυασμό CNN–(Bi)LSTM, έχουν επίσης συνδυαστεί με τον Μηχανισμό Προσοχής για ακόμη μεγαλύτερη βελτίωση της απόδοσης και ερμηνευτικότητας του μοντέλου [229, 262].

Στον Πίνακα 3.2, συνοψίζονται οι προαναφερθείσες μελέτες Βαθιάς Μηχανικής Μάθησης, που αφορούν την πρόβλεψη ποιότητας αέρα και τα χαρακτηριστικά που ενσωματώνονται στις αντίστοιχες αρχιτεκτονικές τους. Η πρόβλεψη της ποιότητας του αέρα, εμπλέκει περίπλοκες αλληλεπιδράσεις μεταξύ πολλαπλών ρύπων και εξωτερικών παραγόντων, όπως οι μετεωρολογικές συνθήκες, οι βιομηχανικές εκπομπές και τα κυκλοφοριακά μοτίβα. Τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNN) και οι παραλλαγές τους, επικρατούν στην σχετική βιβλιογραφία, τόσο ως ανεξάρτητα μοντέλα όσο και ως συστατικά υβριδικών συστημάτων, λόγω της ικανότητάς τους να καταγράφουν μακροχρόνιες σχέσεις, ιδίως με την ενσωμάτωση του Μηχανισμού Προσοχής. Η χρήση πολλαπλών μεταβλητών, συμπεριλαμβανομένων εξωγενών παραγόντων, όπως τα μετεωρολογικά δεδομένα, μπορεί να βελτιώσει σημαντικά την ακρίβεια των προβλέψεων. Επιπλέον, η ένταξη των δικτύων CNN δύναται να είναι επωφέλης σε σενάρια που αφορούν πολλαπλούς μετρητικούς σταθμούς ή τοποθεσίες, διότι τα CNN είναι

ιδιαίτερα αποτελεσματικά στην ανάλυση των χωρικών πληροφοριών.

Έτος	Άρθρο	Συστατικά	Δεδομένα	Συγκρίθηκε Έναντι
2018	[118]	LSTM	Αισθητήρες IoT στο Κουβέιτ	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2018	[98]	LSTM	Δεδομένα PM2.5 του Πεκίνου	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2018	[31]	LSTM	Σετ Δεδομένων Αισθητήρων DHT11 και MQ135	Χωρίς συγκρίσεις
2018	[240]	GRU Attention	Σταθμοί Olympic και Dongsi στο Πεκίνο, Κίνα	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2018	[298]	CNN LSTM	Σταθμοί παρακολούθησης ποιότητας αέρα και Μετεωρολογικοί Σταθμοί στο Πεκίνο	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2019	[12]	LSTM	Επίπεδα καιρού και ρύπανσης από επίγειους σταθμούς και δορυφορικούς αισθητήρες στη Μαδρίτη, Ισπανία	Χωρίς συγκρίσεις

2019	[103]	GRU	Σετ δεδομένων SML2010	Μοντέλα βαθιάς μάθησης
2019	[369]	LSTM	Δεδομένα ρύπανσης και Μετεωρολογικά Δεδομένα από σταθμό παρακολούθησης αέρα στο Chokchai, Ταϊλάνδη	Παραδοσιακά
2019	[102]	BiLSTM Attention	Δεδομένα σταθμού παρακολούθησης ποιότητας αέρα από το Central Pollution Control Board στο Δελχί, Ινδία	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2019	[100]	CNN BiLSTM	Αστικό σετ δεδομένων ποιότητας αέρα	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2019	[367]	CNN BiGRU	Δεδομένα PM2.5 του Πεκίνου	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2020	[89]	LSTM	Σταθμοί παρακολούθησης στο Upper Hunter, Αυστραλία	Χωρίς συγκρίσεις

2020	[117]	LSTM	Δεδομένα PM2.5 του Πεκίνου, Ιταλικό σετ δεδομένων ποιότητας αέρα, Πολυτοπικό σετ δεδομένων ποιότητας αέρα του Πεκίνου	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2020	[143]	GRU Attention	KDD Cup of Fresh Air (Πεκίνο, Κίνα), Met Office (Λονδίνο, ΗΒ)	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2020	[73]	BiGRU Attention	Εθνική πλατφόρμα πραγματικού χρόνου ποιότητας αέρα της Κίνας στην πόλη Xining, επαρχία Qinghai, Κίνα	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2020	[338]	CNN LSTM	Πραγματικό σετ δεδομένων ρύπανσης από το Ελεγκτικό Συμβούλιο για τρεις σταθμούς παρακολούθησης στην πόλη Bhubaneswar, πολιτεία Odisha, Ινδία	Μοντέλα Βαθιάς Μηχανικής Μάθησης

2020	[230]	CNN LSTM	Δεδομένα PM2.5 του Πεκίνου	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2020	[229]	CNN LSTM Attention	Σταθμοί παρακολούθησης ποιότητας αέρα στην πόλη Taiyuan, Κίνα	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2021	[186]	LSTM	Πολυτοπικό σετ δεδομένων ποιότητας αέρα του Πεκίνου	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2021	[349]	LSTM	Αισθητήρες IoT στην Ινδία	Χωρίς συγκρίσεις
2021	[104]	LSTM, GRU	Σταθμοί παρακολούθησης από το Wrocław, Πολωνία	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2021	[441]	LSTM Attention	Σταθμοί παρακολούθησης από το Πεκίνο, Κίνα	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2021	[44]	CNN LSTM	Πολυτοπικό σετ δεδομένων ποιότητας αέρα του Πεκίνου	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2021	[337]	CNN BiLSTM	Σταθμοί παρακολούθησης στην πολιτεία Odisha, Ινδία	Παραδοσιακά

2022	[315]	LSTM Attention	Δεδομένα PM2.5 του Πεκίνου, Πολυτοπικό σετ δεδομένων ποιότητας αέρα του Πεκίνου	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2022	[131]	CNN LSTM	Αισθητήρες στη Βαρκελώνη, Ισπανία και στο Kocaeli και Ιστανμπούλ, Τουρκία	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2022	[136]	CNN BiLSTM	Δεδομένα PM2.5 του Πεκίνου	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2022	[262]	CNN BiLSTM Attention	Σταθμοί παρακολούθησης στη Νότια Κορέα	Μοντέλα Βαθιάς Μηχανικής Μάθησης

Πίνακας 3.2: Πρόσφατες μελέτες Βαθιάς Μηχανικής Μάθησης για την πρόβλεψη της ποιότητας του αέρα. Ο πίνακας περιλαμβάνει τις προτεινόμενες αρχιτεκτονικές, τα δεδομένα που χρησιμοποιήθηκαν και τους τύπους μοντέλων με τους οποίους συγκρίθηκε η προτεινόμενη μέθοδος. Το «|» υποδηλώνει ότι οι αλγόριθμοι χρησιμοποιήθηκαν ως μέρος ενός υβριδικού συστήματος. Το «,» υποδεικνύει ότι οι αλγόριθμοι χρησιμοποιήθηκαν ξεχωριστά.

3.1.2 Πληρότητας Χώρων Στάθμευσης

Τα υψηλά επίπεδα ρύπανσης και ο σημαντικός αριθμός οχημάτων στους δρόμους των πόλεων, έχουν αναδείξει την ανεπάρκεια των υφιστάμενων πολιτικών, για βιώσιμη διαχείριση της αστικής κυκλοφορίας. Έχουν αναπτυχθεί έξυπνα συστήματα στάθμευσης, βασισμένα στο IoT για τη μετρίαση του προβλήματος, επιτρέποντας στους οδηγούς να αποφεύγουν τους περιττούς γύρους, με απο-

τελέσμα την μείωση κατανάλωσης καυσίμων και τις εκπομπές καυσαερίων [313]. Τα περισσότερα έξυπνα συστήματα στάθμευσης χρησιμοποιούν τα RNN [61] και τις παραλλαγές τους όπως τα LSTM και GRU. Τα Μοντέλα αυτά έχουν αποδειχθεί ότι παράγουν αυξημένη απόδοση όταν χρησιμοποιούνται μαζί με εξωγενείς πηγές δεδομένων, όπως δεδομένα καιρού [225, 25, 207, 62], σχετικά με σημεία ενδιαφέροντος (POI), δεδομένα κινητικότητας χάρτη [328], δεδομένα κυκλοφορίας [139] και πληροφορίες τοποθεσίας [184]. Με παρόμοια λογική, προτάθηκε μια αρχιτεκτονική CNN [318] με την προσθήκη δεδομένων συναλλαγών.

Για την ενίσχυση της απόδοσης, αναπτύχθηκαν υβριδικές αρχιτεκτονικές, όπως CNN-LSTM [313, 40, 189] και στοιβαγμένα (stacked) δίκτυα GRU-LSTM [422]. Πιο προχωρημένες μελέτες συμπεριλαμβάνουν την ενσωμάτωση συνελίξεων γραφημάτων με LSTM για την καταγραφή χωρικών και χρονικών μοτίβων της πληρότητας χώρων στάθμευσης σε επίπεδο τετραγώνου [411], καθώς και η σύνθεση ενός Συνελικτικού Δικτύου Γραφημάτων, ενός κανονικού Συνελικτικού Δικτύου και ενός Μηχανισμού Προσοχής, για τη μοντελοποίηση των χωρικών συσχετίσεων, μετρώντας την ομοιότητα των κατανομών διάρκειας στάθμευσης [405].

Ο Πίνακας 3.3 παρέχει μια συγκεντρωτική επισκόπηση των κυριότερων ερευνών στον τομέα της Βαθιάς Μηχανικής Μάθησης για την πρόβλεψη πληρότητας των χώρων στάθμευσης και των αλγορίθμων που ενσωματώνονται στις αντίστοιχες αρχιτεκτονικές τους. Η κατάληψη των χώρων στάθμευσης, επηρεάζεται από μια σειρά παραγόντων, όπως η ανθρώπινη συμπεριφορά και η διαθεσιμότητα δεδομένων σε πραγματικό χρόνο, εκδηλώνοντας συχνά καθημερινά και εβδομαδιαία μοτίβα. Τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα και οι παραλλαγές τους, είναι ιδιαίτερα κατάλληλα για την αντιμετώπιση αυτών των χρονικών διακυμάνσεων. Ωστόσο, σε περιπτώσεις με έντονες χωρικές εξαρτήσεις ή σύνθετα δίκτυα στάθμευσης, ο συνδυασμός τους με CNN ή GNN μπορεί να προσφέρει πρόσθετα οφέλη, επιτρέποντας την αποτελεσματική αποτύπωση και των

δύο διαστάσεων. Επιπλέον, η ενσωμάτωση εξωγενών μεταβλητών, όπως καιρικές συνθήκες, αργίες, ημέρες της εβδομάδας, ώρες της ημέρας, κυκλοφοριακές συνθήκες και τοπικά συμβάντα, μπορούν να ενισχύσουν σημαντικά την απόδοση του μοντέλου.

Έτος	Άρθρο	Συστατικά	Δεδομένα	Συγκρίθηκε Έναντι
2018	[61]	RNN	Δεδομένα πληρότητας πάρκινγκ από το Birmingham	Παραδοσιακά
2018	[114]	LSTM	Αισθητήρες IoT στο St. Petersburg, Ρωσία	Χωρίς συγκρίσεις
2018	[344]	LSTM	Σετ δεδομένων Melbourne	Μοντέλα βαθιάς μάθησης
2018	[225]	LSTM	Αισθητήρες IoT στο Sanlitun, Beijing, Κίνα	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2018	[328]	LSTM	Αισθητήρες IoT στο Beijing και Shenz, Κίνα	Παραδοσιακά
2019	[207]	LSTM	Σετ δεδομένων Melbourne, σετ δεδομένων Kansas City	Παραδοσιακά
2019	[25]	GRU	Αισθητήρες IoT στο Riyadh, Σαουδική Αραβία	Χωρίς συγκρίσεις

2019	[411]	GCN LSTM	Αισθητήρες IoT στο Pittsburgh, Ηνωμένες Πολιτείες	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2020	[21]	LSTM	Αισθητήρες IoT στο Aarhus, Δανία	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2020	[13]	LSTM	Δεδομένα πληρότητας πάρκινγκ από το Birmingham	Χωρίς συγκρίσεις
2020	[318]	CNN	Αισθητήρες IoT στο Arnhem, Ολλανδία	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2021	[313]	CNN LSTM	Αισθητήρες IoT στην περιοχή Campania, Ιταλία	Παραδοσιακά
2021	[40]	CNN LSTM	Δεδομένα πληρότητας πάρκινγκ από το Birmingham, αισθητήρες IoT στο Mantova, Ιταλία	Μοντέλα Βαθιάς Μηχανικής Μάθησης

2021	[405]	GCN CNN Attention	Σετ δεδομένων θέσεων πάρκινγκ στον δρόμο του Melbourne, σετ δεδομένων θέσεων πάρκινγκ στον δρόμο του Melbourne	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2022	[62]	GRU	Σετ δεδομένων ISPARK	Μοντέλα Βαθιάς Μηχανικής Μάθησης
2022	[139]	LSTM	Δεδομένα πληρότητας πάρκινγκ από το Birmingham, δεδομένα αισθητήρων πάρκινγκ στον δρόμο—2018	Χωρίς συγκρίσεις
2022	[184]	LSTM	Δημόσιο σετ δεδομένων Melbourne	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης
2022	[189]	CNN LSTM	Ιδιωτικό σετ δεδομένων	Παραδοσιακά και Μοντέλα Βαθιάς Μηχανικής Μάθησης

2022	[422]	GRU LSTM	Αισθητήρες IoT στο Chongqing, Κίνα	Παραδοσιακά
------	-------	------------	---------------------------------------	-------------

Πίνακας 3.3: Πρόσφατες μελέτες Βαθιάς Μηχανικής Μάθησης για την πρόβλεψη της πληρότητας χώρων στάθμευσης. Ο πίνακας περιλαμβάνει τις προτεινόμενες αρχιτεκτονικές, τα δεδομένα που χρησιμοποιήθηκαν και τους τύπους μοντέλων με τους οποίους συγκρίθηκε η προτεινόμενη μέθοδος.

3.1.3 Διαχείριση Ενεργειακής Ζήτησης

Η κατανάλωση ενέργειας και το περιβαλλοντικό αποτύπωμα των αστικών περιοχών, αποτελούν σημαντικά κοινωνικά ζητήματα, με τις πόλεις να κατανalώνουν περίπου το 75% της παγκόσμιας ενέργειας, τάση που αναμένεται να ενταθεί λόγω της αυξανόμενης αστικοποίησης [331]. Οι παράγοντες που επηρεάζουν τη ζήτηση ενέργειας είναι πολλοί και ποικίλοι, εκ των οποίων κάποιοι εμφανίζουν επαναλαμβανόμενα μοτίβα όπως εορτές, εποχικότητα και χρονικές περίοδοι εντός μιας ημέρας, ενώ άλλοι μπορεί να διαφέρουν σημαντικά μεταξύ διαφορετικών πληθυσμιακών ομάδων ή τοποθεσιών. Καιρικές συνθήκες, οικονομικές καταστάσεις, δραστηριότητες σε εσωτερικούς και εξωτερικούς χώρους, πολιτικές αγοράς ηλεκτρικής ενέργειας, ανάμεσα σε άλλα, παίζουν σημαντικό ρόλο στην κατανάλωση ενέργειας. Η συλλογή και ανάλυση δεδομένων από αισθητήρια δίκτυα στο πλαίσιο των Έξυπνων Πόλεων, αυξάνει την πολυπλοκότητα της πρόβλεψης της ενεργειακής ζήτησης, επισημαίνοντας την ανάγκη για έξυπνα, αυτοματοποιημένα και βελτιστοποιημένα συστήματα διαχείρισης ενέργειας. Οι ακριβείς προβλέψεις βοηθούν στον καλύτερο σχεδιασμό, διανομή και βελτιστοποίηση, συμβάλλοντας στη βελτίωση της αξιοπιστίας των ενεργειακών συστημάτων και της αποτελεσματικότητας των συστημάτων διαχείρισης φορτίου, παράλληλα με θετικό περιβαλλοντικό αντίκτυπο [107].

Η βιβλιογραφία περί πρόβλεψης ενεργειακού φορτίου με χρήση Βαθιάς Μηχανικής Μάθησης, είναι πλούσια και πολυδιάστατη, με τα LSTM Νευρωνικά

Δίκτυα, να κατέχουν σημαντικό ρόλο σε διάφορα σενάρια πρόβλεψης ζήτησης ηλεκτρικής ενέργειας [137, 161, 339], όπως σε νοικοκυριά [319], βραχυπρόθεσμα φορτία [353], καθώς και σε κτίρια [307]. Εξωγενείς χρονικές και περιβαλλοντικές μεταβλητές, όπως η ηλιακή φωταύγεια, η υγρασία, η πίεση, το σημείο δρόσου, η θερμοκρασία και η ταχύτητα του ανέμου, έχουν αποδειχθεί χρήσιμες για τη βελτίωση της ακρίβειας των προβλέψεων. Η μελέτη των Ke et al. [193] εισήγαγε ένα βήμα αυτόματης κωδικοποίησης πριν τη χρήση δικτύων GRU για την πρόβλεψη ηλεκτρικού φορτίου, ενώ για την κατανάλωση φυσικού αερίου, η ανάλυση μοναδικού φάσματος (singular spectrum analysis) υπήρξε προεπεξεργαστικό βήμα στη μελέτη των Wei et al. [388]. Στην έρευνα του Du et al. [101], εφαρμόστηκε μια αρχιτεκτονική κωδικοποιητή-αποκωδικοποιητή βασισμένη σε BiLSTM για την πρόβλεψη οικιακής κατανάλωσης ηλεκτρικής ενέργειας.

Ενώ τα Convolutional Neural Networks (CNN), δεν είναι τόσο διαδεδομένα όσο τα RNN, στον τομέα της πρόβλεψης κατανάλωσης ενέργειας, έχουν αποδειχθεί ότι προσφέρουν ανταγωνιστικές επιδόσεις. Τα CNN, χρησιμοποιήθηκαν για βραχυπρόθεσμη πρόβλεψη φορτίου [375, 414] και για την πρόβλεψη της υψηλότερης τιμής του φορτίου [169], επιδεικνύοντας την ικανότητά τους ν' αναγνωρίζουν σύνθετα χαρακτηριστικά και μοτίβα μέσα από τις χρονοσειρές δεδομένων ενέργειας.

Τα CNN παρά την λιγότερη συχνότητα χρήσης τους, στην πρόβλεψη κατανάλωσης ενέργειας, έχουν αναδειχθεί σε δημοφιλή επιλογή σε υβριδικές αρχιτεκτονικές. Συχνά χρησιμοποιούνται ως στρώματα εξαγωγής χαρακτηριστικών, σε συνδυασμό με LSTM, για οικιακή κατανάλωση [198], βραχυπρόθεσμη πρόβλεψη φορτίου [244], κτίρια [352], με GRU για οικιακό φορτίο [335], έξυπνα πλέγματα [27] έξυπνα σπίτια [50] και σε πολλές περιπτώσεις, παράλληλα με BiLSTMs [218, 377] για οικιακή κατανάλωση [376] και έξυπνα κτίρια [49]. Τα υβρίδια συμπεριλαμβανομένων των CNN, βελτιώθηκαν περαιτέρω, με την ενσωμάτωση του Μηχανισμού Προσοχής για την πρόβλεψη οικιακού φορτίου [60, 23].

Επιπλέον, οι Ji et al. [177] πρότειναν ένα υβριδικό πλαίσιο βραχυπρόθεσμης πρόβλεψης φορτίου κατοικιών, το οποίο συνδυάζει ένα διευρυμένο CNN, για την εξαγωγή των μακροπρόθεσμων σχέσεων δεδομένων, ένα LSTM για την καταγραφή των χαρακτηριστικών ακολουθίας που κρύβονται στα εξαγόμενα χαρακτηριστικά, έναν αυτόματο κωδικοποιητή για την αποκωδικοποίηση τους σε χαρακτηριστικά εξόδου και τέλος έναν Μηχανισμό Προσοχής.

Στον Πίνακα 3.4, παρουσιάζεται μια ανασκόπηση των πρόσφατων μελετών, που εφαρμόζουν τεχνικές Βαθιάς Μηχανικής Μάθησης, στην πρόβλεψη ζήτησης ενέργειας, υπογραμμίζοντας τα συστατικά στοιχεία και τις προκλήσεις τους. Από την ανάλυση φαίνεται ότι τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNN) και οι παραλλαγές τους, όπως τα LSTM και τα GRU, επικρατούν στο πεδίο λόγω της ικανότητάς τους, να μοντελοποιούν μακροπρόθεσμες εξαρτήσεις στα δεδομένα χρονοσειρών. Η ενσωμάτωση του Μηχανισμού Προσοχής αποτελεί σημαντική βελτίωση, αυξάνοντας την ακρίβεια και την ερμηνευσιμότητα των προβλέψεων. Αντίθετα τα CNN, παρά τη μειωμένη χρήση τους ως αυτόνομα μοντέλα, βρίσκουν ευρεία εφαρμογή σε υβριδικές αρχιτεκτονικές, συμβάλλοντας στην εξαγωγή σύνθετων χαρακτηριστικών από τα δεδομένα. Οι μεταβλητές που παίζουν σημαντικό ρόλο περιλαμβάνουν καιρικές συνθήκες και τιμές ενέργειας, ενώ η εφαρμογή συνδυασμών τεχνικών, όπως CNN με RNN ή τον Μηχανισμό Προσοχής, φαίνεται να προσφέρει ιδιαίτερα υψηλές επιδόσεις.

Έτος	Άρθρο	Συστατικά	Δεδομένα	Συγκρίθηκε Έναντι
2018	[307]	LSTM	Δεδομένα αερίου από το κτίριο IBM B3 στο Εθνικό Εργαστήριο Lawrence Berkeley	Παραδοσιακά και Βαθιά Μηχανική Μάθηση

2019	[137]	LSTM	Δεδομένα Ηλεκτρικού Φορτίου από τη Λιουμπλιάνα, 2011	Χωρίς Συγκρίσεις
2019	[319]	LSTM	Σετ δεδομένων IHEPC	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[193]	GRU	Σετ Δεδομένων Βραχυπρόθεσμου Ηλεκτρικού Φορτίου	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[388]	LSTM	Σετ Δεδομένων Κατανάλωσης Αερίου του Λονδίνου, Χονγκ Κονγκ, Μελβούρνης και Καρδίτσας	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[198]	CNN LSTM	Σετ Δεδομένων Ηλεκτρικού Φορτίου	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[218]	CNN BiLSTM	Σετ Δεδομένων IHEPC	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[376]	CNN BiLSTM	Σετ Δεδομένων IHEPC	Βαθιά Μηχανική Μάθηση

2020	[375]	CNN	Σετ Δεδομένων Ρουμανικού Ενεργειακού Συστήματος	Χωρίς Συγκρίσεις
2020	[335]	CNN GRU	ΑΕΡ, ΙΗΕΡC	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2020	[60]	CNN LSTM Attention	ΙΗΕΡC	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2020	[101]	BiLSTM Attention	Πεκίνο PM25, Κατανάλωση Ενέργειας, Ποιότητα Αέρα Ιταλίας, Κυκλοφορία Αυτοκινητοδρόμων, PeMS-Bay	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2021	[161]	LSTM	ΑΕΡ, ΙΗΕΡC	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2021	[353]	LSTM	Σετ Δεδομένων Κατανάλωσης Ηλεκτρικής Ενέργειας Κτιρίων	Βαθιά Μηχανική Μάθηση

2021	[169]	CNN	Σετ Δεδομένων Ενεργειακού Συστήματος του Παναμά	Βαθιά Μηχανική Μάθηση
2021	[352]	CNN LSTM	Σετ Δεδομένων Κατανάλωσης Ενέργειας Κτιρίου KReSIT	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2021	[377]	CNN BiLSTM	Σετ Δεδομένων Κατανάλωσης Νοικοκυριών Τουρκίας	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2021	[49]	CNN BiLSTM	Σετ Δεδομένων Έξυπνου Σπιτιού με Πληροφορίες Καιρού	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2021	[244]	CNN LSTM	Ηλεκτρικό Φορτίο από Ισπανική Υπηρεσία	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2022	[339]	LSTM	Σετ Δεδομένων Κατανάλωσης Ενέργειας KEGOC	Παραδοσιακά
2022	[414]	CNN	Σετ Δεδομένων CK Bogazici Elektrik στην Κωνσταντινούπολη, Τουρκία	Βαθιά Μηχανική Μάθηση

2022	[50]	CNN GRU	Σετ Δεδομένων Κατανάλωσης Ηλεκτρικής Ενέργειας	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2022	[23]	CNN LSTM Attention	IHEPC	Βαθιά Μηχανική Μάθηση
2022	[177]	CNN LSTM Attention	IHEPC	Παραδοσιακά και Βαθιά Μηχανική Μάθηση

Πίνακας 3.4: Πρόσφατες Μελέτες Βαθιάς Μηχανικής Μάθησης γύρω από την πρόβλεψη της ζήτησης ενέργειας συμπεριλαμβανομένων των προτεινόμενων αρχιτεκτονικών, των δεδομένων που χρησιμοποιήθηκαν, και των τύπων μοντέλων με τους οποίους συγκρίθηκε η προτεινόμενη μέθοδος.

3.1.4 Ροή Επιβατών

Η ακριβής και έγκαιρη πρόβλεψη της Ροής Επιβατών σε δίκτυα μεταφορών, όπως μετρό και σταθμοί λεωφορείων, αποτελεί κρίσιμο στοιχείο για τη διαχείριση και τον σχεδιασμό της κυκλοφορίας, τη δημόσια ασφάλεια και την καθοδήγηση σε περιβάλλοντα Έξυπνων Πόλεων [145]. Αλγόριθμοι που βασίζονται στη Βαθιά Μηχανική Μάθηση, με την ικανότητα να συλλαμβάνουν τις χωροχρονικές δυναμικές από πολύπλοκες και μη γραμμικές πληροφορίες, έχουν τη δυνατότητα να βελτιώσουν σημαντικά αυτές τις προσπάθειες. Ωστόσο η αντιμετώπιση των χωρικών και χρονικών εξαρτήσεων πολλαπλών διασυνδεδεμένων στοιχείων, όπως η δομή των δικτύων αστικών μεταφορών και οι κανόνες ροής κυκλοφορίας, παραμένει σημαντική πρόκληση [309].

Τόσο τα LSTMs [144, 334] όσο και τα GRUs [370], έχουν εφαρμοστεί στην πολυμεταβλητή πρόβλεψη Ροής Επιβατών. Η απόδοση αυτών των μοντέλων έχει αποδειχθεί, ότι βελτιώνεται με τροποποιήσεις, όπως η συμπερίληψη εξωγενών με-

ταβλητών π.χ. δεδομένα καιρού [408, 241, 182]. Μελέτες που ενσωματώνουν τον Μηχανισμό Προσοχής [82, 438] έχουν επίσης αναφέρει βελτιώσεις στην απόδοση. Παρόμοια με την πρόβλεψη Ροής Κυκλοφορίας, η πρόβλεψη Ροής Επιβατών, είναι από τη φύση της ένα πρόβλημα που βασίζεται σε γραφήματα. Δεδομένου ότι τα δίκτυα μεταφορών, όπως οι στάσεις λεωφορείων και τρένων, διατηρούν ουσιαστικά μια δομή γραφήματος, η Ροή των Επιβατών, μοντελοποιείται καλύτερα χρησιμοποιώντας GNNs [180]. Έχοντας αυτό υπ' όψη τα GNN έχουν εφαρμοστεί για την πρόβλεψη της Ροής Επιβατών, σε διάφορα δίκτυα και ρυθμίσεις μεταφοράς [226, 145, 326]. Όσον αφορά τα Υβριδικά Μοντέλα, παρ' όλο που έχει εφαρμοστεί ο ευέλικτος συνδυασμός LSTM με CNN [407], η πλειονότητα αυτών των προσεγγίσεων προτιμά το συνδυασμό GCN με άλλες αρχιτεκτονικές, όπως Προσοχή [112, 111], CNNs [428], και GRUs [242].

Ο Πίνακας 3.5 συνοψίζει τις ερευνητικές μελέτες Βαθιάς Μηχανικής Μάθησης, σχετικά με τη Ροή Επιβατών και τους Αλγόριθμους, που χρησιμοποιούνται στις αρχιτεκτονικές τους. Η πρόβλεψη Ροής Επιβατών, εξαρτάται περισσότερο από συγκεκριμένα σενάρια και κάθε σενάριο απαιτεί μια πιο προσαρμοσμένη προσέγγιση. Πιο συγκεκριμένα, για την καταγραφή της Ροής Επιβατών στα αεροδρόμια, όπου η Ροή καθοδηγείται κυρίως από χρονικά μοτίβα, τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα, υπερέχουν καταγράφοντας ημερήσιες και ωριαίες διακυμάνσεις. Αντίθετα, στη συμφόρηση της δημόσιας συγκοινωνίας, ιδιαίτερα σε αστικές περιοχές, όπως η μοντελοποίηση εξαρτήσεων σε διάφορες στάσεις λεωφορείων, μπορεί κανείς να επωφεληθεί περισσότερο από τα CNN, που οριοθετούν αυτά τα χωρικά μοτίβα συμφόρησης. Σε περιπτώσεις πολύπλοκων διαμετακομιστικών κόμβων, που αποτελούνται από εκατοντάδες διασυνδεδεμένους σταθμούς, τα GNN λάμπουν, εκμεταλλευόμενα τις ιδιότητες του δικτύου. Τέλος η ενσωμάτωση εξωγενών μεταβλητών, όπως οι αργίες, οι καιρικές συνθήκες ή τα δρομολόγια των δημόσιων συγκοινωνιών, προσφέρουν σημαντικές πληροφορίες στην πρόβλεψη της Ροής Επιβατών.

Έτος	Άρθρο	Συστατικά	Δεδομένα	Συγκρίθηκε Έναντι
2018	[370]	GRU	Σύνολο Δεδομένων Σιδηροδρόμου, Μετρό και Τραμ της Ile-de-France	Παραδοσιακά
2018	[226]	GCN	Σύνολο Δεδομένων Μετρό του Πεκίνου	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[145]	GCN	Σύστημα Μετρό της Σαγκάης, Κίνα	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[144]	LSTM	Σύνολο Δεδομένων Δημόσιας Μεταφοράς της Qingdao	Παραδοσιακά
2019	[82]	LSTM Attention	Σύνολο Δεδομένων Κέντρου Συντονισμού Λειτουργιών Μεταφοράς του Πεκίνου, Κίνα	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[112]	GCN Attention	Σύνολα Δεδομένων Μετρό, Λεωφορείων και Ταξί του Πεκίνου	Βαθιά Μηχανική Μάθηση

2019	[326]	GCN	Σύνολο Δεδομένων Μετρό του Πεκίνου	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2020	[309]	GCN LSTM	Σύνολα Δεδομένων Μετρό, Λεωφορείων και Ταξί του Πεκίνου	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2020	[241]	LSTM	Σύνολο Δεδομένων Κυβέρνησης Πόλης της Ταϊπέι	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2020	[428]	GCN CNN	Σύνολο Δεδομένων Μετρό του Πεκίνου	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2020	[111]	GCN Attention	Σύνολα Δεδομένων Μετρό, Λεωφορείων και Ταξί του Πεκίνου	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2021	[334]	LSTM	Σύνολο Δεδομένων Kochi metro rail limited	Παραδοσιακά
2021	[408]	LSTM	Σύνολο Δεδομένων Διαγωνισμού Μεγάλων Δεδομένων Ali Tianchi στην Guangzhou, Κίνα	Παραδοσιακά
2021	[182]	LSTM	Σύνολο Δεδομένων Λεωφορείων του Πεκίνου	Βαθιά Μηχανική Μάθηση

2022	[407]	CNN LSTM	Σύνολο Δεδομένων Διεθνούς Αερολιμένα Guangzhou BAIYUN	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2022	[438]	CNN LSTM BiLSTM Attention	Δεδομένα Κάρτας Λεωφορείου στο Guangdong, Κίνα	Βαθιά Μηχανική Μάθηση
2022	[242]	GCN GRU	Σύνολα Δεδομένων HZMetro και SHMetro	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2022	[181]	LSTM Attention	Σύνολο Δεδομένων Συστήματος Μαζικής Μεταφοράς με Τρένο του Χονγκ Κονγκ (MTR)	Παραδοσιακά και Βαθιά Μηχανική Μάθηση

Πίνακας 3.5: Πρόσφατες μελέτες Βαθιάς Μηχανικής Μάθησης για την πρόβλεψη της Ροής Επιβατών, συμπεριλαμβανομένων των προτεινόμενων αρχιτεκτονικών, των δεδομένων που χρησιμοποιήθηκαν και των τύπων μοντέλων με τους οποίους συγκρίθηκε η προτεινόμενη μέθοδος.

3.1.5 Ροή Κυκλοφορίας

Η πρόβλεψη της Ροής Κυκλοφορίας, αναφέρεται στην πρόβλεψη της επόμενης κατάστασης της ροής ως προς τον όγκο, την ταχύτητα, την πυκνότητα ή την συμπεριφορά, βασισμένη σε ιστορικά ή ακόμα και πραγματικού χρόνου δεδομένα. Τέτοιες πληροφορίες μπορούν να βοηθήσουν σημαντικά στην αποφυγή δυσάρεστων καταστάσεων στους δρόμους όπως τα μποτιλιαρίσματα, τα οποία με τη σειρά τους ενδέχεται να οδηγήσουν σε αυξημένη κατανάλωση ενέργειας/καυσίμου και τεράστια εκπομπή ρύπων, όπου επηρεάζουν αρνητικά την υγεία και την ποιότητα ζωής των πολιτών [320].

Η πρόβλεψη της κυκλοφορίας είναι ένα δύσκολο πρόβλημα, κυρίως λόγω της πολύπλοκης χωρικής εξάρτησης από τα οδικά δίκτυα, της μη γραμμικής χρονικής δυναμικής με τις μεταβαλλόμενες συνθήκες του δρόμου και της εγγενούς δυσκολίας της μακροπρόθεσμης πρόβλεψης [231]. Ένας μεγάλος όγκος επιστημονικής βιβλιογραφίας σχετικά με την πρόβλεψη Ροής Κυκλοφορίας οχημάτων, χρησιμοποιώντας δεδομένα πολυμεταβλητών χρονοσειρών, περιλαμβάνει τη χρήση Επαναλαμβανόμενων Νευρωνικών Δικτύων όπως τα LSTM. Διάφορες μελέτες υιοθέτησαν την απλή μοντελοποίηση, LSTM [222, 248, 390, 209, 93, 250], ενώ άλλες προσπάθησαν να βελτιώσουν τα απλά Επαναλαμβανόμενα Νευρωνικά Δίκτυα, με περισσότερες πληροφορίες σχετικά με τις καιρικές συνθήκες ως εξωγενείς πηγές [424], δεδομένα ποιότητας αέρα [30], μοτίβα διάδοσης συμμόρφωσης [274] ή τροποποιημένες αρχιτεκτονικές όπως σταθμισμένα LSTMs [404], στοιβαγμένα LSTMs [267], και μοντέλα ακολουθίας σε ακολουθία [99].

Με την έλευση του Μηχανισμού Προσοχής, πραγματοποιήθηκαν περισσότερες εργασίες, οι οποίες χρησιμοποιούν αρχιτεκτονικές Επαναλαμβανόμενων Νευρωνικών Δικτύων, προσπαθώντας να εκμεταλλευτούν τον Μηχανισμό Προσοχής, για να βελτιώσουν την απόδοση και να κάνουν τις προτεινόμενες αρχιτεκτονικές πιο ερμηνεύσιμες. Στο [409], ο Μηχανισμός Προσοχής χρησιμοποιήθηκε σε συνδυασμό με δίκτυα LSTM, για να βοηθήσει στην καταγραφή τιμών υψηλής σημασίας σε πολύ μεγάλες ακολουθίες και την ενσωμάτωσή τους στο χρονικό βήμα ενδιαφέροντος, ενώ στη Ροή της Κυκλοφορίας, στην έρευνα [373] η παρέμβαση που προκλήθηκε από απροσδόκητα γεγονότα, όπως η πανδημία COVID-19, μοντελοποιήθηκε.

Οι προσεγγίσεις κυκλοφορίας-δάσωσης αγνόησαν τη γραφική φύση του προβλήματος, καθιστώντας τις υποβέλτιστες: ένα οδικό δίκτυο μπορεί να ερμηνευθεί ως γράφημα, με διασταυρώσεις ως κόμβους και οδικές συνδέσεις ως άκρα. Ως αποτέλεσμα τα τελευταία χρόνια, οι πιο προηγμένες και καλές μελέτες σχετικά με την πρόβλεψη της Ροής Κυκλοφορίας, έχουν επικεντρωθεί περισσότερο

στα GNN, λόγω της εγγενούς ικανότητάς τους να καταγράφουν σχέσεις που βασίζονται σε γραφήματα [180].

Αν και τα GNN μπορούν να χρησιμοποιηθούν ως αυτόνομα μοντέλα, για την πρόβλεψη Ροής Κυκλοφορίας [354], οι περισσότερες προσεγγίσεις που βασίζονται σε γραφήματα, βασίζονται στο συνδυασμό GNN με άλλα μοντέλα, με αποτέλεσμα υβριδικές αρχιτεκτονικές. Για παράδειγμα, στο [440], τα GCN βελτιώθηκαν με τον Μηχανισμό Προσοχής, καθώς ένα δυναμικό GNN χρησιμοποιήθηκε για να ενσωματώσει πληροφορίες συσχέτισης στη χωρική δομή και αναπτύχθηκε ένα στοιχείο προσοχής πολλαπλών κεφαλών για να αποκαλύψει δυναμικά τις χρονικές σχέσεις. Επιπλέον μια νέα αρχιτεκτονική βασισμένη στο GNN, που ονομάζεται Συνελικτικό Επαναλαμβανόμενο Νευρωνικό Δίκτυο Διάχυσης (DCRNN), προτάθηκε στο [231], που συνδυάζει ένα Συνελικτικό Δίκτυο Γραφήματος και ένα Μοντέλο ακολουθίας σε ακολουθία που βασίζεται σε GRU. Το πρώτο χρησιμοποιήθηκε για την αποτύπωση των χωρικών σχέσεων, χρησιμοποιώντας τυχαίους αμφίδρομους περιπάτους στο γράφημα, ενώ το δεύτερο ήταν σε θέση να μοντελοποιήσει τις χρονικές σχέσεις, χρησιμοποιώντας προγραμματισμένη δειγματοληψία, για να βελτιώσει τις μακροπρόθεσμες προβλέψεις. Ομοίως, οι Zhao et al. [436] συνδύασαν GCN με GRU, για να συλλάβουν χρονικές και χωρικές εξαρτήσεις ταυτόχρονα. Για περαιτέρω βελτίωση της απόδοσης των DCRNN, η έννοια του «Παράγοντα Επιρροής Κατάταξης» εισήχθη στο [165]. Η ιδέα είναι ότι η συμβολή των γειτονικών κόμβων μπορεί να προσαρμοστεί, με βάση την εγγύτητά τους στον κόμβο-στόχο. Σε μια νεότερη μελέτη [224], αναπτύχθηκε ένα παρόμοιο υβρίδιο CGN-GRU, που χρησιμοποιούσε μια γενετική μέθοδο, για τη μοντελοποίηση της τοπολογίας του δυναμικού γραφήματος σε κάθε χρονικό βήμα. Ένας ακόμη δημοφιλής τύπος υβριδίων που βασίζονται σε GNN, είναι αυτός του GCN-CNN. Στο [417] προτάθηκε ένα νέο πλαίσιο Βαθιάς Μηχανικής Μάθησης, για την πρόβλεψη της κυκλοφορίας που συνδυάζει περιφραγμένη χρονική συνέλιξη και συνέλιξη γραφήματος μέσω χωροχρονικών συνελικτικών μπλοκ.

Ομοίως, αφού έθιξε την αναποτελεσματικότητα των προσεγγίσεων που βασίζονται σε RNN για μεγάλες ακολουθίες και τα εκρηκτικά προβλήματα κλίσης, όταν τα RNN συγχωνεύονται με δίκτυα συνέλιξης γραφημάτων, ο Wu et al. [403] πρότεινε μια υβριδική μεθοδολογία CNN–GCN που ονομάζεται Graph WaveNet. Σύμφωνα με αυτή τη μεθοδολογία, δημιουργήθηκε ένας Αυτο - προσαρμοζόμενος πίνακας εξάρτησης, ικανός ν' αποκαλύπτει αυτόματα αόρατες γραφικές δομές και συνδυάζοντας τη γραφική συνέλιξη, με διευρυμένη περιστασιακή συνέλιξη καταγράφηκαν οι χωροχρονικές εξαρτήσεις. Για περαιτέρω βελτίωση της απόδοσης της αρχιτεκτονικής GCN–CNN, οι Guo et al. ενσωμάτωσε ένα Μηχανισμό Προσοχής σ' αυτό για να μάθει αποτελεσματικά τις δυναμικές χωροχρονικές συσχετίσεις στα δεδομένα κυκλοφορίας [138], ενώ στο [203], προστέθηκε ένα στρώμα Προσοχής, για να καταγράψει τις χωροχρονικές εξαρτήσεις και τη δυναμική δομή του γραφήματος την ίδια στιγμή. Περισσότερα υβρίδια που βασίζονται σε GNN, περιλαμβάνουν προσεγγίσεις που συνδυάζουν τα GCN με τα LSTM και τον Μηχανισμό Προσοχής. Στο [246], προτάθηκε μια αρχιτεκτονική Η η οποία αποτελείται από ένα κλιμακωτό LSTM και μια διαδικασία συνέλιξης διάχυσης με Μηχανισμό Προσοχής, για ν' αποκαλύψει τις χωροχρονικές σχέσεις των δεδομένων Ροής Κυκλοφορίας, παράλληλα με κοινωνικούς και οικονομικούς παράγοντες. Παρόμοια δομικά στοιχεία χρησιμοποιήθηκαν στο [416]; Ωστόσο, σε αυτή την περίπτωση, εισήχθησαν δύο Μηχανισμοί Προσοχής: 1. ένας εσωτερικός Μηχανισμός Προσοχής για την καταγραφή των συσχετίσεων μεταξύ των διαφορετικών χρονοσειρών. και 2. έναν δυναμικό Μηχανισμό Προσοχής που βασίζεται στη γειτνίαση για να συλλάβει τις περίπλοκες χωρικές σχέσεις και να αποκαλύψει πώς τα ετερογενή δεδομένα σε συγκεκριμένες τοποθεσίες επηρεάζουν άμεσα τις προβλέψεις. Άλλες αξιοσημείωτες αναφορές που χρησιμοποιούν υβριδικές προσεγγίσεις αλλά χωρίς χρήση GNN περιλαμβάνουν τα [437, 105, 195], όπου τα CNN συνδυάστηκαν με LSTMs, [332], όπου τα CNN συνδυάστηκαν με GRU, [419], [163, 382] και όπου αναπτύχθηκαν αρχιτεκτονικές CNN–LSTM βασι-

σμένες στην Προσοχή.

Μια συνοπτική εικόνα των εργασιών Βαθιάς Μηχανικής Μάθησης, που συζητήθηκαν σχετικά με τη Ροή Κυκλοφορίας, εμφανίζεται στον Πίνακα 3.6. Παρόμοια με την πρόβλεψη Ροής Επιβατών, η πρόβλεψη Ροής Κυκλοφορίας, βασίζεται στην αλληλεπίδραση μεταξύ χρονικών και χωρικών εξαρτήσεων, όπως αλληλεπιδράσεις οχημάτων, οδικές συνθήκες, σήματα κυκλοφορίας και γεγονότα σε πραγματικό χρόνο, όπως ατυχήματα ή κλείσιμο δρόμων. Τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα, είναι καλύτερα όταν κυριαρχούν πολύπλοκες χρονικές σχέσεις, καθιστώντας τα ιδανικά για σενάρια με επαναλαμβανόμενες καθημερινές ή ωριαίες διακυμάνσεις της κυκλοφορίας σε μεμονωμένους δρόμους. Δεδομένου του πόσο διασυνδεδεμένοι είναι οι δρόμοι σ' ένα πραγματικό σενάριο, τα GNN είναι μια πολύ πιο ρεαλιστική επιλογή, που θα πρέπει να χρησιμοποιηθεί τουλάχιστον συμπληρωματικά. Επιπλέον οι Μηχανισμοί Προσοχής, μπορούν να ενδυναμώσουν τα GNN, επιτρέποντάς τους να εστιάζουν σε ορισμένες κρίσιμες χωρικές σχέσεις και να συγκεντρώνουν επιλεκτικά πληροφορίες. Τα CNN αν και είναι επίσης αποτελεσματικά στην καταγραφή χωρικών εξαρτήσεων, δεν είναι τόσο ισχυρά όσο τα GNN σε σενάρια Ροής Κυκλοφορίας, λόγω της φύσης των δεδομένων. Εξωτερικοί παράγοντες που έχουν σημαντικό αντίκτυπο στην πρόβλεψη Ροής Κυκλοφορίας και ενσωματώνονται συχνά σε Μοντέλα Πρόβλεψης χρονοσειρών, αποτελούν οι καιρικές συνθήκες, αργίες, η ημέρα της εβδομάδας, η ώρα της ημέρας, προγράμματα δημόσιας συγκοινωνίας, τροχαία συμβάντα και μέτρα που σχετίζονται με κοινωνική απόσταση κατά τη διάρκεια πανδημιών.

Έτος	Άρθρο	Συστατικά	Δεδομένα	Συγκρίθηκε Έναντι
2018	[222]	LSTM	Σύνολο δεδομένων κυκλοφορίας από τη Σεούλ	Βαθιά Μηχανική Μάθηση
2018	[248]	LSTM	Σύνολο δεδομένων DPTI	Βαθιά Μηχανική Μάθηση
2018	[424]	GRU	PEMS	Παραδοσιακά
2018	[231]	GCN GRU	METR-LA, PEMS-BAY	Βαθιά Μηχανική Μάθηση
2018	[417]	GCN CNN	BJER4, PeMSD7	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[436]	GCN GRU	SZ-taxi dataset, Los-loop dataset	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[390]	LSTM	PEMS	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[99]	LSTM	Σύνολο δεδομένων κυκλοφορίας (Highways England)	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[409]	LSTM Attention	PEMS	Παραδοσιακά και Βαθιά Μηχανική Μάθηση

2019	[437]	LSTM CNN	Σύνολο Δεδομένων Κυκλοφορίας PEMS (Highways England)	Βαθιά Μηχανική Μάθηση
2019	[105]	LSTM CNN	Αισθητήρες IoT στο Stretford, Ηνωμένο Βασίλειο	Χωρίς συγκρίσεις
2019	[165]	GCN GRU	METRLA, PEMS-BAY, SZ-taxi	Βαθιά Μηχανική Μάθηση
2019	[403]	GCN CNN	METR-LA, PEMS-BAY	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2019	[138]	GCN CNN Attention	PeMSD4, PeMSD8	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2020	[63]	GCN CNN	METR-LA, PEMS-BAY, PEMS07, PEMS03, PEMS04, PEMS08	Βαθιά Μηχανική Μάθηση
2020	[209]	LSTM	PEMS	Χωρίς Συγκρίσεις
2020	[30]	LSTM	Δημόσια δεδομένα από τη Μαδρίτη, Ισπανία	Χωρίς συγκρίσεις
2020	[163]	LSTM CNN Attention	Σύνολο Δεδομένων Ταξί NYC	Παραδοσιακά και Βαθιά Μηχανική Μάθηση

2020	[354]	GCN	PEMS03, PEMS04, PEMS07, PEMS08	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2020	[246]	GCN LSTM Attention	METR-LA, PEMS-BAY	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2021	[93]	LSTM	Δημόσια Δεδομένα Κυκλοφορίας του Austin, Texas	Παραδοσιακά
2021	[250]	LSTM	Δεδομένα Κυκλοφορίας για το Buxton, Ηνωμένο Βασίλειο	Χωρίς Συγκρίσεις
2021	[274]	LSTM	PEMS	Παραδοσιακά
2021	[404]	LSTM	GPS Τροχιά Ταξί στο Πεκίνο	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2021	[373]	LSTM	Σύνολο Δεδομένων TPS	Βαθιά Μηχανική Μάθηση
2021	[195]	CNN LSTM	PEMS	Χωρίς Συγκρίσεις
2021	[382]	CNN LSTM Attention	PEMS	Χωρίς Συγκρίσεις
2021	[416]	GCN LSTM Attention	PeMSD4, PeMSD8	Παραδοσιακά και Βαθιά Μηχανική Μάθηση

2021	[224]	GCN GRU	METRLA, PEMS-BAY, NE-BJ	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2022	[267]	LSTM	Σύνολο Δεδομένων Περιοχής Barui pur στην Κολκάτα, Ινδία	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2022	[419]	LSTM GRU	Δεδομένα Κινούμενου Αυτοκινήτου	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2022	[203]	GCN CNN Attention	METRLA, PEMS-BAY	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2022	[440]	GCN Attention	PEMS03, PEMS04, PEMS07, PEMS08	Βαθιά Μηχανική Μάθηση

Πίνακας 3.6: Πρόσφατες μελέτες Βαθιάς Μηχανικής Μάθησης για την πρόβλεψη της Ροής της Κυκλοφορίας, συμπεριλαμβανομένων των προτεινόμενων αρχιτεκτονικών, των δεδομένων που χρησιμοποιήθηκαν και των τύπων μοντέλων με τους οποίους συγκρίθηκε η προτεινόμενη μέθοδος.

3.1.6 Ποιότητα Νερού

Χρησιμοποιώντας συσκευές και τεχνολογίες IoT, οι φορείς εκμετάλλευσης νερού έχουν την ευκαιρία να παρακολουθούν το δίκτυο ύδρευσης, σε πραγματικό χρόνο και ν' αποκτούν γνώσεις σχετικά με την ποιότητα και τις διαρροές νερού, την κατάσταση των στοιχείων της υποδομής και την κατανάλωση, για τη βελτιστοποίηση της χρήσης των πόρων, τη διασφάλιση της ποιότητας του πόσιμου νερού και βελτίωση των αποφάσεων διαχείρισης [301]. Πιο συγκεκριμένα, όσον αφορά την ποιότητα του νερού, ένα σύνολο καθορισμένων παραμέτρων μετράται, παρακολουθείται, αναλύεται και διατηρείται για διαχείριση σε πραγμα-

τικό χρόνο, ώστε να διασφαλίζεται η ποιότητα των επιφανειακών ή υπόγειων υδάτων. Στη συνέχεια τα συστήματα διαχείρισης ποιότητας του νερού, είναι επιφορτισμένα με την ερμηνεία και την ανάλυση των μετρήσεων των αισθητήρων και την ενημέρωση εάν οι μετρήσεις φτάσουν σε ανησυχητικά επίπεδα, όπως αποφασίστηκε από τους υπεύθυνους [322].

Οι περισσότερες μελέτες πρόβλεψης Ποιότητας Νερού, χρησιμοποιούν δίκτυα και υβρίδια που βασίζονται σε RNN και CNN. Ο Wei et al. [391] χρησιμοποίησε ένα δίκτυο LSTM, το οποίο ενημερώθηκε από διάφορες περιβαλλοντικές παραμέτρους, όπως η αγωγιμότητα, η θερμοκρασία, η πίεση, η αλατότητα και η συγκέντρωση οξυγόνου. Ομοίως, οι Aldhyani et al. [10] εκπαιδύσαν ένα LSTM, λαμβάνοντας υπ' όψη επτά διαφορετικά χαρακτηριστικά: διαλυμένο οξυγόνο (DO), pH, αγωγιμότητα, βιολογική ζήτηση οξυγόνου (BOD), νιτρικά, κολοβακτηρίδιο κοπράνων και ολικό κολοβακτηρίδιο. Έγιναν αρκετές προσπάθειες για τη βελτίωση της απόδοσης ενός απλού δικτύου LSTM: Οι Li et al. [232] ανέπτυξαν έναν αραιό αυτόματο κωδικοποιητή (SAE), για να εξάγει τα χαρακτηριστικά της Ποιότητας του Νερού πριν τα τροφοδοτήσει στο LSTM. Οι Eze et al. [106] χρησιμοποίησαν εμπειρική αποσύνθεση τρόπου λειτουργίας (EEMD), ως μέρος του αγωγού LSTM τους, για να εξαγάγουν περισσότερα χαρακτηριστικά σχετικά με τα προβλεπόμενα σήματα. Οι Chen et al. [69] πρόσθεσαν τον Μηχανισμό Προσοχής πάνω από το LSTM, για να καταγράψουν αποτελεσματικά τις πιο χρονικά μακρινές, αλλά εντυπωσιακές πληροφορίες, κρίσιμες για την απόδοση του μοντέλου. Για να ληφθούν υπ' όψη τόσο οι αρνητικές όσο και οι θετικές γειτονίες των διαδοχικών δεδομένων, οι Zhang et al. [429] πρότειναν ένα δίκτυο BiLSTM, ικανό να επεξεργάζεται δεδομένα σε διαφορετικές κατευθύνσεις ταυτόχρονα και να μάθει μια αμφίδρομη μη γραμμική χαρτογράφηση των πληροφοριών που εξάγονται, από τις ακατέργαστες μετρήσεις ποιότητας νερού και σχετικούς περιβαλλοντικούς παράγοντες.

Μια άλλη οικογένεια μοντέλων, που χρησιμοποιούνται για την πρόβλεψη

της Ποιότητας του Νερού, είναι των υβριδικών. Τα περισσότερα Υβριδικά Μοντέλα, συνδυάζουν Επαναλαμβανόμενα Νευρωνικά Δίκτυα συγκεκριμένα, LSTM, GRU και BiLSTM με CNN. Τα στρώματα CNN, χρησιμοποιούνται για την εξαγωγή πολύτιμων χαρακτηριστικών γύρω από τους δείκτες Ποιότητας του Νερού, ενώ τα επαναλαμβανόμενα στρώματα, ενσωματώνουν αυτά τα χαρακτηριστικά, μαθαίνοντας τις μακροπρόθεσμες εξαρτήσεις μεταξύ τους. Για το σκοπό αυτό, οι Jichang et al. [183] ανέπτυξαν ένα υβρίδιο CNN–GRU χρησιμοποιώντας δεδομένα χημικής ζήτησης οξυγόνου (COD) ως μέτρο της Ποιότητας του Νερού και των λυμάτων. Ομοίως οι Barzegar et al. [41] συνδύασαν ένα CNN με ένα LSTM, για να μάθουν από διάφορες φυσικοχημικές μεταβλητές ποιότητας του νερού, όπως το δυναμικό μείωσης της οξείδωσης και την ηλεκτρική αγωγιμότητα. Ο ίδιος υβριδισμός (CNN–LSTM) δοκιμάστηκε επίσης στο [201], αλλά διαπιστώθηκε ότι ένας άλλος τύπος υβριδικού μοντέλου, το CNN–BiLSTM, είχε καλύτερη απόδοση. Παρόμοια ευρήματα αναφέρθηκαν επίσης από [197]. Για να βελτιώσουν περαιτέρω την απόδοση των Υβριδικών Μοντέλων, οι Yang et al. [412] και Liu et al. [243] ενσωμάτωσαν τον Μηχανισμό Προσοχής, χρησιμοποιώντας ένα μοντέλο CNN–LSTM που βασίζεται σ’ αυτόν τον μηχανισμό. Αν και δεν είναι πολύ δημοφιλές στον τομέα της πρόβλεψης της Ποιότητας του Νερού, αναπτύχθηκε ένα μοντέλο βασισμένο σε γραφήματα CNN από τους Ni et al. [278]. Το προτεινόμενο μοντέλο παρουσίαζε επίσης δύο Μηχανισμούς Προσοχής: έναν για την καλύτερη κατανόηση των πιθανών σχέσεων, μεταξύ των διαφόρων παραμέτρων Ποιότητας του Νερού και έναν άλλο για την καταγραφή των χρονικών σχέσεων. Τέλος το μοντέλο περιελάμβανε επίσης τόσο χρονικές μονάδες συνέλιξης όσο και μονάδες BiGRU.

Μια επισκόπηση των μελετών Βαθιάς Μηχανικής Μάθησης που εξετάστηκαν και των αλγορίθμων που χρησιμοποιούνται στις αρχιτεκτονικές τους, για την πρόβλεψη της Ποιότητας του Νερού, εμφανίζεται στον Πίνακα 3.7. Η πρόβλεψη της Ποιότητας του Νερού, παρουσιάζει ευδιάκριτες προκλήσεις λόγω της

εξάρτησής της από μια σειρά πολύπλοκων φυσικών, χημικών, οικολογικών διεργασιών και τις εποχιακές τάσεις. Σε σενάρια όπου χρειάζονται βραχυπρόθεσμες έως μεσοπρόθεσμες προβλέψεις και κυριαρχούν τα χρονικά πρότυπα, όπως η πρόβλεψη ημερήσιων διακυμάνσεων στη θολότητα του νερού, που επηρεάζονται από τις καιρικές συνθήκες, τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα μπορούν να είναι αποτελεσματικά. Ωστόσο, σε καταστάσεις με περίπλοκες χωρικές αλληλεπιδράσεις, όπως η πρόβλεψη εποχιακών διακυμάνσεων των επιπέδων θρεπτικών ουσιών σε τεράστια υδάτινα οικοσυστήματα, αυτά τα μοντέλα ενδέχεται να υπολειπούνται και θα πρέπει να χρησιμοποιούνται CNN ή GNN. Δεδομένου ότι, τα δεδομένα Ποιότητας Νερού, δεν παρουσιάζουν συχνά μοτίβα που μοιάζουν με δίκτυο, οι περισσότερες μελέτες προτιμούν τη χρήση CNN έναντι GNN για χωρική μοντελοποίηση. Μεταξύ των πιο σημαντικών εξωγενών μεταβλητών, για την πρόβλεψη της Ποιότητας του Νερού, είναι οι μετεωρολογικοί παράγοντες και οι μεταβλητές χρήσης γης/κάλυψης γης. Οι μετεωρολογικοί παράγοντες, περιλαμβάνουν μεταβλητές όπως η θερμοκρασία, η βροχόπτωση, η υγρασία, η ταχύτητα του ανέμου και η ηλιακή ακτινοβολία, τα οποία επηρεάζουν σημαντικά τη δυναμική της Ποιότητας του Νερού. Αντίθετα οι μεταβλητές χρήσης γης και κάλυψης γης, συλλαμβάνουν κρίσιμες πληροφορίες σχετικά με τους τύπους δραστηριοτήτων της γης που λαμβάνουν χώρα, όπως η αστικοποίηση, η γεωργία και η αποψίλωση των δασών.

Έτος	Άρθρο	Συστατικά	Δεδομένα	Συγκρίθηκε Έναντι
2018	[232]	LSTM	Ιδιωτικό Σύνολο Δεδομένων	Βαθιά Μηχανική Μάθηση
2019	[391]	LSTM	Αρχείο δεδομένων Canada data archive	Παραδοσιακά

2019	[183]	CNN GRU	Φράγμα Jinze στη Σαγκάη	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2020	[10]	LSTM	Σύνολο Δεδομένων Ποιότητας Νερού Ινδίας	Βαθιά Μηχανική Μάθηση
2020	[41]	CNN LSTM	Λεκάνη Prespa, Βαλκανική χερσόνησος	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2021	[106]	LSTM	Φάρμα Αβαλώνας στη Νότια Αφρική	Βαθιά Μηχανική Μάθηση
2021	[201]	CNN BiLSTM	Ποταμός Ganga στο Uttarakhand, Ινδία	Βαθιά Μηχανική Μάθηση
2021	[412]	CNN LSTM Attention	Εκβολή Beilun στο Guangxi, Κίνα	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2021	[243]	CNN LSTM Attention	Ποταμός Guangli στο Guangxi, Κίνα	Βαθιά Μηχανική Μάθηση
2022	[69]	LSTM Attention	Ποταμός Burnett στο Queensland, Αυστραλία	Βαθιά Μηχανική Μάθηση
2022	[429]	BiLSTM Attention	Τμήμα Lanzhou του λεκανοπεδίου του Κίτρινου Ποταμού, Κίνα	Βαθιά Μηχανική Μάθηση

2022	[197]	BiLSTM	Ποταμός Yamuna, Ινδία	Παραδοσιακά και Βαθιά Μηχανική Μάθηση
2022	[278]	CNN BiGRU GCNN Attention	Σταθμοί παρακολούθησης στην Επαρχία Jiangsu, Κίνα	Βαθιά Μηχανική Μάθηση

Πίνακας 3.7: Πρόσφατες μελέτες Βαθιάς Μηχανικής Μάθησης για την πρόβλεψη της Ποιότητας του Νερού, συμπεριλαμβανομένων των προτεινόμενων αρχιτεκτονικών, των δεδομένων που χρησιμοποιήθηκαν και των τύπων μοντέλων με τους οποίους συγκρίθηκε η προτεινόμενη μέθοδος.

3.2 Προκλήσεις, Περιορισμοί και Μελλοντικές Κατευθύνσεις

Στην ενότητα αυτή, θίγονται σημαντικές προκλήσεις και περιορισμοί που συναντώνται στα συστήματα Βαθιάς Μηχανικής Μάθησης, εντός του πλαισίου των Έξυπνων Πόλεων και προτείνονται πιθανές κατευθύνσεις για μελλοντικές ερευνητικές προσπάθειες. Οι προκλήσεις αυτές περιλαμβάνουν μεταξύ άλλων, την επιλογή και υπερπροσαρμογή (Overfitting) των μοντέλων, την ερμηνευσιμότητα (Interpretability) και τη δυνατότητα μεταφοράς (Transferability) των μοντέλων, τις υπολογιστικές απαιτήσεις, την παρακολούθηση της απόδοσης των αναπτυγμένων μοντέλων, τις εναλλακτικές λύσεις στις τεχνικές Βαθιάς Μηχανικής Μάθησης, καθώς και ζητήματα που αφορούν το απόρρητο και την προστασία των δεδομένων (Data Privacy and Protection).

3.2.1 Επιλογή Μοντέλου και Υπερπροσαρμογή

Ένα από τα κύρια ζητήματα κατά την ανάπτυξη μοντέλων Βαθιάς Μηχανικής Μάθησης, είναι η επιλογή του κατάλληλου μοντέλου και των υπερπαραμέτρων του (*Model Selection and Hyperparameter Tuning*) [325, 410]. Η φύση του εκάστοτε προβλήματος, παίζει σημαντικό ρόλο στην επιλογή του ιδανικού τύπου μοντέλου, ειδικά λαμβάνοντας υπ' όψη την υποκείμενη δομή των δεδομένων. Ενδεικτικά, σε εφαρμογές όπου η δομή των δεδομένων είναι γραφήματα, όπως στις περιπτώσεις της Πληρότητας Χώρων Στάθμευσης, της Ροής Επιβατών και της Κυκλοφοριακής Ροής, τα Νευρωνικά Δίκτυα Γραφημάτων (*Graph Neural Networks - GNN*) προσφέρουν ανώτερη απόδοση, αξιοποιώντας τις χωρικές ιδιότητες των δικτύων. Για πιο γενικευμένες δομές δεδομένων, τα Υβριδικά Μοντέλα, που συνδυάζουν διάφορες αρχιτεκτονικές, μπορεί να προσφέρουν ενισχυμένη απόδοση, αλλά συνήθως συνοδεύονται από αυξημένες υπολογιστικές απαιτήσεις και πο-

λυπλοκότητα.

Η επιλογή των υπερπαραμέτρων είναι κρίσιμη καθώς επηρεάζουν σημαντικά τις κατανομές του μοντέλου. Η οπτικοποίηση των υπερπαραμέτρων εξαρτάται σε μεγάλο βαθμό από την επιλεγμένη μετρική βελτιστοποίησης και η χρήση διαφόρων μετρικών μπορεί να οδηγήσει σε αλλαγές στα ιδανικά σύνολα υπερπαραμέτρων. Μια δημοφιλής προσέγγιση για τον συντονισμό των υπερπαραμέτρων περιλαμβάνει τα εξής βήματα:

1. Καθορισμός μια μετρικής που αντικατοπτρίζει την απόδοση του μοντέλου στα δεδομένα χρονοσειρών.
2. Χρήση της τεχνικής διασταυρούμενης επικύρωσης k-fold, υποθέτοντας ότι υπάρχουν αρκετά διαθέσιμα δεδομένα.
3. Έναρξη δοκιμής μ' ένα ευρύ φάσμα τιμών υπερπαραμέτρων και στη συνέχεια περιορισμός σταδιακά με βάση τα αποτελέσματα. Για εύρεση καλών υποψήφιων ομάδων υπερπαραμέτρων, προτείνονται τεχνικές όπως η τυχαία αναζήτηση ή η Μπεϋζιανή βελτιστοποίηση.
4. Γραφική αναπαράσταση της σύγκλισης παρακολουθώντας την απόδοση διασταυρούμενης επικύρωσης του μοντέλου.
5. Τελικός έλεγχος απόδοση σ' ένα σετ δοκιμής.

Δεδομένου ότι τα μοντέλα Βαθιάς Μηχανικής Μάθησης είναι γνωστά ότι είναι επιρρεπή στην υπερπροσαρμογή (*overfitting*) [208], θα πρέπει να εφαρμόζονται κατάλληλες τεχνικές τακτοποίησης (*regularization*), όπως οι ποινές L1 και L2, η εγκατάλειψη (*dropout*) και η πρόωρη διακοπή (*early stopping*).

3.2.2 Ερμηνευσιμότητα

Η ερμηνευσιμότητα (*interpretability*) των μοντέλων είναι μία από τις κρίσιμες προκλήσεις στην ανάπτυξη συστημάτων Βαθιάς Μηχανικής Μάθησης, ειδικά

στο πλαίσιο των Έξυπνων Πόλεων [176]. Τα συστήματα αυτά συχνά βασίζονται σε πολύπλοκες αρχιτεκτονικές Νευρωνικών Δικτύων, οι οποίες μπορεί να είναι δύσκολο να ερμηνευτούν, κάτι που καθιστά απαιτητική την εξήγηση των αποφάσεων που προκύπτουν από αυτά τα μοντέλα, ειδικά σε καταστάσεις που έχουν άμεσες επιπτώσεις στην καθημερινή ζωή των πολιτών. Σε τομείς όπως η διαχείριση κυκλοφορίας, η ικανότητα κατανόησης των προβλέψεων ενός τέτοιου μοντέλου είναι ζωτικής σημασίας, τόσο για τους διαχειριστές της πόλης όσο και για τους κατοίκους. Για την αντιμετώπιση αυτής της πρόκλησης, είναι απαραίτητη η έρευνα σε ερμηνεύσιμες τεχνικές Βαθιάς Μηχανικής Μάθησης, οπτικοποιήσεις μοντέλων ή υποκατάστατα μοντέλα. Οι μέθοδοι αυτοί, στοχεύουν να ρίξουν φως στον τρόπο με τον οποίο τα μοντέλα Βαθιάς Μηχανικής Μάθησης φτάνουν στις προβλέψεις τους, παρέχοντας διαφάνεια και εμπιστοσύνη στις διαδικασίες λήψης αποφάσεων. Καθώς ο αριθμός των Έξυπνων Πόλεων και των σχετικών εφαρμογών αυξάνεται παγκοσμίως, οι μελέτες οφείλουν να επικεντρώνονται όλο και περισσότερο στην εξασφάλιση ότι τέτοιες πρωτοβουλίες είναι όχι μόνο αποτελεσματικές, αλλά και ηθικά αποδεκτές και δημοσίως ορθές. Είναι σημαντικό να επιτυγχάνεται ισορροπία μεταξύ της ακρίβειας των μοντέλων Βαθιάς Μηχανικής Μάθησης και της ερμηνευτικότητάς τους.

3.2.3 Δυνατότητα Μεταφοράς

Η Δυνατότητα Μεταφοράς (*transferability*) συστημάτων Βαθιάς Μηχανικής Μάθησης, αναφέρεται στην ικανότητά τους να μεταφέρουν ό,τι έχουν μάθει από τον ένα τομέα στον άλλο, καθώς προωθεί την ανταλλαγή και την επαναχρησιμοποίηση πολύτιμης γνώσης, αυξάνοντας έτσι την επεκτασιμότητα και την αποτελεσματικότητα ενός συστήματος. Τα μοντέλα που έχουν αναπτυχθεί για συγκεκριμένες εφαρμογές Έξυπνων Πόλεων, όπως η διαχείριση της κυκλοφορίας ή η βελτιστοποίηση ενέργειας, θα πρέπει ιδανικά να μπορούν να μεταφερθούν σε άλλες πόλεις ή περιοχές με ελάχιστες προσαρμογές [385]. Η επίτευξη δυνατό-

τητας μεταφοράς συνεπάγεται πολλές προκλήσεις από μόνη της, συμπεριλαμβανομένων των παραλλαγών στα χαρακτηριστικά των δεδομένων, την υποδομή και τους τοπικούς κανονισμούς. Για να βελτιωθεί η δυνατότητα μεταφοράς, είναι απαραίτητο να αναπτυχθούν γενικευμένα μοντέλα τα οποία έχουν την δυνατότητα να προσαρμοστούν σε διαφορετικά περιβάλλοντα Έξυπνων Πόλεων. Αυτό μπορεί να περιλαμβάνει την ενσωμάτωση τεχνικών προσαρμογής όπου επιτρέπουν στα μοντέλα να μαθαίνουν από δεδομένα στην πόλη-στόχο, αξιοποιώντας παράλληλα τη γνώση από την πόλη προέλευσης.

3.2.4 Υπολογιστικοί Πόροι

Η εκτέλεση συστημάτων Βαθιάς Μηχανικής Μάθησης, χρησιμοποιώντας δεδομένα IoT (*Internet of Things*) σ' ένα σενάριο Έξυπνης Πόλης (*smart city*) μπορεί να δημιουργήσει σημαντικές υπολογιστικές απαιτήσεις [140]. Ο τεράστιος όγκος δεδομένων που παράγεται από αισθητήρες IoT σε μια Έξυπνη Πόλη, συμπεριλαμβανομένων των δεδομένων από κάμερες κυκλοφορίας, περιβαλλοντικούς αισθητήρες και μετρητές ενέργειας, μπορεί να είναι τεράστιος. Τα μοντέλα Βαθιάς Μηχανικής Μάθησης, απαιτούν σημαντικούς υπολογιστικούς πόρους για την αποτελεσματική επεξεργασία και ανάλυση αυτών των δεδομένων, κάτι που συχνά προϋποθέτει ισχυρό hardware, όπως GPU (*Graphics Processing Unit*) ή εξειδικευμένους επεξεργαστές, για τον αποτελεσματικό χειρισμό του υπολογιστικού φορτίου. Επιπλέον περιπτώσεις επεξεργασίας δεδομένων IoT σε πραγματικό χρόνο ή σχεδόν σε πραγματικό χρόνο, όπως η διαχείριση της κυκλοφορίας ή η παρακολούθηση της ποιότητας του αέρα, αυξάνουν περαιτέρω τις υπολογιστικές απαιτήσεις. Καθώς τα μοντέλα Βαθιάς Μηχανικής Μάθησης γίνονται μεγαλύτερα, οι μελέτες θα πρέπει να δίνουν ιδιαίτερη προσοχή, στην υποδομή υλικού και στην βελτιστοποίηση πόρων, που απαιτούνται για τη διασφάλιση της επεκτασιμότητας και της ανταπόκρισης τέτοιων συστημάτων σε περιβάλλοντα Έξυπνων Πόλεων.

3.2.5 Παρακολούθηση

Η Παρακολούθηση μοντέλων στην παραγωγή (*production*), είναι μια κρίσιμη πτυχή για τη διασφάλιση της συνεχούς απόδοσης και αξιοπιστίας τους, ειδικά σε εξαιρετικά κρίσιμα σενάρια, όπως οι Έξυπνες Πόλεις (*smart cities*), όπου η ζωή των κατοίκων μπορεί να επηρεαστεί άμεσα [279]. Καθώς τα πρότυπα και τα δεδομένα μπορούν να αλλάξουν γρήγορα, η αποτελεσματική Παρακολούθηση, επιτρέπει τον εντοπισμό ανωμαλιών ή μετατόπισης μοντέλου (*model drift*) και διασφαλίζει ότι γίνονται έγκαιρες παρεμβάσεις για τη διατήρηση της ακεραιότητας του συστήματος. Λόγω του μεγάλου όγκου και της πολυπλοκότητας των δεδομένων IoT που δημιουργούνται, η παρακολούθηση συστημάτων Βαθιάς Μηχανικής Μάθησης σε Έξυπνες Πόλεις μπορεί να είναι αρκετά δύσκολη. Ως εκ τούτου θα ήταν ωφέλιμο για μελλοντικές μελέτες, να συζητήσουν με μεγαλύτερη λεπτομέρεια πώς (τρόποι, τεχνικές, εργαλεία) τα προτεινόμενα μοντέλα μπορούν να παρακολουθούνται κατά την ανάπτυξη ή ακόμη και να προτείνουν νέες μεθοδολογίες.

3.2.6 Εναλλακτικές Βαθιάς Μηχανικής Μάθησης

Στη εν λόγω μελέτη, εξετάστηκαν μόνο οι μέθοδοι Βαθιάς Μηχανικής Μάθησης (*deep learning*) και ενώ είναι οι πιο ισχυρές τεχνικές συνολικά, θα πρέπει να σημειωθεί ότι δεν υπάρχει μια προσέγγιση που ταιριάζει σε όλες τις περιπτώσεις. Υπάρχουν περιπτώσεις όπου απλούστερα μοντέλα, όπως παραλλαγές του ARIMA ή παραλλαγές εκθετικής εξομάλυνσης (*exponential smoothing*) [126], μπορούν να αποδώσουν εξίσου καλά, αν όχι καλύτερα, στην πρόβλεψη χρονοσειρών [252]. Τελικά η επιλογή μεταξύ Παραδοσιακής και Βαθιάς Μηχανικής Μάθησης, θα πρέπει να βασίζεται στα συγκεκριμένα χαρακτηριστικά των δεδομένων και στις απαιτήσεις του προβλήματος. Παρακάτω είναι μερικά πιθανά πλεονεκτήματα απλούστερων προσεγγίσεων σε σχέση με αυτές της Βαθιάς Μηχανικής

Μάθησης:

1. Ιδανικές για μικρότερες χρονοσειρές: Τα πιο απλά μοντέλα δύναται να είναι πιο αποτελεσματικά εάν τα δεδομένα χρονοσειρών δεν είναι πολύ μεγάλα και δεν παρουσιάζουν μακροπρόθεσμες εξαρτήσεις.
2. Ισχυρές υποθέσεις: Τα απλούστερα μοντέλα κάνουν ισχυρές υποθέσεις όσον αφορά τις κατανομές των δεδομένων και των χαρακτηριστικών, όπως η εποχικότητα και επομένως εάν είναι γνωστά εκ των προτέρων, μπορούν να ενσωματωθούν ευκολότερα σ' αυτά τα μοντέλα.
3. Παρουσία θορύβου και ακραίων τιμών: Τα πιο απλά μοντέλα επηρεάζονται λιγότερο από θορυβώδη δεδομένα και ακραίες τιμές καθώς δεν είναι τόσο ευέλικτα.
4. Λιγότερη υπολογιστική ισχύς: Τα πιο απλά μοντέλα είναι ευκολότερα να κατασκευαστούν, να διατηρηθούν και να παρακολουθούνται μετά την ανάπτυξη.

3.2.7 Απόρρητο Δεδομένων (*Data Privacy*)

Σε σενάρια Έξυπνων Πόλεων, όπου τα μοντέλα αναλύουν τεράστιες ποσότητες δεδομένων που συχνά περιλαμβάνουν προσωπικές ή ευαίσθητες πληροφορίες των κατοίκων, τα ζητήματα και οι απαιτήσεις της προστασίας απορρήτου των δεδομένων αποκτούν ιδιαίτερη σημασία [34]. Η διασφάλιση ισχυρής ανωνυμοποίησης και κρυπτογράφησης δεδομένων, είναι ζωτικής σημασίας για την προστασία των δικαιωμάτων απορρήτου των ατόμων. Επιπλέον, οι πολιτικές πρόσβασης και κοινής χρήσης δεδομένων πρέπει να ελέγχονται αυστηρά, με καλά καθορισμένα δικαιώματα χρήστη για την αποτροπή μη εξουσιοδοτημένης πρόσβασης και παραβιάσεων. Η συμμόρφωση με τους κανονισμούς περί απορρήτου δεδομένων, όπως ο GDPR στην Ευρώπη ή παρόμοια νομοθεσία παγκοσμίως, αποτελεί θεμελιώδη υποχρέωση. Αυτό συνεπάγεται τη λήψη συναίνεσης από τους

κατοίκους για τη συλλογή δεδομένων και την εφαρμογή μηχανισμών για τα δικαιώματα των εν λόγω δεδομένων. Είναι υψίστης σημασίας οι νέες μελέτες, να εξισορροπούν καλύτερα την πρόοδο της τεχνολογίας με την προστασία των δικαιωμάτων ιδιωτικής ζωής των πολιτών.

Ένας αναδυόμενος τομέας Βαθιάς Μηχανικής Μάθησης που έχει δείξει μεγάλη υπόσχεση για τη βελτίωση του απορρήτου των δεδομένων, είναι η Ομοσπονδιακή Μάθηση (*Federated Learning*) [178]. Η Ομοσπονδιακή Μάθηση είναι μια προσέγγιση Μηχανικής Μάθησης, η οποία επιτρέπει τη μοντελοποίηση σε κατανεμημένες συσκευές ή πηγές δεδομένων, ενώ διατηρεί τα ευαίσθητα δεδομένα τοπικά στην συσκευή, μετριάζοντας τον κίνδυνο έκθεσης δεδομένων κατά τη μετάδοση.

Κεφάλαιο 4

Ανάλυση και Σύγκριση Μεθόδων Χρονοσειρών για την Πρόβλεψη Ενεργών Κρουσμάτων COVID-19

Η νόσος του κορονοϊού (COVID-19), που προκαλείται από το νέο σοβαρό οξύ αναπνευστικό σύνδρομο SARS-CoV-2, είχε εξελιχθεί σε παγκόσμια πανδημία από τις 4 Μαΐου 2020. [397, 289]. Από τότε που εντοπίστηκε για πρώτη φορά τον Δεκέμβριο του 2019 στη Γουχάν της Κίνας [245], η επιδημία προκάλεσε σοβαρή παγκόσμια κοινωνικοοικονομική αναταραχή [115]. Μέχρι τις 4 Μαΐου 2020, περισσότερα από 3,5 εκατομμύρια κρούσματα COVID-19 καταγράφηκαν σε συνολικά 187 χώρες και περιοχές, με αποτέλεσμα περισσότερους από 248.000 θανάτους, ενώ περισσότεροι από 1,13 εκατομμύρια άνθρωποι είχαν αναρρώσει [81].

Σε απάντηση, πολλές χώρες εφάρμοσαν μέτρα όπως η απομόνωση και η κοινωνική απόσταση για να αποτρέψουν περαιτέρω εξάπλωση, ισοπεδώνοντας κατά συνέπεια την καμπύλη της επιδημίας. Αυτά τα μέτρα αποδείχθηκαν ζωτικής σημασίας για τη διατήρηση των υπηρεσιών υγείας σε ασθενείς που χρειάζονταν περισσότερο φροντίδα είτε για COVID-19 ή για άλλες σοβαρές καταστάσεις [316].

Η ικανότητα εντοπισμού του ρυθμού με τον οποίον εξαπλωνόταν η ασθένεια, ήταν ζωτικής σημασίας για την καταπολέμηση της πανδημίας. Η επίγνωση του επιπέδου εξάπλωσης σε οποιαδήποτε δεδομένη χρονική στιγμή, είχε τη δυνατότητα να βοηθήσει τις κυβερνήσεις στον σχεδιασμό και τη διαμόρφωση πο-

λιτικής για τη δημόσια υγεία, προκειμένου να αντιμετωπιστούν οι συνέπειες της πανδημίας [316, 200].

Ένα κρίσιμο βήμα στην αντιμετώπιση της πανδημίας, ήταν η εφαρμογή ακριβών και εκτεταμένων ελέγχων. Αν και οι μέθοδοι ελέγχου για τον COVID-19 διέφεραν μεταξύ των χωρών, με αποτέλεσμα να υπάρχουν διαφορές στο ποσοστό του πληθυσμού που υποβλήθηκε σε τεστ [297][330], έως τις 23 Απριλίου 2020, δεν υπήρχε χώρα που να είχε ελέγξει πάνω από το 13,4% του πληθυσμού της, με τον μέσο όρο ελέγχων σε όλες τις επηρεασμένες χώρες να είναι μόλις 1,3%. Παράλληλα, παρά την εξέλιξη των κλινικών δοκιμών αντισωμάτων από τις 6 Απριλίου 2020, δεν είχαν ακόμα λάβει έγκριση για ευρεία χρήση [310][383][302]. Η δυνατότητα ακριβούς εκτίμησης του αριθμού των ενεργών κρουσμάτων σε κάθε χρονική στιγμή ήταν επίσης ζωτικής σημασίας, καθώς επέτρεπε την καλύτερη κατανόηση της έκτασης της εξάπλωσης της νόσου και κατ' επέκταση της προόδου προς την κορύφωσή της.

Στην μελέτη αυτή, η οποία έγινε μόλις λίγες εβδομάδες από το ξέσπασμα της πανδημίας, προτάθηκε η χρήση στατιστικών μεθόδων καθώς και μεθόδων Μηχανικής Μάθησης, για την εκτίμηση του ποσοστού των ενεργών κρουσμάτων, σε σχέση με τον συνολικό πληθυσμό για τις δέκα χώρες με τα περισσότερα κρούσματα. Πιο συγκεκριμένα, έξι διαφορετικές προσεγγίσεις χρονοσειρών, ο ARIMA [56], το Προσθετικό Μοντέλο Holt-Winters (HWAAS) [67], ο TBAT [86], ο Προφήτης του Facebook [368], ο DeepAR [336] (όπως εφαρμόζεται στο [11]) και ο N-Beats [295], χρησιμοποιήθηκαν και στη συνέχεια συγκρίθηκαν για καθεμία από τις ακόλουθες χώρες: ΗΠΑ, Ηνωμένο Βασίλειο, Ιταλία, Ισπανία, Ρωσία, Γαλλία, Τουρκία, Γερμανία, Ιράν και Βραζιλία. Όσον αφορά τις μετρικές αξιολογήσεις, η ρίζα μέσου τετραγωνικού σφάλματος (RMSE) χρησιμοποιήθηκε για την αξιολόγηση της απόδοσης κάθε μοντέλου. Τέλος τα αποτελέσματα που θα παρουσιαστούν στην συνέχεια, υποδεικνύουν ότι αν και δεν υπάρχει μια ενιαία προσέγγιση για όλες τις χώρες, στην πλειοψηφία ο ARIMA και ο TBAT επιδεικνύουν ανώτερη

απόδοση σε επτά στις δέκα χώρες, ενώ επιτυγχάνουν τα δεύτερα καλύτερα αποτελέσματα σε άλλες δύο.

Η Μηχανική Μάθηση και οι Στατιστικές Μέθοδοι, έχουν εφαρμοστεί με επιτυχία στο παρελθόν στον τομέα των μολυσματικών ασθενειών. Παραδείγματα περιλαμβάνουν τη Μοντελοποίηση της Λεπτοσπείρωσης και την σχέση της με τις βροχοπτώσεις και τη θερμοκρασία [65] καθώς και χρονικές συσχετίσεις μεταξύ του μηνιαίου αριθμού κρουσμάτων *Plasmodium falciparum* και της νότιας ταλάντωσης El Niño (ENSO) [146].

Παρόμοιες προσεγγίσεις έχουν επίσης ακολουθηθεί για μοντελοποίηση ασθενειών, όπου εμφανίζονται σε κυκλικά ή επαναλαμβανόμενα μοτίβα, όπως η εποχική γρίπη, για την οποία έχει δημοσιευθεί ένας αριθμός μελετών στις οποίες γίνεται χρήση μοντελοποίησης χρονοσειρών για την πρόβλεψη μελλοντικών εστιών. Στο [355], ένα μοντέλο ARIMA [3] έχει αναπτυχθεί για την πρόβλεψη της μηνιαίας επίπτωσης της γρίπης στην Κίνα για το 2012 ενώ στο [415], προτείνεται ένα Μοντέλο Πρόβλεψης (Tempel) για την πρόβλεψη μετάλλαξης των ιών της γρίπης Α. Περισσότερα παραδείγματα περιλαμβάνουν τα έργα του [221], ο οποίος δημιούργησε ένα μοντέλο χρησιμοποιώντας εβδομαδιαίες μετρήσεις από tweets που σχετίζονται με τη γρίπη και το εφάρμοσε για να παρέχει αξιολόγηση σε πραγματικό χρόνο της εξάπλωσης της γρίπης καθώς και του [432], ο οποίος κατασκεύασε ένα μοντέλο SARIMA [3] για την ανάλυση και πρόγνωση της Αυστραλιανής γρίπης και των εποχικών επιδημιών γρίπης στο βόρειο ημισφαίριο, πιο συγκεκριμένα στις ΗΠΑ, το Ηνωμένο Βασίλειο και την Κίνα. Στο [351] η μοντελοποίηση χρονοσειρών, χρησιμοποιείται για τη διερεύνηση του ρόλου των κλιματικών παραγόντων στην μετάδοση της γρίπης σε δύο περιοχές με θερμό κλίμα, το Χονγκ Κονγκ και την κομητεία Maricopa (Αριζόνα, Η.Π.Α.), ενώ το [95] χρησιμοποίησε μια άλλη προσέγγιση χρονοσειρών, με στόχο να εξετάσει τη συμπεριφορά δύο δεικτών σχετικών με την γρίπη στην περιοχή της Βαρκελώνης.

Στο [329], προβλέψεις σε πραγματικό χρόνο για τον σωρευτικό αριθμό

αναφερόμενων κρουσμάτων στις επαρχίες της Κίνας, παράγονται χρησιμοποιώντας τρία διαφορετικά μοντέλα, τα οποία είχαν χρησιμοποιηθεί προηγουμένως για την πρόβλεψη μολυσματικών ασθενειών όπως το SARS, ο Έμπολα, η Πανδημική Γρίπη και ο Δάγκειος Πυρετός. Σε μια σχετική μελέτη το [413], ενσωμάτωσε δεδομένα μετανάστευσης πληθυσμού και επιδημιολογικά δεδομένα, για να εκπαιδεύσει ένα μοντέλο Susceptible-Exposed-Infectious-Removed (SEIR) και το συνέδεσε με μοντέλα Τεχνητής Νοημοσύνης τα οποία εκπαιδεύτηκαν στα δεδομένα του SARS του 2003, με στόχο την πρόβλεψη της επιδημικής καμπύλης στην Κίνα. Στο [227], ο ημερήσιος και ο συνολικός αριθμός μολύνσεων και θανάτων, καθώς και τα αντίστοιχα σημεία καμψής της πανδημίας στην Κίνα, μοντελοποιήθηκαν χρησιμοποιώντας μια συμμετρική συνάρτηση. Ένας τροποποιημένος στοιβαγμένος αυτόματος κωδικοποιητής αναπτύχθηκε στο [164], για να μοντελοποιήσει τη δυναμική μετάδοσης της επιδημίας και να προβλέψει τον αριθμό των επιβεβαιωμένων κρουσμάτων COVID-19 σε ολόκληρη την Κίνα, ενώ το [8] πρότεινε έναν συνδυασμό προσαρμοστικού νευρο-ασαφούς συστήματος συμπερασμάτων (ANFIS) και αλγορίθμου επικοινωνίας λουλουδιών με ενισχυμένο αλγόριθμο (SSA), για την πρόβλεψη των επιβεβαιωμένων κρουσμάτων του COVID-19 τις επόμενες δέκα ημέρες.

Στο [109], μια μελέτη που περιλαμβάνει την Κίνα αλλά και δύο ευρωπαϊκές χώρες, την Ιταλία και τη Γαλλία, χρησιμοποιήθηκαν απλά μοντέλα μέσου πεδίου, για την πρόβλεψη της εξάπλωσης της πανδημίας COVID-19 και κυρίως το ύψος και τον χρόνο κορύφωσής της σε καθεμία από τις προαναφερθείσες χώρες.

Ο βασικός αναπαραγωγικός αριθμός (R_0), υπολογίστηκε σε τρεις διαφορετικές μελέτες: η μελέτη [400] χρησιμοποίησε τις μεθόδους Markov Chain Monte Carlo (MCMC), η μελέτη [22] πρότεινε ένα μοντέλο susceptible Infectious Recovered Dead (SIRD) και η μελέτη [431], η οποία εστίασε στο κρουαζιερόπλοιο Diamond Princess, προσάρμοσε τις στατιστικές κατανομές για να εκτιμήσει το R_0

στο πρώιμο στάδιο της επιδημίας COVID-19. Επιπλέον η μελέτη [22], προβλέπει τα ημερήσια ποσοστά θνησιμότητας και ανάρρωσης από τη μόλυνση, καθώς και την εξέλιξη της επιδημίας για τις επόμενες τρεις εβδομάδες, προσαρμόζοντας τις παραμέτρους του μοντέλου SIRD.

Στο επίκεντρο της προσέγγισης που ακολούθησε η μελέτη [171] βρισκόταν η στατιστική μοντελοποίηση, με στόχο την πρόβλεψη της πίεσης που θα ασκούσε η πανδημία στο σύστημα υγείας των Ηνωμένων Πολιτειών. Η μελέτη αυτή εκτίμησε τον αναγκαίο αριθμό νοσοκομειακών κλινών, κλινών ΜΕΘ και αναπνευστήρων που θα χρειαζόνταν κατά τους επόμενους τέσσερις μήνες, καθώς και τον αναμενόμενο αριθμό θανάτων.

Τέλος σε μια συναφή μελέτη, η εργασία [311] υιοθέτησε απλούστερες μεθόδους πρόβλεψης για χρονοσειρές, εφαρμόζοντας μοντέλα από την οικογένεια της Εκθετικής Εξομάλυνσης, με σκοπό την πρόβλεψη του αριθμού των επιβεβαιωμένων κρουσμάτων COVID-19 σε παγκόσμιο επίπεδο.

4.1 Δεδομένα COVID-19: Θάνατοι, Κρούσματα, Ανάρρωση

Στο πλαίσιο της αντίδρασης στην επιδημία, πλήθος οργανισμών και ατόμων, είχαν διαθέσει προς το κοινό, συνόλα δεδομένων σχετικά με τον COVID-19, για αναλυτικές και ερευνητικές χρήσεις. Ένα από τα πλέον διαδεδομένα προγράμματα, ήταν το πρόγραμμα το οποίο που υλοποίησε ο Λευκός Οίκος, σε συνεργασία με πρωτοπόρες ερευνητικές ομάδες, προσφέροντας μια βάση δεδομένων που περιλαμβάνει πάνω από 51.000 επιστημονικά άρθρα, εκ των οποίων περισσότερα από 40.000 είναι σχετικά με τον COVID-19, τον SARS-CoV-2 και άλλους σχετικούς κορονοϊούς.

Στην παρούσα μελέτη, χρησιμοποιήθηκαν δύο δημόσια διαθέσιμα σύνολα δεδομένων από το kaggle.com για την ανάπτυξη και ανάλυση μοντέλων: το «Novel Corona Virus 2019 Dataset» [1] και το σύνολο πληθυσμού ανά χώρα [2].

Το πρώτο σύνολο δεδομένων, παρέχει πληροφορίες χρονοσειρών σχετικά με την εξάπλωση του ιού σε κάθε χώρα, ενώ το δεύτερο χρησιμοποιήθηκε για την εξαγωγή, τη μοντελοποίηση και την πρόβλεψη των ενεργών κρουσμάτων του ιού ως ποσοστό του συνολικού πληθυσμού για κάθε χώρα. Αυτό επιτεύχθηκε διαιρώντας την τιμή κάθε χρονοσειράς με τον συνολικό πληθυσμό κατά τη διάρκεια της εκπαίδευσης, της αξιολόγησης και των δοκιμών των μοντέλων, προσφέροντας έτσι μια πιο σαφή εικόνα και επιτρέποντας μια πιο δίκαιη σύγκριση του ποσοστού εξάπλωσης της νόσου μεταξύ των διαφόρων χωρών.


Το «Novel Corona Virus 2019 Dataset» περιλαμβάνει καθημερινές πληροφορίες για:

1. Τον αριθμό των επιβεβαιωμένων κρουσμάτων COVID-19
2. Τον αριθμό των ασθενών που έχουν αναρρώσει από τον COVID-19
3. Τον αριθμό των θανάτων λόγω του COVID-19

Ο αριθμός των ενεργών κρουσμάτων σε κάθε χώρα, για κάθε ημέρα, υπολογίστηκε αφαιρώντας τόσο τους ασθενείς που έχουν αναρρώσει, όσο και τον αριθμό των θανάτων από τα επιβεβαιωμένα κρούσματα.

Η κατανομή των συνολικών επιβεβαιωμένων κρουσμάτων ανά χώρα στις 4 Μαΐου 2020 εμφανίζεται στο σχήμα 4.2, ενώ το σχήμα 4.1 δείχνει τον αριθμό των ενεργών κρουσμάτων, επίσης από τις 4 Μαΐου 2020, χρησιμοποιώντας λογαριθμική κλίμακα.


Με βάση τα στατιστικά δεδομένα που παρουσιάζονται στο Σχήμα 4.2, επικεντρωθήκαμε στις 10 χώρες με τον μεγαλύτερο αριθμό επιβεβαιωμένων κρουσμάτων, οι οποίες από τις 4 Μαΐου 2020, αντιπροσωπεύουν πάνω από το 70% του συνόλου των επιβεβαιωμένων κρουσμάτων παγκοσμίως. Οι χώρες αυτές, βρίσκόμενες σε πιο προχωρημένα στάδια της πανδημίας και έχοντας υποστεί τις μεγαλύτερες επιπτώσεις από τον ιό, μπορούν να προσφέρουν πολύτιμες πληροφορίες και να υπηρετήσουν ως σημεία αναφοράς για χώρες που βρίσκονται σε πρώιμα στάδια της εξάπλωσης.



Σχήμα 4.1: Αριθμός ενεργών κρουσμάτων ανά χώρα με χρήση λογαριθμικής κλίμακας


Τέλος, το ποσοστό των ενεργών κρουσμάτων σε σχέση με τον συνολικό πληθυσμό για κάθε χώρα παρουσιάζεται στα Σχήματα 4.3 και 4.4. Στο πρώτο

Distribution of confirmed COVID-19 cases per country as of 04 May 2020



Σχήμα 4.2: Κατανομή των συνολικών επιβεβαιωμένων κρουσμάτων COVID-19 ανά χώρα στις 4 Μαΐου 2020

απεικονίζεται η εξάπλωση της πανδημίας, σε κάθε χώρα κατά τη διάρκεια του χρόνου από τον Ιανουάριο, ενώ στο δεύτερο η χρονική στιγμή του πρώτου επιβεβαιωμένου κρούσματος, γίνεται το σημείο αναφοράς (στιγμή μηδέν) για κάθε χώρα. Η ευθυγράμμιση των χρονοσειρών με τον τρόπο αυτό, προσφέρει μια πιο συγκριτική και ολοκληρωμένη άποψη της εξάπλωσης της πανδημίας στις επιλεγμένες χώρες, βοηθώντας στη βαθύτερη κατανόηση της φάσης της πανδημίας σε καθεμιά από αυτές.



Σχήμα 4.3: Ποσοστό ενεργών κρουσμάτων σε σχέση με τον συνολικό πληθυσμό ανά χώρα χρησιμοποιώντας γραμμική κλίμακα.



Σχήμα 4.4: Ποσοστό ενεργών κρουσμάτων σε σχέση με τον συνολικό πληθυσμό ανά χώρα. Για κάθε χώρα η στιγμή μηδέν, είναι το πρώτο επιβεβαιωμένο κρούσμα σε αυτήν τη χώρα.

4.2 Πειράματα και Αποτελέσματα

Στην παρούσα ενότητα, παρουσιάζεται η διαδικασία ανάπτυξης και αξιολόγησης έξι διαφορετικών προσεγγίσεων πρόβλεψης χρονοσειρών: το μοντέλο ARIMA [56], το Προσθετικό Μοντέλο Holt-Winters (HWAAS) [67], ο TBAT [86], ο Προφήτης του Facebook [368], το DeepAR [336] (όπως υλοποιείται στην αναφορά [11]), και ο N-Beats [295]. Περιλαμβάνεται επίσης μια συνοπτική ανάλυση των τελικών αποτελεσμάτων.

4.2.1 Διαδικασία Μοντελοποίησης

Η διαδικασία Μοντελοποίησης, είχε ως στόχο τη σύγκριση διαφόρων μεθόδων χρονοσειρών, στην πρόβλεψη του ποσοστού των ενεργών κρουσμάτων COVID-19 επί του συνολικού πληθυσμού. Για την ανάλυση επιλέχθηκαν οι δέκα χώρες με το μεγαλύτερο αριθμό συνολικά επιβεβαιωμένων κρουσμάτων, αντιπροσωπεύοντας πάνω από το 70% των παγκοσμίως επιβεβαιωμένων κρουσμάτων.

Κάθε μοντέλο χρονοσειρών υποβλήθηκε σε εκπαίδευση, αξιολόγηση και δοκιμή για τις χρονοσειρές, οι οποίες απεικονίζουν τα ποσοστά ενεργών περιπτώσεων, σε σχέση με τον συνολικό πληθυσμό για τις επιλεγμένες χώρες.

Για κάθε μία από τις δέκα χώρες, συλλέχθηκαν συνολικά 104 δείγματα, με κάθε δείγμα να αντιστοιχεί στο ποσοστό των ενεργών κρουσμάτων κορωνοϊού, επί του συνολικού πληθυσμού, για μια δοθείσα ημέρα στη συγκεκριμένη χώρα. Ο υπολογισμός περιπτώσεων ενεργών κρουσμάτων, ανά ημέρα για κάθε χώρα πραγματοποιήθηκε, αφαιρώντας τον αριθμό των ασθενών που είχαν αναρρώσει και των θανάτων από τον συνολικό αριθμό των επιβεβαιωμένων κρουσμάτων. Επιπλέον, για τον υπολογισμό του ποσοστού των ενεργών κρουσμάτων επί του πληθυσμού, ο αριθμός των ενεργών περιπτώσεων (αναρρώσεων / θανάτων) κάθε μέρας, διαιρέθηκε με τον συνολικό πληθυσμό της αντίστοιχης χώρας.

Για τους σκοπούς εκπαίδευσης και επικύρωσης, επιλέχθηκαν 97 από τα

δείγματα, με 72 από αυτά να αξιοποιούνται, για την εκπαίδευση των μοντέλων και τα υπόλοιπα 25 για επικύρωση. Ένα χρονικό παράθυρο επτά ημερών ορίστηκε, για την αξιολόγηση της απόδοσης των προγνωστικών μοντέλων που έχουν αναλυθεί στις Ενότητες 2.1 και 2.3. Ως μέτρο αξιολόγησης της προγνωστικής ακρίβειας κάθε προσέγγισης χρησιμοποιήθηκε η ρίζα μέσου τετραγωνικού σφάλματος (RMSE).

4.2.2 Απόδοση Μοντέλων

Τα αποτελέσματα των μοντέλων για κάθε χώρα παρουσιάζονται στον Πίνακα 4.1, δείχνοντας ότι δεν υπάρχει μια μοναδική προσέγγιση που να κυριαρχεί στην πρόβλεψη του ποσοστού των ενεργών κρουσμάτων σε σχέση με τον συνολικό πληθυσμό ανά χώρα.

	US	Spain	Italy	UK	France
ARIMA	0.007421	0.080094	0.005628	0.005484	0.060824
Prophet	0.013877	0.065433	0.019217	0.007634	0.044482
HWAAS	0.172957	0.031497	0.006616	0.004366	0.011007
NBEATS	0.036958	0.050492	0.008645	0.037623	0.004220
Gluonts	0.044805	0.108842	0.043551	0.046134	0.010549
TBAT	0.009873	0.029295	0.005810	0.004310	0.007003
	Germany	Russia	Turkey	Brazil	Iran
ARIMA	0.006431	0.001536	0.004442	0.004194	0.002628
Prophet	0.037139	0.014681	0.044595	0.009279	0.016281
HWAAS	0.004586	0.002295	0.000887	0.005717	0.001046
NBEATS	0.013192	0.027078	0.018265	0.010870	0.003745
Gluonts	0.057523	0.034479	0.093839	0.002836	0.002277
TBAT	0.003389	0.002193	0.001946	0.005621	0.000425

Πίνακας 4.1: Απόδοση Μοντέλων (RMSE) για τις δέκα χώρες με τα περισσότερα επιβεβαιωμένα κρούσματα COVID-19 έως τις 4 Μαΐου 2020.

Για την στατιστική αξιολόγηση των αποτελεσμάτων, υιοθετήθηκε το μη παραμετρικό τεστ πολλαπλών ομάδων Friedman [121] με επίπεδο σημαντικότητας $\alpha = 0.02$. Η μέθοδος αυτή επιτρέπει την παραγωγή μιας κατάταξης μεταξύ των αλγορίθμων, καθορίζοντας στατιστικά σημαντικές διαφορές στην απόδοσή τους, όπως παρουσιάζεται στον Πίνακα 4.2.

Rank	Algorithm
1.70000	TBAT
2.90000	ARIMA
2.90000	HWAAS
4.10000	NBEATS
4.60000	Prophet
4.80000	Gluonts

Πίνακας 4.2: Κατάταξη Στατιστικού τεστ Friedman (Επίπεδο Σημαντικότητας $\alpha = 0,02$).

Συμπερασματικά, όπως επιβεβαιώνεται τόσο από τα αποτελέσματα στον Πίνακα 4.1 όσο και από τη Στατιστική Κατάταξη στον Πίνακα 4.2, παρατηρείται ότι οι Στατιστικές Μέθοδοι όπως ARIMA, TBAT και HWAAS έχουν καλύτερη απόδοση σε σύγκριση με τις μεθόδους Βαθιάς Μηχανικής Μάθησης όπως ο N-BEATS και ο DeepAR (GluonTS). Αυτό μπορεί να αποδοθεί, στην ανάγκη των αλγορίθμων Βαθιάς Μηχανικής Μάθησης για μεγάλο όγκο δεδομένων ώστε να λειτουργήσουν πιο αποτελεσματικά.

Επιπλέον η μέθοδος του Προφήτη του Facebook, δεν κατάφερε να υπερτερήσει σε καμία από τις εξετασθείσες χώρες, επιβεβαιώνοντας την προσδοκία, ότι η μέθοδος αυτή είναι περισσότερο κατάλληλη για επιχειρηματικές εφαρμογές, παρά για εκτεταμένες επιδημιολογικές αναλύσεις.

Σύμφωνα με τα παραπάνω, ο TBAT και ο ARIMA, αποδείχθηκαν ως οι μέθοδοι με τις καλύτερες επιδόσεις συνολικά, παρέχοντας τις πιο ακριβείς προβλέψεις για επτά από τις δέκα χώρες, με βάση το RMSE και επίσης σημείωσαν τα δεύτερα καλύτερα αποτελέσματα σε άλλες δύο χώρες. Ειδικότερα, ο αλγόριθμος ARIMA ξεχώρισε για τις επιδόσεις του στις Ηνωμένες Πολιτείες, την Ιταλία και τη Ρωσία, ενώ ο TBAT προσφέρθηκε ως η καλύτερη λύση για την Ισπανία, το Ηνωμένο Βασίλειο, τη Γερμανία και το Ιράν.

Ο TBAT διαπρέπει σε εννέα από τις δέκα περιπτώσεις, φτάνοντας στις δύο πρώτες θέσεις, με την εξαίρεση της Βραζιλίας όπου κατέλαβε την τρίτη καλύτερη επίδοση, πίσω από τον Gluonts και τον ARIMA.


Επίσης, όταν εφαρμόστηκε η post-hoc Στατιστική Ανάλυση του Holm στα αποτελέσματα του Friedman τεστ, διαπιστώθηκε ότι ο TBAT, με επίπεδο σημαντικότητας $\alpha = 0.02$, υπερέχει στατιστικά σημαντικά σε σύγκριση με τον Προφήτη, τον DeepAR (Gluonts), και τον N-BEATS, όπως παρουσιάζεται στον Πίνακα 4.3.

Εκτός από τις μεθόδους Στατιστικής Ανάλυσης χρονοσειρών, όπως οι ARIMA και HWAAS, με τον ARIMA να παρουσιάζει συνολικά καλύτερες επιδόσεις σε σύγκριση με τον HWAAS και οι δύο παραπάνω μέθοδοι καταγράφηκαν στις πρώτες τρεις θέσεις, σε επτά από τις δέκα περιπτώσεις. Συγκεκριμένα το Προσθετικό Μοντέλο Holt-Winters, διακρίθηκε για τις επιδόσεις του στην Τουρκία.


Αναφορικά με τις μεθόδους Βαθιάς Μηχανικής Μάθησης, παρά τη γενικότερα χαμηλή απόδοσή τους, οι N-BEATS και DeepAR (Gluonts) κατάφεραν να εξασφαλίσουν καλύτερα αποτελέσματα στη Γαλλία και τη Βραζιλία αντίστοιχα, επιδεικνύοντας ότι υπάρχουν περιπτώσεις όπου οι μέθοδοι Βαθιάς Μηχανικής Μάθησης μπορούν να υπερέχουν.

Comparison	Statistic	Adjusted p -Value	Result
TBAT vs Gluonts	3.70521	0.00106	H0 is rejected
TBAT vs Prophet	3.46616	0.00211	H0 is rejected
TBAT vs NBEATS	2.86855	0.01237	H0 is rejected
TBAT vs ARIMA	1.43427	0.30299	H0 is accepted
TBAT vs HWAAS	1.43427	0.30299	H0 is accepted


Πίνακας 4.3: TBAT εναντίων όλων: Η post-hoc Στατιστική Ανάλυση του Holm που εφαρμόστηκε πάνω από το τεστ Friedman (επίπεδο σημαντικότητας $\alpha = 0, 02$).



Σχήμα 4.5: Προβλέψεις για την Ρωσία.



Σχήμα 4.6: Προβλέψεις για το Ηνωμένο Βασίλειο.



Σχήμα 4.7: Προβλέψεις για την Γαλλία.

4.2.3 Σύγκριση Μεταξύ Χωρών

Η δυσκολία στο να καθοριστούν οι ακριβείς λόγοι όπου καθιστούν ορισμένους αλγόριθμους, πιο αποδοτικούς σε συγκεκριμένες χώρες σε σύγκριση με άλλες είναι σημαντική. Αρκετοί παράγοντες πρέπει να ληφθούν υπ'όψη, όπως:

1. Οι κλιματικές συνθήκες και τα γεωγραφικά χαρακτηριστικά της κάθε χώρας.
2. Διαφορές στα χαρακτηριστικά που σχετίζονται με τον πληθυσμό, όπως η πυκνότητα του πληθυσμού μεταξύ διαφόρων χωρών.
3. Ασυνέπειες στις δοκιμές και στη συλλογή δεδομένων ανά χώρα.
4. Η ποικιλομορφία των μέτρων καραντίνας και κοινωνικής απόστασης που εφαρμόστηκαν σε διάφορες χώρες, καθώς και ο χρόνος εφαρμογής, η διάρκεια και η αυστηρότητά τους.

Αυτοί οι παράγοντες, μεταξύ άλλων, μπορεί να αιτιολογήσουν τις διακυ-

μάνσεις στην επίδοση των Προβλεπτικών Μοντέλων μεταξύ των διαφόρων χωρών. Συνεπώς, είναι σημαντικό αυτοί να λαμβάνονται υπόψη κατά τη διαδικασία σύγκρισης και ανάλυσης των αποτελεσμάτων.

Κεφάλαιο 5

Αλγόριθμοι Μηχανικής Μάθησης για Πρόβλεψη της Τιμής του Bitcoin

Το Διαδίκτυο, έχει παίξει καθοριστικό ρόλο στην εξέλιξη της παγκόσμιας οικονομίας, με τη δημιουργία του Bitcoin το 2009, ν' αποτελεί ένα από τα πιο εμβληματικά γεγονότα. Το Bitcoin [275] εισήγαγε μια νέα μορφή οικονομικής συναλλαγής, ως το πρώτο αποκεντρωμένο ψηφιακό νόμισμα στον κόσμο, λειτουργώντας χωρίς την ανάγκη ενός κεντρικού οργανισμού ή ενιαίας διαχειριστικής αρχής. Αυτό επιτρέπει στους χρήστες να πραγματοποιούν συναλλαγές απευθείας μεταξύ τους σε οποιοδήποτε σημείο του πλανήτη, προσφέροντας μια νέα ελευθερία και αυτονομία στον τομέα των οικονομικών συναλλαγών.

Η δημιουργία των Bitcoin επιτυγχάνεται μέσω μιας διαδικασίας γνωστής ως εξόρυξη (mining) [288], η οποία αποτελεί τον μηχανισμό που διασφαλίζει την ασφάλεια και την ακεραιότητα του δικτύου Bitcoin. Στη διαδικασία αυτή, οι υπολογιστές ανταγωνίζονται για την επίλυση συγκεκριμένων περίπλοκων υπολογιστικών προβλημάτων, και ο πρώτος που τα καταφέρνει ανταμείβεται με μια συγκεκριμένη ποσότητα Bitcoin. Παρ'όλο που η εξόρυξη ήταν σχετικά πιο εύκολη στις αρχές της ύπαρξης του Bitcoin, έχει πλέον γίνει μια πιο απαιτητική διαδικασία η οποία απαιτεί σημαντική επεξεργαστική ισχύ. Ως εκ τούτου, η εξόρυξη γίνεται συχνά από εξειδικευμένα εξοπλισμένα κέντρα, γνωστά φάρμες εξόρυξης, καθιστώντας την απόκτηση Bitcoin μέσω εξόρυξης δύσκολη για τους μέσους χρήστες, οι οποίοι συχνά προτιμούν τις συναλλαγές για την απόκτηση του νομίσματος.

Τα τελευταία χρόνια, το Bitcoin έχει κερδίσει τεράστια δημοτικότητα και η τιμή του έχει εκτοξευθεί σε αστρονομικά επίπεδα. Ξεκινώντας από μηδενική αξία κατά τη δημιουργία του το 2009, το Bitcoin έχει φτάσει να κοστίζει χιλιάδες ευρώ ανά μονάδα, καθιστώντας το ένα από τα πιο πολύτιμα ψηφιακά νομίσματα στον κόσμο. Αυτή η εκρηκτική αύξηση της αξίας του, έχει προσελκύσει την προσοχή επενδυτών, επιχειρήσεων και ακαδημαϊκών, που ενδιαφέρονται να εξερευνήσουν τις δυνατότητες και τις προκλήσεις που προσφέρει αυτό το νέο οικονομικό περιβάλλον.

Η διακύμανση της τιμής του Bitcoin, έχει προκαλέσει μεγάλο ενδιαφέρον στον οικονομικό κόσμο, με πολλές προσπάθειες να γίνουν για την πρόβλεψη της μελλοντικής του τιμής. Ερευνητές και αναλυτές, χρησιμοποιούν διάφορες μεθόδους, από παραδοσιακές οικονομικές θεωρίες μέχρι προηγμένες τεχνικές Μηχανικής Μάθησης, προσπαθώντας να κατανοήσουν και να προβλέψουν τις τάσεις της αγοράς. Η υψηλή μεταβλητότητα του Bitcoin ωστόσο, καθιστά την πρόβλεψη της τιμής του, μια ιδιαίτερα προκλητική διαδικασία, με τους αναλυτές ν' αναζητούν συνεχώς νέες πηγές δεδομένων και μεθοδολογίες οι οποίες έχουν την δυνατότητα να προσφέρουν πιο ακριβείς προβλέψεις.

Στην παρούσα διατριβή, ακολουθήθηκε μια πρωτοποριακή τεχνική που συνδυάζει την ιστορικότητα της τιμής του Bitcoin, με δεδομένα από το Google Trends και από το Twitter (τώρα X) [211], τα οποία αντανakλούν την κοινή γνώμη. Χρησιμοποιώντας αλγόριθμους Μηχανικής Μάθησης, τόσο Βαθιάς όσο και Ρηχής Μάθησης, έγινε μια προσπάθεια ν' αξιοποιηθούν τα εν λόγω δεδομένα προκειμένου να γίνει πρόβλεψη της μελλοντικής τιμής του Bitcoin. Η παραπάνω προσέγγιση ανοίγει νέους δρόμους για την κατανόηση των δυναμικών που κινούν την αγορά ψηφιακών νομισμάτων και προσφέρει σημαντικές προοπτικές για την ανάπτυξη πιο ακριβών μοντέλων πρόβλεψης.

Βάσει των ευρημάτων που παρουσιάζονται στη σύγχρονη βιβλιογραφία, έχει επισημανθεί μια σαφής συσχέτιση μεταξύ της τιμής του Bitcoin και των συ-

ναισθημάτων που εκφράζονται μέσω tweets. [258] Εντυπωσιακά, η ανάλυση των θετικών tweets δείχνει ότι έχουν τη δυνατότητα να προβλέψουν τις μεταβολές στην αξία του Bitcoin, ακόμα και 3 έως 4 ημέρες πριν συμβούν. Παράλληλα, η αξιολόγηση των δεδομένων από το Google Trends, ενισχύει την υπόθεση αυτής της συσχέτισης, αποκαλύπτοντας πως τα δεδομένα αναζητήσεων σχετικά με το Bitcoin συνδέονται άμεσα με τις κινήσεις της αγοράς του. [258]

Επιπροσθέτως, ο Stenqvist και οι συνεργάτες του [358] επιχείρησαν ν' αξιοποιήσουν την ένταση της διακύμανσης του συναισθήματος, με στόχο τη δημιουργία ενός πιο απλοϊκού, αλλά ενδιαφέροντος Μοντέλου Πρόβλεψης. Το μοντέλο αυτό εστιάζει, στην πρόβλεψη των μεταβολών της τιμής του Bitcoin, κατά τη διάρκεια συγκεκριμένων χρονικών περιόδων, εκμεταλλευόμενο τη δυναμική σχέση, μεταξύ συναισθηματικής έντασης και οικονομικής αξίας.

Αυτό το μοντέλο κατάφερε να επιτύχει μια εντυπωσιακή ακρίβεια της τάξης του 83%, αποδεικνύοντας την ικανότητά του να αναλύει και να προβλέπει τις μεταβολές της τιμής του Bitcoin, με βάση την ανάλυση συναισθηματικών δεδομένων από tweets. Ωστόσο, ένας σημαντικός περιορισμός που αναγνωρίστηκε αφορούσε την έλλειψη δεδομένων. Το σύνολο των δεδομένων που χρησιμοποιήθηκε, περιελάμβανε μόνο tweets για μια περίοδο 31 ημερών μεταξύ Μαΐου και Ιουνίου 2017. Ο συγγραφέας της μελέτης επισημαίνει ότι, ο περιορισμένος αριθμός των προβλέψεων που προέκυψαν από αυτό το χρονικό διάστημα, καθιστά την εξαγωγή ουσιαστικών συμπερασμάτων, για την αποτελεσματικότητα του μοντέλου Πρόβλεψης αβάσιμη. Η έλλειψη ευρύτερων δεδομένων, περιορίζει σημαντικά την δυνατότητα γενίκευσης και την αξιοπιστία των συμπερασμάτων, καθιστώντας αναγκαία την περαιτέρω επέκταση της έρευνας σε μελλοντικές μελέτες.

Οι Lamou και οι συνεργάτες του, [214] δημιούργησαν ένα σύνολο δεδομένων, το οποίο περιλάμβανε επικεφαλίδες άρθρων ειδήσεων και tweets σχετικά με τα κρυπτονομίσματα Bitcoin, Litecoin, και Ethereum. Η μελέτη τους εστίασε στην πρόβλεψη της διακύμανσης της αξίας κάθε νομίσματος, χρησιμοποιώντας

προηγμένα μοντέλα Μηχανικής Μάθησης, όπως η Logistic Regression, SVM, και Naïve Bayes. Μοναδικό στοιχείο της προσέγγισής τους, ήταν η κατηγοριοποίηση κάθε tweet και τίτλου ειδήσεων, βάσει των πραγματικών μεταβολών της τιμής μία ημέρα στο μέλλον, χωρίς να λαμβάνεται υπόψη η ανάλυση συναισθήματος.

Αν και το μοντέλο τους, αποδείχθηκε αποτελεσματικό στον εντοπισμό των γενικών τάσεων στις τιμές των νομισμάτων, αντιμετώπισε δυσκολίες στην ακριβή πρόβλεψη των διακυμάνσεων των τιμών που απείχαν από την καταγεγραμμένη γενική τάση. Αυτή η πρόκληση, υπογραμμίζει την πολυπλοκότητα της αγοράς κρυπτονομισμάτων και την ανάγκη για περαιτέρω εξέλιξη των Μοντέλων Πρόβλεψης, για την κατανόηση και προσαρμογή στις μεταβλητές της.

Στην έρευνά τους οι Kim και συνεργάτες [199], επιδόθηκαν στη συλλογή εκτεταμένων δεδομένων σχετικά με το Bitcoin, αποκτώντας πληροφορίες από διαδικτυακά φόρουμ, το Google Trends και τη Wikipedia. Με τη χρήση τεχνικών μοντελοποίησης θεμάτων (Topic Modeling), κατόρθωσαν ν' αναδείξουν σημαντικές λέξεις- κλειδιά και ν' αξιολογήσουν τα κείμενα-δεδομένα, με βάση τη σχέση τους με αυτές τις λέξεις. Ενσωματώνοντας ένα μοντέλο Βαθιάς Μηχανικής Μάθησης, το οποίο επεξεργαζόταν το σύνολο των συλλεχθέντων δεδομένων, κατάφεραν να επιτύχουν μια εντυπωσιακή ακρίβεια της τάξης του 80% στην πρόβλεψη των διακυμάνσεων της τιμής του Bitcoin. Η μεθοδολογία αυτή, υπογραμμίζει την αξία της ενσωμάτωσης διαφορετικών πηγών δεδομένων και της προηγμένης ανάλυσης κειμένου, για την κατανόηση και την πρόβλεψη της αγοραίας συμπεριφοράς στον τομέα των κρυπτονομισμάτων.

Στην προσπάθειά τους να προσδιορίσουν τα πιο σημαντικά χαρακτηριστικά για τις προβλέψεις της τιμής του Bitcoin, οι Mallqui [253] και οι συνεργάτες του εφάρμοσαν μια σειρά από τεχνικές επιλογής χαρακτηριστικών. Χρησιμοποίησαν προηγμένες τεχνικές Μηχανικής Μάθησης, όπως τα Τεχνητά Νευρωνικά Δίκτυα (ANN), τις Μηχανές Διανυσμάτων Υποστήριξης (SVM) και έναν συνδυαστικό αλγόριθμο με βάση τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNN), κα-

θώς και τη μέθοδο ομαδοποίησης k-means, με στόχο την πρόβλεψη των μέγιστων, ελάχιστων και τιμών κλεισίματος του Bitcoin.

Το τελικό αποτέλεσμα της έρευνάς τους, ήταν η ανάπτυξη ενός μοντέλου που κατέγραψε ένα Μέσο Απόλυτο Ποσοστό Σφάλματος (MAPE) μεταξύ 1 και 2%, δείχνοντας εξαιρετική ακρίβεια στην πρόβλεψη των τιμών του Bitcoin. Η επιτυχία αυτού του μοντέλου, υπογραμμίζει την αξία της επιλογής των κατάλληλων χαρακτηριστικών και της εφαρμογής σύνθετων τεχνικών Μηχανικής Μάθησης, για την ακριβή πρόβλεψη της συμπεριφοράς στον τομέα των κρυπτονομισμάτων.

Πρόσφατα, ο McNally [260] εξέτασε την αποτελεσματικότητα διαφόρων Μοντέλων Πρόβλεψης στην εκτίμηση της τιμής του Bitcoin, χρησιμοποιώντας το στατιστικό μοντέλο ARIMA, Επαναλαμβανόμενα Νευρωνικά Δίκτυα, και Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης (LSTM). Το σύνολο δεδομένων του, κάλυπτε την περίοδο από τις 19 Αυγούστου 2013 έως τις 19 Ιουλίου 2016, με τα μοντέλα να εκπαιδεύονται στο 80% των δεδομένων και να αξιολογούνται στο εναπομείναν 20%.

Η σύγκριση των μοντέλων, αποκάλυψε την ανωτερότητα των μοντέλων Μηχανικής Μάθησης, έναντι του ARIMA. Ειδικότερα, το μοντέλο ARIMA σημείωσε ρίζα μέσου τετραγωνικού σφάλματος 53,74%, ενώ τα Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης (LSTM) και τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα εξασφάλισαν σημαντικά χαμηλότερα ποσοστά σφάλματος, στο 6,87% και 5,45% αντίστοιχα.

Σε μια πρόσφατη μελέτη από τους Kwon και συνεργάτες, [212], εφαρμόστηκε ο αλγόριθμος των Νευρωνικών Δικτύων Μακροπρόθεσμης Μνήμης (LSTM), σε χρονοσειρές τιμών κρυπτονομισμάτων με στόχο την ταξινόμησή τους. Η σύγκριση των αποτελεσμάτων του μοντέλου LSTM με εκείνα ενός μοντέλου Ενίσχυση Κλίσης (Gradient Boosting), αποκάλυψε μια βελτίωση της απόδοσης κατά περίπου 7% στις τιμές της μετρικής f1.

Αντίστοιχα, οι Lahmiri και Bekiros [213] εξέτασαν την εφαρμογή τεχνι-

κών Βαθιάς Μηχανικής Μάθησης, στην πρόβλεψη της τιμής των τριών πιο δημοφιλών ψηφιακών νομισμάτων: Bitcoin, Digital Cash, και Ripple. Έλεγξαν για την ύπαρξη μη γραμμικότητας στις χρονοσειρές των νομισμάτων και διαπίστωσαν ότι παρουσιάζουν φράκταλ δυναμική, μεγάλη μνήμη και αυτοομοιότητα. Αρχικά δημιούργησαν μια γενικευμένη Νευρωνική Αρχιτεκτονική Παλινδρόμησης ως σημείο αναφοράς, συγκεκριμένα Νευρωνικά Δίκτυα Γενικής Παλινδρόμησης (GRNN), τα οποία βασίζονται σε πυρήνες Gauss.

Επιπλέον, η μελέτη επεκτάθηκε με τη χρήση Νευρωνικών Δικτύων Μακροπρόθεσμης Μνήμης (LSTM), για τα τρία κρυπτονομίσματα που εξετάστηκαν. Οι συγγραφείς επισήμαναν ότι, η δυνατότητα πρόβλεψης του μοντέλου Βαθιάς Μηχανικής Μάθησης, ήταν σημαντικά υψηλότερη σε σύγκριση με τα General Regression Neural Networks (GRNN) και ότι αποδείχθηκε ιδιαίτερα αποτελεσματικό, στην πρόβλεψη της εγγενούς χαοτικής δυναμικής των αγορών κρυπτονομισμάτων.

Σε μια εμπειρική ανάλυση που πραγματοποιήθηκε από τους Jang και Lee [173], εξετάστηκαν καθημερινά δεδομένα, στην περίοδο από τις 9 Νοεμβρίου 2011 έως τις 22 Αυγούστου 2017, με στόχο την εξερεύνηση των κυριότερων χαρακτηριστικών, που είχαν την δυνατότητα να εξηγήσουν την εξαιρετική αστάθεια που παρουσίασε το Bitcoin κατά τη διάρκεια αυτής της περιόδου. Για τον σκοπό αυτό, ανέπτυξαν ένα Μπαγεσιανό Νευρωνικό Δίκτυο, το οποίο ενσωμάτωσε κάθε σχετικό χαρακτηριστικό από μεταβλητές εισόδου, πληροφορίες Blockchain και μακροοικονομικούς παράγοντες, για την πρόβλεψη της τιμής του Bitcoin. Για την αξιολόγηση του BNN, χρησιμοποιήθηκαν Μηχανές Διανυσμάτων Υποστήριξης (SVR) και η Γραμμική Παλινδρόμηση (Linear Regression).

Τα αποτελέσματα της μελέτης κατέδειξαν ότι το Μπαγεσιανό Νευρωνικό Δίκτυο, ξεπέρασε σημαντικά τις Παραδοσιακές Μεθόδους Πρόβλεψης, όπως οι Μηχανές Διανυσμάτων Υποστήριξης (SVR) και η Γραμμική Παλινδρόμηση. Η αυξημένη απόδοση του BNN αποδείχθηκε κατάλληλη, για την αντιμετώπιση της

πολυπλοκότητας και της αστάθειας της αγοράς κρυπτονομισμάτων, παρέχοντας μια πιο βαθιά και εξειδικευμένη κατανόηση των δυναμικών που διαμορφώνουν τις τιμές του Bitcoin.

Σε μια πρόσφατα δημοσιευμένη μελέτη από τον Shen και την ομάδα του [345], ερευνήθηκε η πιθανή συσχέτιση μεταξύ της τιμής του Bitcoin και του ενδιαφέροντος των επενδυτών, όπως αυτή αντικατοπτρίζεται μέσω του Twitter. Η συλλογή των tweets, έλαβε χώρα στη διάρκεια της περιόδου από τις 4 Σεπτεμβρίου 2014 έως τις 31 Αυγούστου 2018. Για την ανάλυση χρησιμοποιήθηκαν Διανυσματικά Αυτοπαλινδρομικά Μοντέλα (VAR) και το γραμμικό τεστ αιτιότητας Granger, καθώς και το τεστ μη γραμμικής αιτιότητας των Diks και Panchenko.

Από την ανάλυση, προέκυψε ότι υπάρχει συσχέτιση μεταξύ του όγκου των tweets και του όγκου συναλλαγών του Bitcoin. Ωστόσο, οι συγγραφείς διαπίστωσαν ότι δεν υφίστανται σημαντικές ενδείξεις που να υποστηρίζουν την ιδέα ότι τα tweets μπορούν να έχουν άμεση επίδραση στις εκθετικές αποδόσεις του Bitcoin.

5.1 Συλλογή Δεδομένων και Προτεινόμενη Μεθοδολογία

Στα πλαίσια της διατριβής, αναπτύχθηκε ένα πολυμεταβλητό μοντέλο πρόβλεψης για την τιμή του Bitcoin. Το μοντέλο αυτό, διακρίνεται για την ικανότητά του να συνδυάζει πληροφορίες από ποικίλες πηγές, πέρα από τις απλές χρονοσειρές των τιμών, ενσωματώνοντας επίσης στοιχεία από την ανάλυση συναισθήματος δεδομένων του Twitter.

Tweets
Bitcoin Could Revolutionize Governance, Says Cypherpunk Jameson Lopp: According to Jameson... https://goo.gl/fb/55LxMg
Looking at my slightly over a year-old Bitcoin price prediction for the end of 2018, wow, I was way off https://twitter.com/bascule/status/937014918359932928
Buy/Sell Bitcoin changes with up to 100x Leverage at Bitmex! 💎💎 Get 10% Fee Discount: Click here: https://www.bitmex.com/register/zzb3GX \$QTUM \$MTL \$ARK \$DNT \$XLM \$NANO \$MCO \$BTC \$ETH \$ICX \$TRX \$BTC \$NEO \$OMG \$LSK \$NEO \$DASH \$ETH \$NEO \$LINK \$BTC \$ADA \$XRP \$OMG 1546300725 pic.twitter.com/MnqRh1F26e
#Happy2019 #Bitcoin Ends the Year #2018 in the #Red @ \$3742 #GMT Fingers crossed for 2019 #btc pic.twitter.com/jcQXp2Jt9i
Bitcoin, Ripple, Ethereum, Bitcoin Cash, EOS, Stellar, Litecoin, Bitcoin SV, TRON, Cardano: Price Analysis, Dec. 31 http://bit.ly/2EXKqC1

Πίνακας 5.1: Παράδειγμα των μη επεξεργασμένων Tweets

5.1.1 Συλλογή Δεδομένων και Προεπεξεργασία

Η διαδικασία ξεκίνησε με τη συλλογή ενός εκτεταμένου σύνολου δεδομένων από το Twitter, χρησιμοποιώντας την εφαρμογή Twint. Η περίοδος κατά την οποία διεξήχθη η συλλογή κάλυπτε από την 1η Ιανουαρίου 2017 έως την 31η Δεκεμβρίου 2018, καταγράφοντας αρχικά 26.605.988 tweets (Βλ. Πίνακα 5.1).

5.1.1.1 Επεξεργασία Κειμένου

Πριν την ανάλυση των δεδομένων, ήταν απαραίτητο να πραγματοποιηθούν σημαντικά βήματα προεπεξεργασίας για την εξασφάλιση της ποιότητας και της ακρίβειας των αποτελεσμάτων. Η διαδικασία αυτή περιελάμβανε τα εξής βήματα:

- **Αφαίρεση Διπλοτύπων:** Αναγκαίο βήμα για την εξάλειψη δεδομένων που παράχθηκαν από αυτοματοποιημένα συστήματα (bots), μειώνοντας έτσι τον θόρυβο και βελτιώνοντας την ποιότητα του τελικού συνόλου δεδομένων.
- **Εξάριση Ανεπιθύμητων Hashtags:** Αφαίρεση tweets με hashtags που σχετίζονται με ανεπιθύμητο περιεχόμενο ή προωθητικές δραστηριότητες, τα οποία δεν προσφέρουν σημαντική αξία στην ανάλυση.
- **Καθαρισμός Κειμένου:** Κρίσιμο βήμα που περιλαμβάνει την αφαίρεση συνδέσμων, ειδικών χαρακτήρων και άλλων μη σχετικών στοιχείων από τα tweets για να διευκολυνθεί η επεξεργασία του κειμένου.

5.1.1.2 Συναισθηματική Ανάλυση

Στα πλαίσια της προεπεξεργασίας των δεδομένων για την συναισθηματική ανάλυση, χρησιμοποιήθηκαν οι βιβλιοθήκες TextBlob [294] και του NLTK [52]. Και τα δύο εργαλεία εφαρμόζουν τη λεξική προσέγγιση για την αξιολόγηση της πολικότητας των κειμένων, παρέχοντας μία ποσοτική μέτρηση του συναισθήματος από -1 (αρνητικό) έως +1 (θετικό). Συγκεκριμένα τα βήματα που ακολουθεί η λεξική προσέγγιση είναι τα εξής:

- **Αναγνώριση και εξαγωγή λέξεων ή φράσεων από το κείμενο:** Για παράδειγμα, το κείμενο «Αυτή η ταινία ήταν εξαιρετική!» επεξεργάζεται για την εξαγωγή κύριων λέξεων όπως «εξαιρετική». Τούτο επιτυγχάνεται

μέσω της διαδικασίας σχηματισμού λεκτικών μονάδων, διαδικασία κατά την οποία το κείμενο διαιρείται σε μικρότερα κομμάτια, τα tokens.

- **Συσχέτιση κάθε λέξης ή φράσης με τις συναισθηματικές τιμές από το λεξικό:** Η λέξη «εξαιρετική» συσχετίζεται μ' ένα θετικό συναισθηματικό βάρος από το λεξικό. Στο TextBlob, λόγου χάρη, αυτό μπορεί να αντιστοιχίζεται σε μια πολικότητα κοντά στο +1.
- **Υπολογισμός της συνολικής πολικότητας του κειμένου:** Στη συνέχεια, υπολογίζεται η συνολική πολικότητα του κειμένου βάσει των συναισθηματικών τιμών των εντοπισμένων λέξεων. Έτσι, αν το κείμενο περιέχει κυρίως λέξεις με θετικό βάρος, όπως «εξαιρετική», η συνολική πολικότητα θα είναι θετική.
- **Προσαρμογή του σκορ συναισθήματος με βάση το περιεχόμενο και την ένταση:** Τέλος το σκορ του συναισθήματος, προσαρμόζεται ανάλογα με την παρουσία παραγόντων, όπως η ένταση των λέξεων ή η χρήση σημείων στίξης, που ενισχύουν το συναίσθημα. Για παράδειγμα, στη φράση «Αυτή η ταινία ήταν πραγματικά εξαιρετική!!», η λέξη «πραγματικά» και το διπλό θαυμαστικό, ενισχύουν τη θετική πολικότητα οδηγώντας σε υψηλότερο συνολικό σκορ συναισθήματος.

Η κύρια διαφορά μεταξύ του TextBlob και του NLTK έγκειται στο λεξικό που χρησιμοποιούν και την ικανότητα του NLTK ν' αναλύει επιπλέον στοιχεία του κειμένου, όπως σημεία στίξης και κεφαλαία γράμματα, τα οποία μπορούν να ενισχύσουν την ένταση του συναισθήματος. Αυτό το καθιστά ιδιαίτερα κατάλληλο για την ανάλυση κειμένων από social media, όπου η χρήση εικονιδίων (emoticon), συντομογραφιών και άλλων μορφών μη τυπικής γραφής είναι συχνή. Αντίθετα, το TextBlob είναι πιο γενικευμένο εργαλείο, το οποίο παρέχει αξιόπιστα αποτελέσματα σε μια ευρύτερη ποικιλία κειμένων.

Στην παρούσα διατριβή, η χρήση και των δύο εργαλείων επέτρεψε την ανάλυση των tweets με μια ευρύτερη σκοπιά, συνδυάζοντας τις δυνάμεις τους για πιο ολοκληρωμένη κατανόηση του συναισθήματος που εκφράζεται. Το TextBlob χρησιμοποιήθηκε για την αρχική εκτίμηση της πολικότητας και της υποκειμενικότητας των tweets, ενώ το NLTK εφαρμόστηκε, για να προσδιοριστεί με μεγαλύτερη ακρίβεια το συναίσθημα, σε περιπτώσεις όπου η έκφραση ήταν λιγότερο σαφής ή όταν χρησιμοποιήθηκαν μη συμβατικοί τρόποι επικοινωνίας.

Τα αποτελέσματα της ανάλυσης, αποκάλυψαν σημαντικές πληροφορίες σχετικά με τις διακυμάνσεις του συναισθήματος των χρηστών του Twitter, παρέχοντας βαθύτερη κατανόηση της δημόσιας γνώμης.


5.1.1.3 Σύνθεση του Τελικού Συνόλου Δεδομένων

Τέλος τα 7,415,835 επεξεργασμένα tweets (Βλ. Πίνακα 5.2) οργανώθηκαν ανά ημέρα, διευκολύνοντας την επόμενη φάση της ανάλυσης και την αξιοποίηση τους για την εκπαίδευση του Μοντέλου Πρόβλεψης.

Επεξεργασμένα Tweets
Bitcoin Could Revolutionize Governance Says Cypherpunk Jameson Lopp According to Jameson
Looking at my slightly over a year old Bitcoin price prediction for the end of 2018 wow I was way off
Buy Sell Bitcoin changes with up to 100x Leverage at Bitmex Get 10 Fee Discount Click here QTUM MTL ARK DNT XLM NANO MCO BTC ETH ICX TRX BTC NEO OMG LSK NEO DASH ETH NEO LINK BTC ADA XRP OMG 1546300725 pic twitter com MnqRh1F26e
Happy2019 Bitcoin Ends the Year 2018 in the Red 3742 GMT Fingers crossed for 2019 btc
Bitcoin Ripple Ethereum Bitcoin Cash EOS Stellar Litecoin Bitcoin SV TRON Cardano Price Analysis Dec 31


Πίνακας 5.2: Το ίδιο παράδειγμα από Tweets μετά την προεπεξεργασία

Επιπρόσθετα, συμπεριλήφθηκε στην ανάλυση, ένα σετ δεδομένων που αφορούσε το ιστορικό τιμών του Bitcoin (Βλ. Εικόνα 5.2) και τα δεδομένα των



Σχήμα 5.1: Δεδομένα για το Bitcoin από το Google Trends

Google Trends [205] (Βλ. Εικόνα 5.1). Τα δεδομένα Google Trends, οργανώνονται σε μια κλίμακα από 1 έως 100 και αντικατοπτρίζουν το επίπεδο ενδιαφέροντος αναζήτησης για το Bitcoin σε παγκόσμιο επίπεδο, με βάση τον αριθμό των αναζητήσεων κάθε ημέρα.



Σχήμα 5.2: Η πορεία της τιμής του Bitcoin από την 1η Ιανουαρίου 2017 έως την 31η Δεκεμβρίου 2018

Το τελικό σύνολο δεδομένων, όπως παρουσιάζεται στον Πίνακα 5.3, ενσωματώνει τέσσερα κύρια χαρακτηριστικά: τον μέσο όρο των συναισθηματικών αξιών που προέκυψαν από την ανάλυση με τη βοήθεια του NLTK, τον μέσο όρο των συναισθηματικών αξιών που προέκυψαν από την ανάλυση με τη βοήθεια του

TextBlob, τις αξίες από τα Google Trends, και τις τιμές του Bitcoin της προηγούμενης ημέρας.

Τιμή	Πόλωση Textblob	Google Trends	Πόλωση NLTK
962.94	0.097	46	0.106
1002.99	0.096	74	0.092
1012.00	0.103	69	0.106
1021.44	0.077	81	0.076
1090.00	0.085	100	0.072
974.86	0.065	82	0.028

Πίνακας 5.3: Δείγμα του Τελικού Συνόλου Δεδομένων

5.1.2 Προσεγγίσεις Μοντέλων Πρόβλεψης

Στο πλαίσιο της ερευνητικής ανάλυσης, εξετάστηκαν τρεις διαφορετικές μεθοδολογικές προσεγγίσεις για την πρόβλεψη της τιμής του Bitcoin:


1. **Βαθιά Μηχανική Μάθηση με LSTM:** Αρχικά δοκιμάστηκε ένα μοντέλο Βαθιάς Μηχανικής Μάθησης, χρησιμοποιώντας Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNN) και συγκεκριμένα Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης (LSTM) [156]. Οι υπερπαραμέτροι του μοντέλου συντονίστηκαν με τη χρήση της βιβλιοθήκης hyperas, με ειδική προσοχή στην αποφυγή υπερπροσαρμογής (overfitting).
2. **Παλινδρόμηση Ενίσχυσης Κλίσης (Gradient Boosting Regression):** Ως δεύτερη προσέγγιση, χρησιμοποιήθηκε ένα μοντέλο Παλινδρόμησης Ενίσχυσης Κλίσης [120], με τις υπερπαραμέτρους να συντονίζονται μέσω της βιβλιοθήκης hyperopt. Η τεχνική της πρόωρης διακοπής, εφαρμόστηκε για την αποφυγή υπερπροσαρμογής.
3. **XGBoost:** Τέλος δοκιμάστηκε ένα μοντέλο XGBoost [71], με τις υπερπαραμέτρους να ρυθμίζονται επίσης μέσω της βιβλιοθήκης hyperopt [202]. Η

πρόωρη διακοπή χρησιμοποιήθηκε και εδώ για την αποφυγή υπερπροσαρμογής.

Κάθε μία από αυτές τις μεθόδους αξιολογήθηκε με βάση την ικανότητά της να προβλέπει ακριβώς την τιμή του Bitcoin, χρησιμοποιώντας ένα σύνολο δεδομένων το οποίο περιλαμβάνει τόσο το ιστορικό τιμών όσο και δείκτες ενδιαφέροντος από τις Google Τάσεις ή την συναισθηματική ανάλυση που έγινε στα tweets.

5.2 Πειράματα, Αποτελέσματα και Σχολιασμός

Στα προηγούμενα κεφάλαια, έχουν αναλυθεί μια σειρά από αλγόριθμους και μεθοδολογίες πρόβλεψης, οι οποίες έχουν την προοπτική να εντοπίσουν και να μοντελοποιήσουν την πορεία της τιμής του Bitcoin. Στην προσπάθεια κατανόησης των προκλήσεων και των δυνατοτήτων που παρουσιάζουν οι επιλεγμένοι αλγόριθμοι, έχουν σχεδιαστεί και εφαρμοστεί μια σειρά από πειράματα τα οποία αποτυπώνονται στο παρακάτω διάγραμμα ροής. (Βλ. Εικόνα 5.3)



Σχήμα 5.3: Διάγραμμα ροής της διαδικασίας εκπαίδευσης και επικύρωσης των μοντέλων πρόβλεψης της τιμής του Bitcoin.

5.2.1 Πειράματα και Αποτελέσματα

Για την εκπαίδευση (training) των μοντέλων, χρησιμοποιήθηκε το 80% των δεδομένων, ενώ από αυτό το ποσοστό, το 25% αποφασίστηκε να χρησιμοποιηθεί για επικύρωση (validation). Το εναπομείναν 20% των δεδομένων αξιοποιήθηκε για τις δοκιμές (testing). Αρχικά, δοκιμάστηκε ένα μοντέλο, βασισμένο σε προηγούμενες μελέτες, όπως αυτή του McNally [260]. Το μοντέλο αυτό, το οποίο εκπαι-

δεύτηκε χρησιμοποιώντας μόνο την προηγούμενη τιμή του Bitcoin, στηρίχθηκε σε δύο στρώματα LSTM [346] και βελτιστοποιήθηκε με τη βοήθεια της βιβλιοθήκης Hyperas, επιτυγχάνοντας στα δεδομένα δοκιμής *ρίζα μέσου τετραγωνικού σφάλματος (RMSE)* 1, 583%. (Βλ. Εικόνα 5.4α')


Σε δεύτερη φάση, εκπαιδεύτηκε και βελτιστοποιήθηκε ένα παρόμοιο δίκτυο LSTM, το οποίο συμπεριέλαβε όλα τα διαθέσιμα χαρακτηριστικά που προέκυψαν από την ανάλυση συναισθήματος των tweets και τα δεδομένα τάσεων της Google. Το μοντέλο αυτό πέτυχε σημαντικά καλύτερα αποτελέσματα, με σφάλμα 0, 999% στα δεδομένα δοκιμής. (Βλ. Εικόνα 5.4β')

Επίσης, ακολουθήθηκε παρόμοια διαδικασία για την εξέταση ενός μοντέλου Ενίσχυσης Κλίσης αρχικά, χρησιμοποιώντας μόνο την προηγούμενη τιμή του Bitcoin. Μετά από βελτιστοποίηση των υπερπαραμέτρων, το μοντέλο επέτυχε σφάλμα 2, 030% στα δεδομένα δοκιμής (Βλ. Εικόνα 5.5α'). Αντίστοιχα, η δημιουργία ενός προηγμένου μοντέλου Ενίσχυσης Κλίσης όπου ενσωμάτωσε όλα τα νέα χαρακτηριστικά, οδήγησε σε σφάλμα 2, 206% μετά την βελτιστοποίηση των υπερπαραμέτρων. (Βλ. Εικόνα 5.5β')


Τέλος, αναπτύχθηκαν δύο μοντέλα XGBoost ακολουθώντας την ίδια μεθοδολογία με τα μοντέλα Ενίσχυσης Κλίσης. Τα εν λόγω μοντέλα κατέγραψαν *ρίζα μέσου τετραγωνικού σφάλματος (RMSE)* 1, 798% για το μονομεταβλητό μοντέλο (Βλ. Εικόνα 5.6α') και 2, 656% για το πολυμεταβλητό (Βλ. Εικόνα 5.6β'). Όλα τα αποτελέσματα παρουσιάζονται συνοπτικά στον Πίνακα 5.4, δείχνοντας τη σημαντική επίδραση της επιλογής χαρακτηριστικών και της βελτιστοποίησης των υπερπαραμέτρων στην απόδοση των μοντέλων Μηχανικής Μάθησης.

Αλγόριθμος	Μονομεταβλητό	Πολυμεταβλητό
LSTM	1.583	0.999
Gradient Boosting	2.030	2.206
XGBoost	1.798	2.656

Πίνακας 5.4: Όλα τα Αποτελέσματα




(α') LSTM με μια μεταβλητή




(β') LSTM με όλες τις μεταβλητές

Σχήμα 5.4: Αποτελέσματα προβλέψεων μοντέλου LSTM για το Bitcoin.




(α') Gradient Boosting με μια μεταβλητή




(β') Gradient Boosting με όλες τις μεταβλητές

Σχήμα 5.5: Αποτελέσματα προβλέψεων μοντέλου Gradient Boosting για το Bitcoin.



(α') XGBoost με μια μεταβλητή



(β') XGBoost με όλες τις μεταβλητές

Σχήμα 5.6: Αποτελέσματα προβλέψεων μοντέλου XGBoost για το Bitcoin.

5.2.2 Σχολιασμός Αποτελεσμάτων

Συνοψίζοντας όπως παρατηρήθηκε και τα δύο ρηχά μοντέλα παρουσίασαν χειρότερα αποτελέσματα σε σύγκριση με το Βαθύ Επαναλαμβανόμενο Νευρωνικό Δίκτυο, ανεξάρτητα από την παρουσία ή όχι των επιπλέον χαρακτηριστικών. Ένα ενδιαφέρον εύρημα, ήταν ότι η προσθήκη νέων χαρακτηριστικών έδειξε να μπερδεύει τα μοντέλα αυτά, χωρίς να προσφέρει κάποια εμφανή βελτίωση. Από τα παραπάνω γραφήματα δεν παρατηρούνται σημαντικές διαφορές, ούτε οι αλγοριθμικές προβλέψεις αποδείχθηκαν αποτελεσματικές στο να προσεγγίσουν την πραγματική τιμή του Bitcoin (Βλ. Εικόνα 5.5α', 5.5β', 5.6α', 5.6β')

Αντίθετα, το δίκτυο LSTM, εκμεταλλεύτηκε επιτυχώς τα νέα χαρακτηριστικά, βελτιώνοντας σημαντικά το σφάλμα του. Στις παραπάνω εικόνες (Βλ. Εικόνα 5.4α', 5.4β'), φαίνεται η αξιοσημείωτη βελτίωση στις προβλέψεις του Νευρωνικού Δικτύου όταν χρησιμοποιούνται τα πρόσθετα χαρακτηριστικά.

Εν κατακλείδι αναλύοντας τα γραφήματα και συγκρίνοντας τα αποτελέσματα, μπορούμε με βεβαιότητα να οδηγηθούμε στο συμπέρασμα ότι η αξιοποίηση του συναισθήματος από τα tweets και τα δεδομένα από το Google Trends, σε συνδυασμό με την προηγούμενη τιμή του Bitcoin και τη χρήση ενός κατάλληλου αλγορίθμου, έχουν την δυνατότητα να ενισχύσουν την απόδοση για την πρόβλεψη μελλοντικών τιμών του Bitcoin.

Καταλήγοντας, με την ανάλυση αυτή ενισχύονται προηγούμενες μελέτες, όπως [258, 358], οι οποίες υποστήριξαν ότι η ανάλυση συναισθήματος από tweets ή η χρήση δεδομένων όπως τα Google Trends συσχετίζονται με τη μελλοντική τιμή του Bitcoin.

Κεφάλαιο 6

Εφαρμογή της Μεθόδου της Αλληλουχίας (Cascade) σε Δεδομένα Χρονοσειρών

Οι προσεγγίσεις πρόβλεψης χρονοσειρών μεμονωμένων μοντέλων συχνά αντιμετωπίζουν την ευαισθησία στο θόρυβο, τις ακραίες τιμές και τις προκλήσεις που δημιουργούνται από τα δεδομένα, οδηγώντας σε ανακριβείς και μη ισχυρές προβλέψεις, ειδικά σε σύνθετα και μη γραμμικά σενάρια χρονοσειρών [291]. Ο συνδυασμός δύο ή περισσότερων μοντέλων σε μια ενοποιημένη αρχιτεκτονική, έχει γίνει κοινή πρακτική για να ξεπεραστούν αυτές οι προκλήσεις. Η Αλληλουχία (Cascading) [124] και η Ψηφοφορία (Voting) [92] είναι δύο συνδυαστικές τεχνικές, καθεμία από τις οποίες στοχεύει στη βελτίωση της ακρίβειας και της ευρωστίας της πρόβλεψης. Η ψηφοφορία περιλαμβάνει τον υπολογισμό του μέσου όρου των προβλέψεων από πολλαπλά μοντέλα, ενώ η αλληλουχία, που ανήκει στην οικογένεια αλγορίθμων στοίβαξης, συνεπάγεται διαδοχική εκπαίδευση πολλαπλών μοντέλων Παλινδρόμησης. Κάθε μοντέλο βελτιώνει τις προβλέψεις του προηγούμενου, οδηγώντας σε επαναληπτικές βελτιώσεις στην ακρίβεια πρόβλεψης. Σε κάθε βήμα, το σύνολο δεδομένων επεκτείνεται προσθέτοντας νέα χαρακτηριστικά που προέρχονται από τις εξόδους των προηγούμενων αναδρομών.

Η παρούσα διατριβή, εφαρμόζει την αλληλουχία για την πρόβλεψη χρονοσειρών, παρουσιάζοντας μια νέα και ισχυρή προσέγγιση για το συνδυασμό Μοντέλων Πρόβλεψης. Κατά την αξιολόγηση, οι παραδοσιακοί αλγόριθμοι Μη-

χανικής Μάθησης—Τυχαίο Δάσος (Random Forest, RF) [58], Μηχανή Ενίσχυσης Κλίσης (Gradient Boosting Machine, GBM) [119], Δέντρα Ενισχυμένης Κλίσης (eXtreme Gradient Boosting, XGB) [72] και Παλινδρόμηση Διανύσματος Υποστήριξης (Support Vector Regression, SVR) [97]—ομαδοποιήθηκαν σε ζεύγη για να αξιολογήσουν την προτεινόμενη προσέγγιση.

Η απόδοση της προτεινόμενης προσέγγισης, έναντι των συμβατικών μεθόδων μέσου όρου δύο μοντέλων, αξιολογήθηκε μετρώντας την ρίζα μέσου τετραγωνικού σφάλματός τους (RMSE) σ' ένα σύνολο δεδομένων χρονοσειρών, όπου περιλάμβανε δεδομένα οδικής κυκλοφορίας, κατανάλωσης ενέργειας, πληρότητας χώρων στάθμευσης, θερμοκρασίας και υγρασίας, ηλιακής παραγωγής, δεδομένα ανεμογεννητριών, παροχή ρεύματος, μετρήσεις θερμοκρασίας απο συσκευές Διαδικτύου των πραγμάτων (IoT) και κυκλοφορία ταξί. Επιπλέον, χρησιμοποιήθηκε μια δοκιμή Friedman για να αναλυθούν στατιστικά οι διαφορές στην απόδοση μεταξύ των μεθόδων. Τα αποτελέσματα έδειξαν ότι η προσέγγιση αλληλουχίας πέτυχε γενικά καλύτερη απόδοση από την ψηφοφορία, αν και οι παρατηρούμενες διαφορές δεν είχαν στατιστική σημασία. Ωστόσο, η σταθερή τάση υποδηλώνει ότι η αλληλουχία μπορεί να θεωρηθεί αξιόπιστη εναλλακτική λύση έναντι της ψηφοφορίας, επιδεικνύοντας τις δυνατότητές της ως αποτελεσματική στρατηγική, για την βελτίωση της πρόβλεψης χρονοσειρών σ' ένα ευρύ φάσμα πολύπλοκων και δυναμικών σεναρίων.

Σύμφωνα με τους Allende και Valle [16], τα οφέλη από την ενοποίηση μοντέλων για την πρόβλεψη χρονοσειρών αποδίδονται σε τρεις βασικούς παράγοντες. Πρώτον η συνολική ακρίβεια των προβλέψεων ενισχύεται σημαντικά μέσω της χρήσης κατάλληλων τεχνικών. Δεύτερον σε καταστάσεις όπου είναι αβέβαιο ποιο Μοντέλο Πρόβλεψης είναι το βέλτιστο, η χρήση συνδυαστικών στρατηγικών αποδεικνύεται ως η καταλληλότερη εναλλακτική λύση. Τρίτον η συγχώνευση πολλαπλών προβλέψεων ελαχιστοποιεί τα λάθη αποτελεσματικά.

Η χρήση συνδυαστικών μεθόδων για πρόβλεψη, μπορεί να δικαιολογηθεί

με διάφορους τρόπους, όπως η ενίσχυση της ικανότητας γενίκευσης των αποτελεσμάτων, η μείωση της διακύμανσης του μοντέλου και η αύξηση της ανοχής στο θόρυβο των δεδομένων [261]. Ο συνδυασμός μοντέλων στην πρόβλεψη χρονοσειρών περιλαμβάνει διάφορες μεθοδολογίες. Στην παρούσα ενότητα, εστιάζουμε στην ψηφοφορία και στη συνέχεια στην αλληλουχία, ως εναλλακτική λύση.

6.0.1 Ψηφοφορία

Η Ψηφοφορία αποτελεί μια διαδεδομένη μέθοδο, εμπνευσμένη από την Μπεϋζιανή θεωρία μάθησης, η οποία υποστηρίζει τη μεγιστοποίηση της προγνωστικής ακρίβειας, χρησιμοποιώντας ολόκληρο τον χώρο της υπόθεσης αντί να βασίζεται σε ένα και μοναδικό Μοντέλο Μάθησης [14]. Στον τομέα της πρόβλεψης χρονοσειρών, υπάρχουν αρκετές εξέχουσες παραλλαγές της μεθόδου ψηφοφορίας [16], συμπεριλαμβανομένων ενδεικτικά:

1. Απλός Μέσος Όρος: Η πρόβλεψη κάθε βασικού Μοντέλου Παλινδρόμησης, συμβάλλει εξίσου στην τελική πρόβλεψη για μία παρατήρηση.
2. Περικομμένος Μέσος Όρος: Οι μικρότερες και μεγαλύτερες προβλέψεις για μία παρατήρηση, αφαιρούνται πριν από τον υπολογισμό του μέσου όρου.
3. Μέσος Όρος Παραθύρου: Οι τιμές των μικρότερων και μεγαλύτερων προβλέψεων για μια παρατήρηση, περιορίζονται πριν υπολογιστεί ο μέσος όρος, χρησιμοποιώντας τις προβλέψεις που βρίσκονται πλησιέστερα στις εν λόγω τιμές.
4. Σταθμισμένος Μέσος Όρος: Σε κάθε βασικό Μοντέλο Παλινδρόμησης, εκχωρείται ένα βάρος που μπορεί να ποικίλει δυναμικά, με βάση ορισμένα κριτήρια, ενισχύοντας έτσι τον αντίκτυπό του στη συνολική πρόβλεψη.

Στην έρευνα του [130], αναπτύχθηκε μια προηγμένη προσέγγιση συνδυασμού μοντέλων, γνωστή ως Γενικευμένο Εκθετικά Τακτοποιημένο Σύστημα Γενι-

κής Παλινδρόμησης Νευρωνικών Δικτύων (GEFTS-GRNN). Η μεθοδολογία αυτή, υιοθετεί ένα δυναμικό σχήμα ψηφοφορίας με μη γραμμική στάθμιση, συνδυάζοντας τις εκροές από διαφορετικά GRNN βασικού επιπέδου μέσω της χρήσης ενός meta-GRNN, για την παραγωγή της τελικής πρόβλεψης. Η εν λόγω προσέγγιση δοκιμάστηκε σε αντιπαράθεση με έντεκα κοινώς χρησιμοποιούμενους αλγορίθμους, πάνω σε τριάντα σύνολα δεδομένων, επιδεικνύοντας την υπεροχή της, στην πρόβλεψη χρονοσειρών με εποχιακά μοτίβα.

Ο Παπαγεωργίου και συνεργάτες παρουσίασαν μια πρωτοποριακή μεθοδολογία συνδυασμού προβλέψεων, με σκοπό την ακριβέστερη εκτίμηση της κατανάλωσης φυσικού αερίου [304]. Η προσέγγισή τους, μια υβριδική λύση, που ενσωματώνει Εξελικτικούς Ασαφείς Γνωστικούς Χάρτες (FCM) και Τεχνητά Νευρωνικά Δίκτυα (ANN), κατάφερε να ξεπεράσει σε απόδοση μεμονωμένες μεθόδους όπως τα ANN, τα FCM και τα Δίκτυα Μακροπρόθεσμης Μνήμης (LSTMs).

Παράλληλα, εισήχθη μια καινοτόμος χρονικά σταθμισμένη μέθοδος ψηφοφορίας, η οποία λαμβάνει υπ' όψη την γήρανση των πληροφοριών, στοχεύοντας στην παραγωγή «κερδοφόρων μοντέλων πρόβλεψης τάσεων» και στη βελτίωση της διαδικασίας λήψης αποφάσεων για μεγάλες οικονομικές χρονοσειρές [314]. Τα πειράματα που διεξήχθησαν με δεδομένα από διάφορους χρηματιστηριακούς δείκτες, απέδειξαν ότι η μέθοδος ψηφοφορίας με σταθμισμένους κανόνες, ξεπέρασε σε απόδοση τις μεμονωμένες μεθόδους.

Στον τομέα των χρονοσειρών μεγάλων δεδομένων, οι Galicia και συνεργάτες, παρουσίασαν μια συνδυαστική μέθοδο η οποία ενσωματώνει τρεις διαφορετικές τεχνικές: Δέντρα Απόφασης (Decision Trees, DT), Δέντρα Ενισχυμένης Κλίσης (Gradient Boosted Trees, GBT) και Τυχάιο Δάσος (Random Forest, RF) [123]. Ο συνδυασμός των μοντέλων αυτών, προσδιόρισε τα βάρη μέσω μιας σταθμισμένης μεθόδου ελαχίστων τετραγώνων, προσφέροντας τη δυνατότητα για στατικές ή δυναμικές ενημερώσεις των βαρών. Η προσέγγιση αυτή επιδείχθηκε αποτελεσματική, τόσο σε δυναμικά όσο και σε στατικά σύνολα δεδομένων κατανάλωσης

ηλεκτρικής ενέργειας καθώς και ηλιακής ενέργειας.

Οι Larrea και συνεργάτες εξέτασαν, την εφαρμογή ενός συνδυαστικού μοντέλου Ακραίας Μηχανικής Μάθησης (ELM), χρησιμοποιώντας μια μέθοδο υπολογισμού βαρών, για τον καθορισμό του μέσου όρου και Βελτιστοποίησης Σμήνους Σωματιδίων (Particle Swarm Optimization) για την προσαρμογή παραμέτρων [217]. Η αποτελεσματικότητα αυτού του συνόλου, αποδείχθηκε μέσω πειραματικών δοκιμών στο σύνολο δεδομένων λείζερ Santa Fe και στο σύνολο δεδομένων πρόβλεψης ηλεκτρικής κατανάλωσης της Ισπανίας.

Τέλος στη μελέτη του Phyo et al. [312], αρχικά πραγματοποιήθηκε αξιολόγηση διάφορων αλγορίθμων Παλινδρόμησης. Στη συνέχεια, δημιουργήθηκε ένα μοντέλο ψηφοφορίας, επιλέγοντας τις καλύτερες διαθέσιμες επιλογές. Αυτό το συνδυαστικό μοντέλο συγκρίθηκε με έξι αυτόνομα μοντέλα, δείχνοντας ανώτερες επιδόσεις σε σχέση με αυτά, βάσει των πειραματικών αποτελεσμάτων που αναλύθηκαν. Τα δεδομένα για την ανάλυση προήλθαν από τομείς ενέργειας και καιρού σε τέσσερις διαφορετικές περιοχές του νησιού Jeju.

6.0.2 Αλληλουχία

Η Αλληλουχία Cascade [124], αποτελεί μέρος της οικογένειας των αλγορίθμων στοίβαξης. Η τεχνική αυτή συνεπάγεται την διαδοχική εκπαίδευση πολλών μοντέλων, όπου η έξοδος κάθε μοντέλου, ενσωματώνεται ως είσοδος στο αμέσως επόμενο μοντέλο της αλληλουχίας, σε συνδυασμό με τα αρχικά δεδομένα. Η παραπάνω διαδικασία επαναλαμβάνεται επανειλημμένα, μέχρι τη δημιουργία ενός τελικού μοντέλου πρόβλεψης, το οποίο ικανοποιεί τις απαιτήσεις ακρίβειας.

Όσον αφορά τις μελέτες αλληλουχίας για δυαδική ταξινόμηση, οι Zhao και Ram [434] παρουσίασαν έναν γενικό αλγόριθμο για περιορισμένη αλληλουχία δέντρων απόφασης. Ο Αλγόριθμος αυτός, επέτρεψε την εκμάθηση ενδιάμεσων εννοιών, εξερευνώντας διάφορες στρατηγικές σύζευξης, όπως η χαλαρή και η σφιχτή σύζευξη. Η εμπειρική αξιολόγηση της τεχνικής με τη χρήση λογιστι-

κής παλινδρόμησης και C4.5 ως βασικών αλγορίθμων σε 32 σύνολα δεδομένων, αποκάλυψε ότι καμία από τις στρατηγικές σύζευξης δεν υπερτερεί. Σε επακόλουθη μελέτη [435], οι ίδιοι συγγραφείς επεκτείνουν την προσέγγισή τους, στην αντιστοίχιση οντοτήτων από ετερογενείς πηγές δεδομένων, επιτυγχάνοντας σημαντική αποτελεσματικότητα στον χειρισμό ετερογενών και «βρώμικων» δεδομένων. Από την άλλη πλευρά, ο Balogun και συνεργάτες εισήγαγαν ένα Λειτουργικό Δέντρο βασισμένο στην αλληλουχία (CG-FT) για την ανίχνευση επιθέσεων phishing [37], προσφέροντας μια νέα προοπτική στην ασφάλεια ιστού.

Η αλληλουχία έχει εφαρμοστεί εκτενώς, για δυαδική ταξινόμηση στον τομέα της υγειονομικής περίθαλψης, παρέχοντας σημαντικές προοπτικές στην ανίχνευση και διάγνωση διαφόρων νοσημάτων. Μελέτες όπως αυτή των Nugroho et al. [285] πρότειναν, μια στρατηγική αλληλουχίας για την ανίχνευση καρκίνου του μαστού, με βάση τη μαστογραφία. Επίσης οι Aziz et al. [32], επιβεβαίωσαν τα οφέλη της χρήσης αλληλουχίας για την ανίχνευση καρκίνου του μαστού, επισημαίνοντας την αποτελεσματικότητά της ειδικά σε σύνολα δεδομένων με κυρίαρχους αριθμητικούς παράγοντες πρόβλεψης. Αντίστοιχα, η μελέτη για την ανίχνευση στεφανιαίας νόσου χρησιμοποίησε C4.5 και RIPPER ως μέρος μιας προσέγγισης αλληλουχίας [286]. Συμπληρωματικά η μελέτη των Kraipeerapun et al. [204], πρότεινε δύο προσεγγίσεις για την επιλογή μεθόδου κρυοθεραπείας στη θεραπεία των κονδυλωμάτων, ενσωματώνοντας Νευρωνικά Δίκτυα, σε επίπεδο βάσης αλλά και στο μέτα-επίπεδο στην αλληλουχία. Η προσέγγιση των Nilnumpetch et al. [280], όπου εισήχθη το Νευρωνικό Δίκτυο εξόδου Cascade Generalization Duo (CG-DONN), αντιμετώπισε την ανίχνευση καρκίνου με επιτυχία. Τέλος η πρόσφατη μελέτη των Nilnumpetch et al. [282], ανέπτυξε μια διαδικασία δυαδικής ταξινόμησης, σε σύνολα δεδομένων σχετικά με την υγεία, χωρίς τη χρήση τιμών κατωφλίου. Η προσέγγιση αυτή συνδύασε την ισχύ των Νευρωνικών Δικτύων με την ευελιξία της αλληλουχίας, για την αντιμετώπιση προκλήσεων, στην πρόβλεψη και ταξινόμηση υγειονομικών δεδομένων.

Ενώ η Αλληλουχία έχει αποδειχθεί μια ισχυρή στρατηγική στα πλαίσια της δυαδικής ταξινόμησης, η προσαρμοστικότητά της επεκτείνεται επίσης σε προκλήσεις ταξινόμησης πολλαπλών κλάσεων. Η ευελιξία αυτής της μεθόδου αποδεικνύεται, μέσω της εφαρμογής της σε διάφορους τομείς, από την γεωργία μέχρι την υγειονομική περίθαλψη. Οι Corrales et al. [79] προσέγγισαν το πρόβλημα της σκουριάς του καφέ στον αγροτικό τομέα, προτείνοντας έναν εμπειρικό πολυταξινομητή ο οποίος χρησιμοποιεί την Αλληλουχία. Επίσης η ενσωμάτωση της Αλληλουχίας σε συμπληρωματικά Νευρωνικά Δίκτυα, παρουσίασε μια πιο περίπλοκη προσέγγιση για τη βελτίωση της ταξινόμησης πολλαπλών κλάσεων, σε τρία διαφορετικά προβλήματα όπως περιγράφεται από Nilnumpetch et al. [281].

Στο πλαίσιο των συνδυαστικών μεθόδων για την ανάλυση χρονοσειρών, οι Ribeiro et al. [327] εισήγαγαν το TimeStacking, μια νέα προσέγγιση Στοιβαγμένης Αλληλουχίας, για την ταξινόμηση χρονοσειρών. Η εν λόγω μεθοδολογία επέκτεινε τον Παραδοσιακό Αλγόριθμο Στοιβαξης, ενσωματώνοντας προηγούμενες προβλέψεις από τα βασικά μοντέλα, για την ενίσχυση της απόδοσης ταξινόμησης σε δεδομένα συνεχών χρονοσειρών. Η εν λόγω εργασία υπογράμμισε τα οφέλη των μετα-μοντέλων, στην ευρύτερη σφαίρα της ανάλυσης χρονοσειρών και τις θετικές επιδράσεις της ποικιλομορφίας των μοντέλων που επιτυγχάνονται μέσω των συνδυαστικών μεθόδων. Στην περίπτωση της ταξινόμησης πολυμεταβλητών χρονοσειρών (MTS), οι Fauvel et al. [113] ανέπτυξαν τη μέθοδο eXplainable-by-Design Ensemble (XEM), χρησιμοποιώντας τη μέθοδο Υβριδικού Συνόλου Local Cascade Ensemble (LCE). Η XEM υπερέβη τους ταξινομητές MTS τελευταίας γενιάς σε δημόσια δεδομένα UEA.

Πέρα από την εφαρμογή της, σε παραδοσιακές εργασίες ταξινόμησης, η Αλληλουχία έχει επίσης εξερευνηθεί στον τομέα των συστημάτων συστάσεων (recommendation systems), προσφέροντας μια νέα προοπτική για τη βελτίωση των αλληλεπιδράσεων χρήστη-αντικειμένου. Πιο συγκεκριμένα, οι Tsihrintzis et

al. [215] παρουσίασαν ένα νέο υβριδικό σύστημα Συστάσεων Αλληλουχίας, το οποίο συνδυάζει τα δυνατά σημεία της ταξινόμησης μιας κλάσης με το συνεργατικό φιλτράρισμα. Το σύστημά τους είναι δομημένο σε δύο επίπεδα, όπου το αρχικό στάδιο χρησιμοποιεί έναν ταξινομητή μιας κλάσης, για να φιλτράρει τα επιθυμητά στοιχεία, με βάση τις αραιές προτιμήσεις των χρηστών. Ακολούθως εφαρμόζεται συνεργατικό φιλτράρισμα στο βελτιωμένο σύνολο στοιχείων, για την πρόβλεψη των βαθμολογιών αξιολόγησης, βελτιώνοντας σημαντικά την ακρίβεια των προτάσεων, σε σχέση με το Μέσο Απόλυτο Σφάλμα (MAE). Επεκτείνοντας την ιδέα αυτή, ο Σωτηρόπουλος και ο Τσιχρίντζης [356] χρησιμοποίησαν στη συνέχεια το πλαίσιο της Μηχανικής Μάθησης Τεχνητού Ανοσοποιητικού Συστήματος (AIS) ως μέρος μιας Αρχιτεκτονικής Αλληλουχίας. Ένας ταξινομητής μιας κλάσης βασισμένος στο AIS, εντόπιζε αρχικά ένα υποσύνολο στοιχείων που ανταποκρίνονταν στις προτιμήσεις των χρηστών, χωρίς την ανάγκη για αρνητική ανατροφοδότηση. Κατόπιν ένας ταξινομητής πολλαπλών κλάσεων βασισμένος σε Νευρωνικά Δίκτυα, βελτίωνε περαιτέρω τις συστάσεις, αποδεικνύοντας την προσαρμοστικότητα της Αλληλουχίας στη δημιουργία εξατομικευμένων εμπειριών για τους χρήστες. Αμφότερες οι μελέτες ανέδειξαν την ικανότητα της Αλληλουχίας, στην βελτίωση των αλληλεπιδράσεων χρήστη-αντικειμένου σε συστήματα συστάσεων, μέσω της διαδικασίας φιλτραρίσματος και ταξινόμησης σε επίπεδα.

6.1 Προτεινόμενη Μεθοδολογία

Στην ενότητα αυτή, με γνώμονα τις προκλήσεις που είναι εγγενείς στην παραδοσιακή πρόβλεψη χρονοσειρών, παρουσιάζεται η μεθοδολογία η οποία χρησιμοποιεί την Αλληλουχία, για τη βελτίωση της ακρίβειας των προβλέψεων χρονοσειρών. Η Αλληλουχία έχει εφαρμοστεί με επιτυχία σε διάφορες εργασίες ταξινόμησης, όπως συζητήθηκε παραπάνω. Ωστόσο, η εφαρμογή της στην Παλινδρόμηση και ιδιαίτερα στην πρόγνωση χρονοσειρών, παραμένει λιγότερο εξερευνημένη. Μέσω της προσαρμογής της Αλληλουχίας για την αντιμετώπιση των ειδικών προκλήσεων της ανάλυσης χρονοσειρών, σκοπός είναι η ανάδειξη των δυνατοτήτων της, στην αποτύπωση πολύπλοκων χρονικών δυναμικών και στην αντιμετώπιση των μοναδικών προκλήσεων, που τίθενται από τα δεδομένα τα οποία εξαρτώνται από το χρόνο, επιδιώκοντας έτσι τη βελτίωση της προγνωστικής ακρίβειας.

Η προσέγγισή βασίζεται στις αρχές των Αλγορίθμων Στοίβαξης και συγκεκριμένα στην Αλληλουχία. Επιδιώκει την επαναληπτική βελτίωση των προβλέψεων, μέσω της διαδοχικής εκπαίδευσης μοντέλων Παλινδρόμησης. Η διαδοχική αρχιτεκτονική, επιτρέπει την ενσωμάτωση μαθησιακών πληροφοριών από προηγούμενα στάδια, προσαρμόζοντας προοδευτικά τα μοντέλα, στις πολυπλοκότητες που υπάρχουν στα δεδομένα χρονοσειρών. Ζεύγη ευρέως χρησιμοποιούμενων αλγορίθμων, επιλέγονται για τις αποδεδειγμένες δυνάμεις τους, στη μοντελοποίηση μη γραμμικών σχέσεων και δεδομένων υψηλών διαστάσεων, όπως Ενίσχυση Κλίσης (Gradient Boosting), Δέντρα Ενίσχυση Κλίσης (XGBoost), Παλινδρόμηση Διανυσμάτων Υποστήριξης (Support Vector Regressor - SVR) και Τυχαία Δάση (Random Forests), τα οποία λειτουργούν ως βασικά και δευτερεύοντα μοντέλα εντός της Αλληλουχίας. Μέσα από εκτεταμένους πειραματισμούς σε δέκα διαφορετικά σύνολα δεδομένων, η μελέτη αποδεικνύει την αποτελεσματικότητα των μοντέλων Αλληλουχίας για την πρόβλεψη χρονοσειρών και επιδεικνύει την

υπεροχή τους, έναντι της πιο συχνά εφαρμοζόμενης στρατηγικής της ψηφοφορίας.

6.1.1 Περιγραφή Δεδομένων και Προεπεξεργασία

Για τη διασφάλιση μιας ολοκληρωμένης αξιολόγησης της προτεινόμενης προσέγγισης πρόβλεψης χρονοσειρών, χρησιμοποιήθηκε ένα σύνολο από δέκα σέτ δεδομένων, τα οποία αντιπροσωπεύουν διαφορετικούς τομείς, όπως η κυκλοφορία, η ενέργεια, η στάθμευση αυτοκινήτων και οι περιβαλλοντικοί παράγοντες. Η παρούσα ενότητα, περιγράφει τα χαρακτηριστικά των συνόλων δεδομένων και τα βήματα προεπεξεργασίας που εφαρμόστηκαν για τη βελτίωση της καταλληλότητάς τους όσον αφορά την άσκηση της πρόβλεψης.

6.1.1.1 Επισκόπηση Συνόλων Δεδομένων

Ο Πίνακας 6.1 παρουσιάζει μια επισκόπηση των δέκα συνόλων δεδομένων που χρησιμοποιήθηκαν στην παρούσα μελέτη. Τα μεγέθη των συνόλων δεδομένων διαφέρουν, κυμαινόμενα από λίγες χιλιάδες έως δεκάδες χιλιάδες γραμμές και καλύπτουν ευρύ φάσμα τομέων, όπως μοτίβα οδικής κυκλοφορίας, κατανάλωση ενέργειας και περιβαλλοντικές συνθήκες.

Δεδομένα	Γραμμές	Τομέας
Traffic	48120	Traffic
Power Consumption of Turkey	40272	Energy
Energy Consumption	32896	Energy
Parking Occupancy	9437	Car Parking
Temperature and Humidity of Kolkata	52439	Environment
Solar Generation in Italy	16944	Energy
Wind Turbine Texas	7096	Energy
Power Supply of Joho	17350	Energy
IOT Temperature Readings	2674	Environment
NYC Taxi Traffic	4991	Traffic

Πίνακας 6.1: Σέτ Δεδομένων

6.1.1.2 Χρονικό Πλαίσιο και Παραγωγή Χαρακτηριστικών

Δεδομένου ότι όλα τα σύνολα δεδομένων περιέχουν ωριαίες μετρήσεις, η χρήση ενός χρονικού παραθύρου των τελευταίων 168 ωρών (που αντιστοιχεί σε μία εβδομάδα) θεωρήθηκε ζωτικής σημασίας για τη δημιουργία ακριβών προβλέψεων τιμών για την επόμενη ώρα.

2.1 Χειρισμός τιμών που λείπουν

Προτού τα δεδομένα τροφοδοτηθούν στα μοντέλα, υλοποιήθηκαν βήματα προεπεξεργασίας, με στόχο τη διασφάλιση της ποιότητάς τους. Οι ελλείπουσες τιμές (NaN) αφαιρέθηκαν συστηματικά για την προστασία της ακεραιότητας των δεδομένων.

2.2 Παραγωγή Χαρακτηριστικών

Για τη βελτίωση των χρονικών πληροφοριών που παρέχονται στα Μοντέλα Πρόβλεψης, αναπτύχθηκαν χειροκίνητα τα εξής χαρακτηριστικά βασισμένα στον χρόνο:

1. Χαρακτηριστικά βάσει ώρας:

- ▶ hour: Η τρέχουσα ώρα παρατήρησης.
- ▶ next_hour: Η τιμή την επόμενη ώρα.
- ▶ prev_hour: Η τιμή της προηγούμενης ώρας.

2. Χαρακτηριστικά βάσει ημέρας:

- ▶ day: Η ημέρα του μήνα.
- ▶ day_of_week: Η ημέρα της εβδομάδας.
- ▶ day_of_year: Η ημέρα του χρόνου.
- ▶ next_day: Η τιμή για την ίδια ώρα την επόμενη μέρα.
- ▶ prev_day: Η τιμή για την ίδια ώρα της προηγούμενης ημέρας.

3. Χαρακτηριστικά βάσει εβδομάδας:

- ▶ week_of_year: Η εβδομάδα του χρόνου.
- ▶ next_week: Η τιμή για την ίδια ώρα την επόμενη εβδομάδα.
- ▶ prev_week: Η τιμή για την ίδια ώρα την προηγούμενη εβδομάδα.

4. Χαρακτηριστικά βάσει μήνα:

- ▶ month: Ο μήνας της παρατήρησης.

5. Χαρακτηριστικά βάσει έτους:

- ▶ year: Το έτος της παρατήρησης.

Τα παραπάνω χαρακτηριστικά ενσωματώθηκαν στα σύνολα δεδομένων, προσδίδοντας στα μοντέλα ένα πλούσιο χρονικό πλαίσιο το οποίο είναι κρίσιμο για την καταγραφή των υποκείμενων προτύπων. Τα εν λόγω χαρακτηριστικά διευκολύνουν την αναγνώριση τάσεων, εποχικότητας και κυκλικών μοτίβων στα δεδομένα χρονοσειρών, ζωτικής σημασίας για την πρόβλεψη μελλοντικών τιμών.

6.1.2 Γενίκευση της Αλληλουχίας για την Πρόβλεψη Χρονοσειρών

Η Αλληλουχία είναι μέλος της οικογένειας Αλγορίθμων Στοίβαξης. Η γενίκευση της Στοίβαξης, όπως ορίζεται από τον Wolpert [396], προσφέρει ένα γενικό πλαίσιο για την ενσωμάτωση πολλαπλών προβλεπτικών μοντέλων και για την ενημέρωση των επόμενων σταδίων μοντελοποίησης. Η γενίκευση της Αλληλουχίας μπορεί να θεωρηθεί ως μια εξειδικευμένη μορφή γενίκευσης Στοίβαξης. Σε αντίθεση με την παραδοσιακή Στοίβαξη, όπου κάθε μοντέλο επικεντρώνεται αποκλειστικά στα αποτελέσματα του προηγούμενου, στην Αλληλουχία κάθε νέο μοντέλο, χρησιμοποιεί τόσο τα αρχικά δεδομένα όσο και τις πληροφορίες που παράγονται από τα προηγούμενα μοντέλα. Η αρχική πρόταση της Αλληλουχίας [124] εστίαζε στην ταξινόμηση, όπου η έξοδος παίρνει διακριτές τιμές από ένα

σύνολο καθορισμένων κλάσεων δηλαδή, όπου η μεταβλητή εξόδου Y λαμβάνει τιμές από ένα σύνολο προκαθορισμένων τιμών/κλάσεων $\{C_1, \dots, C_k\}$, με C_i να δηλώνει την κλάση i και k τον αριθμό των κλάσεων.

Στην παρούσα διατριβή, η Αλληλουχία προσαρμόζεται για την πρόβλεψη χρονοσειρών, με τη μεταβλητή εξόδου Y να λαμβάνει πλέον συνεχείς τιμές. Έστω D το σύνολο δεδομένων εκπαίδευσης, που αποτελείται από ζεύγη (X_i, Y_i) , όπου X_i είναι ένα διάνυσμα εισόδου με πολλαπλές μεταβλητές στη χρονική στιγμή i με m χαρακτηριστικά και Y_i είναι η σχετική μεταβλητή συνεχούς εξόδου. Ένας αλγόριθμος παλινδρόμησης αποτελεί μια συνάρτηση που αντιστοιχίζει τον χώρο εισόδου X κάθε χρονική στιγμή στη μεταβλητή συνεχούς εξόδου Y . Η προβλεπόμενη τιμή του Y για το δείγμα X_i σε κάθε χρονική στιγμή αναπαρίσταται ως $\mathcal{P}(X_i, D)$.

Ο εποικοδομητικός τελεστής $\phi(X_i, M)$, όπου M αντιπροσωπεύει το μοντέλο που προέρχεται από τον παλινδρομητή βάσει των δεδομένων εκπαίδευσης D και X_i είναι ένα δείγμα εισόδου, συγχωνεύει το X_i με την εκτιμώμενη συνεχή τιμή. Το M περιλαμβάνει τις σχέσεις και τα μοτίβα που αποκαλύφθηκαν μέσα από την εκπαίδευση, αντικατοπτρίζοντας τη συσσωρευμένη γνώση, ενώ ο αλγόριθμος παλινδρόμησης $\mathcal{R}(D)$ αναφέρεται στην επιλεγμένη συνάρτηση παλινδρόμησης. Αυτός ο τελεστής εφαρμόζεται σε κάθε δείγμα του συνόλου δεδομένων D , δημιουργώντας έτσι το νέο εμπλουτισμένο σύνολο δεδομένων $D_{\text{augmented}}$. Το νέο σύνολο δεδομένων που δημιουργείται, περιλαμβάνει όλα τα δείγματα που εμφανίζονται στο D , επαυξημένα με τις προβλεπόμενες συνεχείς τιμές οι οποίες παράγονται από το μοντέλο M . Ο πληθάρθρωμος του $D_{\text{augmented}}$ είναι ίσος με τον πληθάρθρωμο του D , δηλαδή έχουν τον ίδιο αριθμό δειγμάτων και κάθε δείγμα $X_i \in D_{\text{augmented}}$ έχει ένα αντίστοιχο δείγμα στο D , το οποίο έχει επαυξηθεί μ' ένα νέο συνεχές χαρακτηριστικό που αντιπροσωπεύει την προβλεπόμενη τιμή. Αυτό το νέο χαρακτηριστικό είναι η προβλεπόμενη τιμή που προκύπτει από την εφαρμογή του παλινδρομητή $\mathcal{R}(D)$ στο δείγμα X_i . Μαθηματικά, η παραπάνω

διαδικασία εκφράζεται όπως απεικονίζεται στην Εξίσωση 6.1.

$$D_{\text{augmented}} = \phi(D, M) = \{(X_i, y_i, \hat{y}_i) \mid (X_i, y_i) \in D, \hat{y}_i = \mathcal{R}(D)(X_i) = M(X_i)\} \quad (6.1)$$

Είναι κρίσιμο να τονιστεί, ότι η διαδικασία επαύξησης του συνόλου δεδομένων, όπως ορίζεται από τον τελεστή ϕ , μπορεί να εφαρμοστεί επαναληπτικά πολλαπλές φορές. Σε κάθε επανάληψη εκπαιδεύεται ένας νέος αλγόριθμος παλινδρόμησης, χρησιμοποιώντας το επαυξημένο σύνολο δεδομένων, παρέχοντας την ευκαιρία για την εφαρμογή διαφορετικών αλγορίθμων ή μοντέλων παλινδρόμησης σε κάθε στάδιο. Στην εν λόγω διατριβή, εστιάζουμε σε μια προσέγγιση Αλληλουχίας δύο επιπέδων, όπου η διαδικασία εκπαίδευσης εφαρμόζεται δύο φορές. Η διαδικασία δύο επιπέδων οδηγεί σε μία εφαρμογή του τελεστή ϕ , οδηγώντας σ' ένα επαυξημένο σύνολο δεδομένων που ενσωματώνει προβλεπόμενες συνεχείς τιμές από δύο στάδια παλινδρόμησης. Η επαναληπτική αυτή μέθοδος, παρέχει τη δυνατότητα ευελιξίας στην επιλογή των αλγορίθμων ή των μοντέλων παλινδρόμησης για κάθε επίπεδο, ενισχύοντας την προσαρμοστικότητα της μεθοδολογίας της Αλληλουχίας στις προκλήσεις της πρόβλεψης χρονοσειρών.

Η Αλληλουχία για μια δομή 2 επιπέδων, προσαρμοσμένη για πρόβλεψη χρονοσειρών, είναι μια διαδοχική σύνθεση αλγορίθμων παλινδρόμησης και εκτελείται ως εξής:

Φάση εκπαίδευσης:

1. Εκπαίδευση του πρώτου μοντέλου (Επίπεδο 1):

Εκπαιδεύεται το M_1 , το πρώτο μοντέλο, με την εφαρμογή του παλινδρομητή R_1 στο αρχικό σύνολο δεδομένων εκπαίδευσης D . Τούτο μαθηματικά αποτυπώνεται ως:

$$M_1 = R_1(D)$$

2. Υλοποίηση προβλέψεων με το M_1 στο σύνολο δεδομένων εκπαίδευ-

σης:

Από το M_1 , μόλις αυτό έχει εκπαιδευτεί, προκύπτουν προβλέψεις για το αρχικό σύνολο δεδομένων εκπαίδευσης D :

$$P_1 = M_1(D)$$

3. Κατασκευή του επαυξημένου συνόλου δεδομένων εκπαίδευσης:

Το σύνολο δεδομένων εκπαίδευσης D επαυξάνεται με την ενσωμάτωση των προβλέψεων από το M_1 , δημιουργώντας το $D_{\text{augmented}}$:

$$D_{\text{augmented}} = \phi(D, M_1)$$

4. Εκπαίδευση του δεύτερου μοντέλου (Επίπεδο 2):

Στο δεύτερο επίπεδο, εκπαιδύεται ένα διαφορετικό μοντέλο M_2 με την εφαρμογή της μεθόδου R_2 , στο επαυξημένο σύνολο δεδομένων εκπαίδευσης $D_{\text{augmented}}$:

$$M_2 = R_2(D_{\text{augmented}})$$

Φάση δοκιμής: Με δεδομένο ένα νέο και αχρησιμοποίητο σύνολο δεδομένων δοκιμής D_{test} , το επόμενο βήμα είναι η πραγματοποίηση των προβλέψεων και η αξιολόγηση της απόδοσης του μοντέλου σε άγνωστα δεδομένα.

1. Υλοποίηση προβλέψεων με το M_1 στο σύνολο δεδομένων δοκιμής:

Το εκπαιδευμένο M_1 χρησιμοποιείται για την πραγματοποίηση προβλέψεων στο σύνολο δεδομένων δοκιμής D_{test} :

$$P_{1_test} = M_1(D_{\text{test}})$$

2. Κατασκευή του επαυξημένου συνόλου δεδομένων δοκιμής:

Τα αρχικά δεδομένα δοκιμής D_{test} επαυξάνονται με τη συγχώνευσή τους με

τις προβλέψεις από το M_1 , δημιουργώντας το $D_{\text{augmented_test}}$:

$$D_{\text{augmented_test}} = \phi(D_{\text{test}}, M_1)$$

3. Πραγματοποίηση των τελικών προβλέψεων με το M_2 στο σύνολο δεδομένων δοκιμής:

Το M_2 χρησιμοποιείται για την πραγματοποίηση των τελικών προβλέψεων στο δοκιμαστικό σύνολο δεδομένων, χρησιμοποιώντας το επαυξημένο σύνολο δεδομένων:

$$\text{Τελική πρόβλεψη} = M_2(D_{\text{augmented_test}})$$

Συνεπώς διενεργείται διαδοχική εκπαίδευση δύο μοντέλων, με το πρώτο να παράγει προβλέψεις, βασιζόμενο στα ιστορικά δεδομένα και το δεύτερο να βελτιώνει αυτές τις προβλέψεις, μέσω της ενσωμάτωσης τόσο των ιστορικών πληροφοριών όσο και των προβλέψεων από το πρώτο μοντέλο. Αυτό το διαδοχικό σχήμα εφαρμόζεται στη συνέχεια σε δεδομένα τα οποία δεν έχουν προηγουμένως εξεταστεί. Η εν λόγω πολυεπίπεδη προσέγγιση, αποσκοπεί στη βελτίωση της ακρίβειας των προβλέψεων για τις χρονοσειρές.

6.1.3 Πειραματική Αξιολόγηση

Στην συγκεκριμένη ενότητα, αναλύεται ολιστικά η πειραματική αξιολόγηση, με έμφαση στη σύγκριση της Αλληλουχίας, μ' ένα παραδοσιακό συνδυαστικό μοντέλο ψηφοφορίας. Σκοπός είναι η εξέταση των δυνατοτήτων και των περιορισμών κάθε προσέγγισης, όσον αφορά την ακρίβεια και την ευρωστία των προβλέψεων.

Πριν την εκπαίδευση και την αξιολόγηση, τα σύνολα δεδομένων υποβλήθηκαν σε μια διεξοδική διαδικασία προετοιμασίας. Η διαδικασία αυτή περιλάμ-

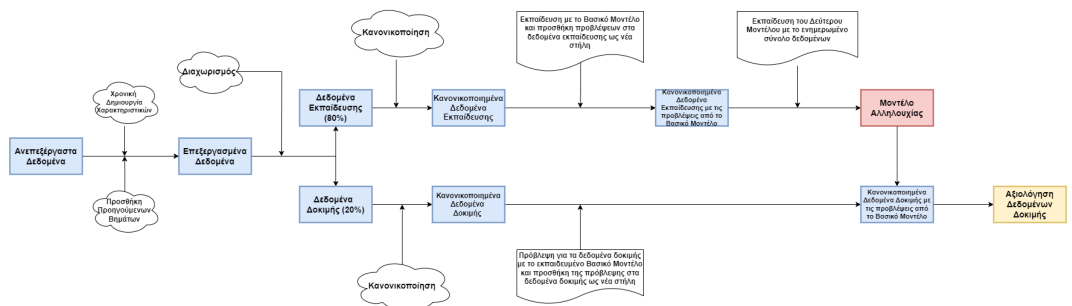
βανε την εφαρμογή ενός προκαθορισμένου διαχωρισμού για την εκπαίδευση και τη δοκιμή των δεδομένων, όπου το 80% των δεδομένων αφιερώθηκε στην εκπαίδευση και το υπόλοιπο 20% στην αξιολόγηση. Επιπρόσθετα, πραγματοποιήθηκε κανονικοποίηση για να εξασφαλιστεί η εναρμόνιση των χαρακτηριστικών σε μια κοινή κλίμακα, αποφεύγοντας έτσι τη δυνατότητα κάποια χαρακτηριστικά να επηρεάζουν δυσανάλογα την εκπαίδευση του μοντέλου.

Για την εκτίμηση της ακρίβειας της πρόβλεψης, εφαρμόστηκε η μεθοδολογία της ρίζας του μέσου τετραγωνικού σφάλματος (RMSE), η οποία ορίζεται μαθηματικά ως:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}$$

στην οποία, n συμβολίζει τον συνολικό αριθμό των παρατηρήσεων στο σετ δοκιμών.

Το Σχήμα 6.1 αποτυπώνει την πειραματική διαδικασία, συμπεριλαμβανομένης της εφαρμογής του προτεινόμενου αλγορίθμου γενίκευσης Αλληλουχίας για την πρόβλεψη δεδομένων χρονοσειρών.



Σχήμα 6.1: Προτεινόμενη Μεθοδολογία.

Τα μοντέλα που χρησιμοποιήθηκαν ήταν η Ενίσχυση Κλίσης (Gradient Boosting), Δέντρα Ενίσχυση Κλίσης (XGBoost), Παλινδρόμηση Διανυσμάτων Υποστήριξης (Support Vector Regressor - SVR) και Τυχαία Δάση (Random Forests). Ερευνήθηκε η αποδοτικότητα της γενίκευσης Αλληλουχίας μέσω της αξιολόγησης

σης 12 διαφορετικών συνδυασμών Αλληλουχίας. Στη διαδικασία αυτή, κάθε ένα από τα μοντέλα χρησιμοποιήθηκε ως το αρχικό μοντέλο σε συνδυασμό μ' ένα άλλο μοντέλο, για τη δημιουργία του συνδυαστικού μοντέλου Αλληλουχίας. Αυτοί οι συνδυασμοί συγκρίθηκαν με τους μέσους όρους των αποδόσεων των αντίστοιχων μοντέλων, παρέχοντας εικόνα για την επιρροή κάθε συνδυασμού στην τελική απόδοση.

Για την επιβεβαίωση των διαπιστωθέντων διαφορών, υποβλήθηκαν σε στατιστική ανάλυση, με τη διενέργεια του Friedman Test (Δοκιμή Friedman) για τη γενική αξιολόγηση της απόδοσης και την εφαρμογή επακόλουθων δοκιμασιών post-hoc για μια πιο αναλυτική κατανόηση. Οι αναλύσεις αυτές αποδείχθηκαν καθοριστικές, για τον προσδιορισμό της στατιστικής σημαντικότητας των διαφορών, ανάμεσα στην Αλληλουχία (Cascade Generalization) και το συνδυαστικό μοντέλο Ψηφοφορίας (Voting Ensemble).

6.2 Αποτελέσματα και Συζήτηση

Αναλύεται λεπτομερώς η απόδοση της γενίκευσης Αλληλουχίας, αρχίζοντας με την παρουσίαση συνοπτικών αποτελεσμάτων από το τεστ Friedman (Πίνακας 6.2), για την ανάδειξη της συγκριτικής απόδοσης μεταξύ της Αλληλουχίας και των μεθόδων Ψηφοφορίας σε διάφορους συνδυασμούς αλγορίθμων. Επιπλέον, διεξάγεται ανάλυση post-hoc (Πίνακας 6.3) για τον προσδιορισμό της στατιστικής σημαντικότητας των εν λόγω διαφορών. Ακολουθεί εμβάθυνση στην αποτελεσματικότητα κάθε συνδυασμού μοντέλων, μέσω της αξιολόγησης της πρωτογενούς απόδοσής τους ως προς το RMSE σε όλα τα σύνολα δεδομένων, αναγράφονται στους Πίνακες 6.12-6.15.

6.2.1 Τεστ Friedman και post hoc ανάλυση

Τα αποτελέσματα από το τεστ Friedman (Πίνακας 6.2) επιβεβαιώνουν μια προτίμηση προς την Αλληλουχία (Cascade) έναντι της Ψηφοφορίας στην πρόβλεψη χρονοσειρών, με την Αλληλουχία να υπερτερεί στην πλειονότητα των συγκρίσεων (επικρατώντας 6 φορές έναντι 2 για την ψηφοφορία, με 4 ισοπαλίες). Εντυπωσιακό είναι ότι η Αλληλουχία ξεπερνά ή ισούται της ψηφοφορίας σε όλες τις περιπτώσεις που περιλαμβάνουν το SVR σε συνδυασμό με άλλα μοντέλα, δείχνοντας μια συνέργεια κατά την οποία επωφελείται από την διαδικασία διαδοχικής βελτίωσης. Αντίθετα στον συνδυασμό «Random Forest & XGBoost» και το αντίστροφο, ο μέσος όρος φαίνεται πιο αποτελεσματικός συνολικά, τονίζοντας την ευρωστία και την απλότητα της εφαρμογής του. Περαιτέρω, η ανάλυση post-hoc (Πίνακας 6.3) αποκαλύπτει, πως οι διαπιστωμένες διαφορές στην κατάταξη μεταξύ της Αλληλουχίας (Cascade) και της Ψηφοφορίας (Voting), δεν ήταν πάντα στατιστικά σημαντικές. Τούτο υποδηλώνει ότι, παρά το γεγονός πως η Αλληλουχία ενδέχεται να προσφέρει κάποια πλεονεκτήματα σε συγκεκριμένες περιστάσεις, τα οφέλη αυτά δεν είναι εγγυημένα να ισχύουν σε κάθε περίπτωση

Comparison	Method	Value
Gradient Boosting & Random Forest	Cascade	1.5
	Averaging	1.5
Gradient Boosting & SVR	Cascade	1.4
	Averaging	1.6
Gradient Boosting & XGBoost	Cascade	1.3
	Averaging	1.7
Random Forest & Gradient Boosting	Cascade	1.5
	Averaging	1.5
Random Forest & SVR	Cascade	1.5
	Averaging	1.5
Random Forest & XGBoost	Averaging	1.1
	Cascade	1.9
SVR & Gradient Boosting	Cascade	1
	Averaging	2
SVR & Random Forest	Cascade	1.1
	Averaging	1.9
SVR & XGBoost	Cascade	1.1
	Averaging	1.9
XGBoost & Gradient Boosting	Cascade	1.4
	Averaging	1.6
XGBoost & Random Forest	Averaging	1.3
	Cascade	1.7
XGBoost & SVR	Averaging	1.5
	Cascade	1.5

Πίνακας 6.2: Αποτελέσματα test Friedman.

ή για κάθε δοκιμασμένο συνδυασμό μοντέλων και σε όλα τα σύνολα δεδομένων. Αυτό υποδεικνύει μια σημαντική ποικιλία στην απόδοση, εξαρτώμενη από τα συγκεκριμένα χαρακτηριστικά και τη δυσκολία του προβλήματος, καθώς και από τις ιδιότητες των επιλεγμένων μοντέλων.

6.2.2 Ακατέργαστα Αποτελέσματα

Εξετάζονται εκτενώς οι λεπτομερείς πτυχές της απόδοσης του μοντέλου μέσω της ανάλυσης των τιμών της Ρίζας Μέσου Τετραγωνικού Σφάλματος (RMSE) που προκύπτουν στα διάφορα σύνολα δεδομένων, όπως αναφέρεται λεπτομερώς

Comparison	P-Value (Averaging vs Cascade)
Gradient Boosting & Random Forest	0.9203443254
Gradient Boosting & SVR	0.8414805811
Gradient Boosting & XGBoost	0.6891565168
Random Forest & Gradient Boosting	1
Random Forest & SVR	1
Random Forest & XGBoost	0.1336144025
SVR & Gradient Boosting	0.1615133185
SVR & Random Forest	0.3681202507
SVR & XGBoost	0.3681202507
XGBoost & Gradient Boosting	1
XGBoost & Random Forest	0.2301393404
XGBoost & SVR	0.9203443254

Πίνακας 6.3: Αποτελέσματα post-hoc ανάλυσης.

στους Πίνακες 6.5 έως 6.15. Η ανάλυση αυτή, αποσκοπεί στην αποκάλυψη πληροφοριών, σχετικά με τα δυνατά σημεία και τους περιορισμούς της μεθόδου γενίκευσης της Αλληλουχίας. Για τον λόγο αυτόν, τα ακατέργαστα αποτελέσματα κατηγοριοποιούνται σε τρεις ομάδες. Η πρώτη ομάδα περιλαμβάνει συνδυασμούς μοντέλων όπου υπερτερεί η Αλληλουχία σε σύγκριση με την Ψηφοφορία, η δεύτερη ομάδα περιλαμβάνει περιπτώσεις όπου η Ψηφοφορία υπερτερεί της Αλληλουχίας και η τρίτη ομάδα αποτελείται από συνδυασμούς, όπου διαπιστώνεται συγκρίσιμη αποδοτικότητα μεταξύ των δύο μεθόδων.

6.2.2.1 Η Αλληλουχία υπερτερεί της Ψηφοφορίας

Κατά το τεστ Friedman η Αλληλουχία, αποδείχθηκε ανώτερη σε σχέση με την Ψηφοφορία, στους μισούς από τους εξεταζόμενους συνδυασμούς μοντέλων (6 στους 12). Αναλυτικότερα, τα αποτελέσματα έδειξαν ότι η Αλληλουχία υπερέχει στις ακόλουθες περιπτώσεις:

1. XGBoost & Gradient Boosting (Πίνακας 6.4) - 6/10 περιπτώσεις
2. Gradient Boosting & SVR (Πίνακας 6.5) - 6/10 περιπτώσεις
3. Gradient Boosting & XGBoost (Πίνακας 6.6) - 7/10 περιπτώσεις
4. SVR & Random Forest (Πίνακας 6.7) - 9/10 περιπτώσεις

5. SVR & XGBoost (Πίνακας 6.8) - 9/10 περιπτώσεις

6. SVR & Gradient Boosting (Πίνακας 6.9) - 10/10 περιπτώσεις

Στους πίνακες 6.4, 6.5, και 6.6, παρατηρήθηκε ότι, παρ'όλο που η Αλληλουχία συχνά υπερέχει της Ψηφοφορίας, οι διαφορές στην απόδοση είναι συχνά περιορισμένες. Ειδικότερα ο Πίνακας 6.4 (XGBoost & Gradient Boosting) αποκαλύπτει ένα ξεκάθαρο πλεονέκτημα της Αλληλουχίας στο σύνολο δεδομένων «Power», με το RMSE να φτάνει το 415,1 σε αντίθεση με το 534,0 της Ψηφοφορίας, δηλώνοντας μια σημαντική βελτίωση. Ωστόσο για το σύνολο δεδομένων «Taxi», η Ψηφοφορία επιδεικνύει καλύτερη απόδοση με RMSE 992,6 σε σύγκριση με το 1019,9 της Αλληλουχίας, ενώ τα υπόλοιπα σύνολα δεδομένων εμφανίζουν μικρές διαφορές στην απόδοση. Ο Πίνακας 6.5 (Gradient Boosting & SVR) επισημαίνει την επιτυχία της Αλληλουχίας στο σύνολο δεδομένων «Parking», όπου το RMSE είναι 670,0, αρκετά κατώτερο από το 828,9 Αλληλουχίας σε αυτή την περίπτωση. Για το σύνολο δεδομένων «Energy», το RMSE που προέκυψε από την Αλληλουχία ήταν 4655,9, το οποίο αποδείχθηκε σημαντικά υψηλότερο από το 2606,6 το οποίο επιτεύχθηκε με την Ψηφοφορία. Τούτο υποδηλώνει ότι σε συγκεκριμένες περιστάσεις, όπως είναι το σύνολο δεδομένων «Energy», οι επιλεγμένοι συνδυασμοί μοντέλων εντός της προσέγγισης της Αλληλουχίας, δεν καταφέρνουν να προσφέρουν την αναμενόμενη βελτίωση, ενδεχομένως επιδεινώνοντας την απόδοση. Αντίθετα, στον Πίνακα 6.6 (Gradient Boosting & XGBoost), τα αποτελέσματα εμφανίζουν μια ξεκάθαρη υπεροχή της Αλληλουχίας για το σύνολο δεδομένων «Energy», με το RMSE να μειώνεται από 444,9 σε 399,4, επιβεβαιώνοντας τη δυνατότητα της μεθόδου για διαδοχική βελτίωση της απόδοσης του μοντέλου. Επιπρόσθετα το σύνολο δεδομένων «Power» αποδεικνύει και πάλι το πλεονέκτημα της μεθόδου με RMSE 403,9, σε σύγκριση με το 534,0 της Ψηφοφορίας.

Στους πίνακες 6.7, 6.8, 6.9, η κυριαρχία της Αλληλουχίας επιβεβαιώνεται έντονα. Η συνεπής απόδοση σε σχεδόν όλα τα σύνολα δεδομένων για αυτούς

Dataset	Base	Second Model	Cascade	Averaging
Traffic	4.056	4.228	4.083	4.023
Energy	417.0	572.8	421.1	444.9
Power	421.2	745.3	415.1	534.0
Parking	492.1	517.8	495.5	478.4
Kolkata	0.503	0.566	0.510	0.514
Solar	244.5	288.8	246.1	246.9
Turbine	329.3	304.4	333.4	309.2
Joho	1337.6	1489.2	1302.1	1309.5
Iot	1.178	2.073	1.177	1.498
Taxi	1011.7	1102.4	1019.9	992.6

Πίνακας 6.4: XGBoost & Gradient Boosting RMSE

Dataset	Base	Second Model	Cascade	Averaging
Traffic	4.228	5.129	4.292	4.436
Energy	572.8	5064.0	4655.9	2606.6
Power	745.3	2878.1	1400.6	1611.6
Parking	517.8	1385.7	670.0	828.9
Kolkata	0.566	0.550	0.528	0.534
Solar	288.8	2631.7	1379.4	1347.7
Turbine	304.4	860.1	382.2	504.3
Joho	1489.2	13009.3	12514.3	6648.5
Iot	2.073	2.657	2.113	2.271
Taxi	1102.4	6762.6	6324.5	3552.3

Πίνακας 6.5: Gradient Boosting & SVR RMSE

Dataset	Base	Second Model	Cascade	Averaging
Traffic	4.228	4.056	3.971	4.023
Energy	572.8	417.0	399.4	444.9
Power	745.3	421.2	403.9	534.0
Parking	517.8	492.1	543.1	480.1
Kolkata	0.566	0.503	0.505	0.514
Solar	288.8	244.5	257.4	246.8
Turbine	304.4	329.3	318.6	309.1
Joho	1489.2	1337.6	1307.3	1309.5
Iot	2.073	1.178	1.376	1.513
Taxi	1102.4	1011.7	954.6	999.9

Πίνακας 6.6: Gradient Boosting & XGBoost RMSE

τους συνδυασμούς μοντέλων, δείχνει ότι η μέθοδος διακρίνεται όχι μόνο για τη δύναμή της, αλλά και για την προσαρμοστικότητά της, καθιστώντας την ως ένα ιδανικό εργαλείο για πληθώρα προβλημάτων πρόβλεψης. Οι σημαντικές βελτιώσεις στις τιμές RMSE που παρατηρήθηκαν, επισημαίνουν την ανάγκη για εξέταση της μεθόδου σε καταστάσεις όπου η ακριβής πρόβλεψη είναι ζωτικής σημασίας και οι υπάρχουσες διαδικασίες των δεδομένων είναι αρκετά περίπλοκες, ώστε να επωφεληθούν από τις δυνατότητες επαναλαμβανόμενης βελτίωσης που προσφέρει η μέθοδος.

Προχωρώντας σε πιο λεπτομερείς παρατηρήσεις, ο Πίνακας 6.7 (SVR & Random Forest) εμφανίζει μια σημαντική υπεροχή της μεθόδου, καθώς επικρατεί σε 9 από τα 10 σύνολα δεδομένων. Στο σύνολο δεδομένων «Power», η Αλληλουχία παρουσιάζει RMSE 264,6, αποτελώντας δραματική βελτίωση έναντι του 1465,8 της μεθόδου Ψηφοφορίας. Σε ανάλογο τρόπο, ο Πίνακας 6.8 (SVR & XGBoost) αποδεικνύει την αποδοτικότητα της μεθόδου, η οποία υπερτερεί της Ψηφοφορίας σε 9 από τις 10 περιπτώσεις. Εντυπωσιακά στο σύνολο δεδομένων «Energy», η μέθοδος επιτυγχάνει RMSE 422,8, συγκριτικά με το 2557,2 της ανταγωνιστικής μεθόδου, καταγράφοντας εκθετική βελτίωση. Τέλος, ο Πίνακας 6.9 (SVR & Gradient Boosting) καταδεικνύει την εξαιρετική απόδοση της μεθόδου η οποία κυριαρχεί σε όλα τα εξεταζόμενα σύνολα δεδομένων. Πιο Συγκεκριμένα, στο σύνολο δεδομένων «Joho», το RMSE της Αλληλουχίας είναι 1505,9, σημαντικά χαμηλότερο από το 6651,5 της Ψηφοφορίας, ενώ επίσης διαπιστώνεται επιτυχία στο σύνολο δεδομένων «Turbine», με RMSE 303,6 για την Αλληλουχία έναντι 504 της Ψηφοφορίας.

6.2.2.2 Η Ψηφοφορία υπερτερεί της Αλληλουχίας

Η μέθοδος Ψηφοφορίας υπερέχει της μεθόδου Αλληλουχίας σε 2 από τους 12 συνδυασμούς μοντέλων, όπως αποδεικνύεται από τα αποτελέσματα της δοκιμής Friedman. Συγκεκριμένα, υπερτερεί στις ακόλουθες περιπτώσεις:

Dataset	Base	Second Model	Cascade	Averaging
Traffic	5.129	4.186	4.200	4.382
Energy	5064.0	429.6	431.1	2567.6
Power	2878.1	266.1	264.6	1465.8
Parking	1385.7	492.8	497.9	815.2
Kolkata	0.550	0.501	0.529	0.499
Solar	2631.7	252.8	253.8	1339.6
Turbine	860.1	314.3	317.2	507.8
Joho	13009.3	1233.5	1262.9	6596.6
Iot	2.657	1.776	1.984	2.149
Taxi	6762.6	1141.8	1130.8	3552.6

Πίνακας 6.7: SVR & Random Forest RMSE

Dataset	Base	Second Model	Cascade	Averaging
Traffic	5.129	4.056	3.956	4.293
Energy	5064.0	417.0	422.8	2557.2
Power	2878.1	421.2	428.7	1492.5
Parking	1385.7	492.1	497.1	800.0
Kolkata	0.550	0.503	0.507	0.501
Solar	2631.7	244.5	247.5	1334.5
Turbine	860.1	329.3	322.5	507.0
Joho	13009.3	1337.6	1400.1	6588.9
Iot	2.657	1.178	1.435	1.733
Taxi	6762.6	1011.7	1016.1	3497.4

Πίνακας 6.8: SVR & XGBoost RMSE

Dataset	Base	Second Model	Cascade	Averaging
Traffic	5.129	4.228	4.165	4.437
Energy	5064.0	572.8	572.8	2606.6
Power	2878.1	745.3	743.7	1611.7
Parking	1385.7	517.8	516.7	828.9
Kolkata	0.550	0.566	0.530	0.534
Solar	2631.7	288.8	289.5	1347.7
Turbine	860.1	304.4	303.6	504.4
Joho	13009.3	1489.2	1505.9	6651.5
Iot	2.657	2.073	2.095	2.264
Taxi	6762.6	1102.4	1108.2	3553.0

Πίνακας 6.9: SVR & Gradient Boosting RMSE

1. XGBoost & Random Forest (Πίνακας 6.10) - 7/10 περιπτώσεις
2. Random Forest & XGBoost (Πίνακας 6.11) - 9/10 περιπτώσεις

Στους Πίνακες 6.10 και 6.11, όπου γενικά η Ψηφοφορία υπερέχει της Αλληλουχίας, παρατηρείται μια τάση η οποία ενδεχομένως υποδηλώνει ότι η μέθοδος της Ψηφοφορίας μπορεί κατά καιρούς να αποδεικνύεται πιο ωφέλιμη σε σύγκριση με τη διαδοχική βελτίωση της Αλληλουχίας, ανάλογα με τη φύση του συγκεκριμένου συνόλου δεδομένων. Ειδικότερα στον Πίνακα 6.10 (Αποτελέσματα RMSE XGBoost & Random Forest), εντοπίζεται ένα συγκεκριμένο παράδειγμα όπου, στο σύνολο δεδομένων «Solar», το RMSE της Ψηφοφορίας είναι 232,4, ελαφρώς καλύτερο από το 246,2 της Αλληλουχίας. Παρομοίως το σύνολο δεδομένων «Joho» παρουσιάζει στενή ανταγωνιστικότητα, με την Ψηφοφορία να επιτυγχάνει RMSE 1224,9, οριακά καλύτερο από το 1346,1 της Αλληλουχίας, δείχνοντας ότι το πλεονέκτημα της Ψηφοφορίας δεν είναι πάντα σημαντικό. Στον Πίνακα 6.11 (Αποτελέσματα RMSE Random Forest & XGBoost), η Ψηφοφορία εμφανίζει ξεκάθαρη υπεροχή στο σύνολο δεδομένων «Energy», με RMSE 389,0 σε αντίθεση με το 400,3 της Αλληλουχίας. Το σύνολο δεδομένων «Traffic» επίσης αναδεικνύει μικρή υπεροχή της Ψηφοφορίας, με RMSE 4.009 σε σύγκριση με 4.274 της Αλληλουχίας. Αυτή η παρατήρηση υποδηλώνει ότι για κάποια είδη δεδομένων, οι συγκεντρωτικές προβλέψεις από την Ψηφοφορία μπορεί να είναι πιο ισχυρές.

6.2.2.3 Η Αλληλουχία και η Ψηφοφορία αποδίδουν εξίσου

Σε 4 από τους 12 συνδυασμούς μοντέλων η μέθοδος Ψηφοφορίας (Averaging) και η Αλληλουχία (Cascade) παρουσίασαν ισορροπημένη απόδοση στα διάφορα σύνολα δεδομένων. Καθένας από αυτούς τους συνδυασμούς, επιτυγχάνει νίκες στο μισό των περιπτώσεων, όπως καταδεικνύεται από τα ευρήματα του τεστ Friedman.

1. Gradient Boosting & Random Forest (Table 6.12) - 5/10 περιπτώσεις η κάθε

Dataset	Base	Second Model	Cascade	Averaging
Traffic	4.056	4.186	4.115	4.002
Energy	417.0	429.6	417.6	390.1
Power	421.2	266.1	233.4	304.5
Parking	492.1	492.8	492.7	479.1
Kolkata	0.503	0.501	0.512	0.488
Solar	244.5	252.8	246.2	232.4
Turbine	329.3	314.3	335.2	315.8
Joho	1337.6	1233.5	1346.1	1224.9
Iot	1.178	1.776	1.178	1.370
Taxi	1011.7	1141.8	1016.6	1017.8

Πίνακας 6.10: XGBoost & Random Forest RMSE

Dataset	Base	Second Model	Cascade	Averaging
Traffic	4.186	4.056	4.274	4.009
Energy	429.6	417.0	400.3	389.0
Power	266.1	421.2	285.5	299.5
Parking	492.8	492.1	521.1	480.7
Kolkata	0.501	0.503	0.551	0.489
Solar	252.8	244.5	240.3	234.3
Turbine	314.3	329.3	322.7	315.4
Joho	1233.5	1337.6	1257.9	1218.5
Iot	1.776	1.178	1.486	1.357
Taxi	1141.8	1011.7	1085.7	1014.5

Πίνακας 6.11: Random Forest & XGBoost RMSE

μέθοδος

2. Random Forest & Gradient Boosting (Table 6.13) - 5/10 περιπτώσεις η κάθε μέθοδος
3. Random Forest & SVR (Table 6.14) - 5/10 περιπτώσεις η κάθε μέθοδος
4. XGBoost & SVR (Table 6.15) - 5/10 περιπτώσεις η κάθε μέθοδος

Η ισορροπημένη απόδοση μεταξύ της μεθόδου Ψηφοφορίας και της Αλληλουχίας υπογραμμίζει, πως η αποτελεσματικότητα κάθε μεθόδου ενδέχεται να διαφοροποιηθεί ανάλογα με τα χαρακτηριστικά του κάθε συνόλου δεδομένων.

Dataset	Base	Second Model	Cascade	Averaging
Traffic	4.228	4.186	4.057	4.101
Energy	572.8	429.6	471.4	472.3
Power	745.3	266.1	229.1	457.1
Parking	517.8	492.8	539.7	493.5
Kolkata	0.566	0.501	0.517	0.513
Solar	288.8	252.8	269.3	253.8
Turbine	304.4	314.3	313.2	305.2
Joho	1489.2	1233.5	1355.8	1295.3
Iot	2.073	1.776	1.575	1.878
Taxi	1102.4	1141.8	1012.3	1076.3

Πίνακας 6.12: Gradient Boosting & Random Forest RMSE

Στον πίνακα που αναφέρεται στον συνδυασμό Gradient Boosting και Random Forest, παρατηρείται ότι η Αλληλουχία επιφέρει χαμηλότερο RMSE στο σύνολο δεδομένων «Power» με σκορ 229,1 σε αντίθεση με το 457,1 της Ψηφοφορίας. Ωστόσο, στο σύνολο δεδομένων «Parking», οι ρόλοι αντιστρέφονται, με την Ψηφοφορία να επιτυγχάνει χαμηλότερο RMSE 493,5 σε σύγκριση με το 539,7 της Αλληλουχίας. Παρόμοια, στον συνδυασμό Random Forest και Gradient Boosting, η Αλληλουχία καταγράφει μια επιτυχία στο σύνολο δεδομένων «Solar», προσφέροντας RMSE 240,3 σε αντίθεση με 234,3 της Ψηφοφορίας, παρά τη στενή διαφορά. Στο σύνολο δεδομένων «Traffic», η απόδοση και των δύο μεθόδων είναι σχεδόν ίδια, με την Αλληλουχία να εμφανίζει 4.200 και την Ψηφοφορία 4.382 RMSE. Επιπλέον στον συνδυασμό Random Forest και SVR, η Αλληλουχία ξεπερνά σημαντικά την Ψηφοφορία στο σύνολο δεδομένων «Turbine», με RMSE 366,4 έναντι 509,0. Αντιθέτως, στο σύνολο δεδομένων «Joho», η διαφορά RMSE μεταξύ Αλληλουχίας και Ψηφοφορίας είναι πιο στενή, με την Αλληλουχία να καταγράφει 12.469,5 και την Ψηφοφορία 6.600,2. Τέλος, στον συνδυασμό XGBoost και SVR, εμφανίζεται ένα ανάλογο μοτίβο, όπου η Αλληλουχία επιτυγχάνει να ξεπεράσει τον μέσο όρο στο σύνολο δεδομένων «Taxi» με RMSE 6303,6, σε αντίθεση με το 3497,4 της Ψηφοφορίας. Ωστόσο, στο σύνολο δεδομένων «Solar», η Ψηφοφορία καταγράφει μια ελαφριά υπεροχή με RMSE 1334,5 συγκριτικά με το 1347,5 της Αλληλουχίας.

Dataset	Base	Second Model	Cascade	Averaging
Traffic	4.186	4.228	4.208	4.100
Energy	429.6	572.8	422.8	472.4
Power	266.1	745.3	291.4	456.1
Parking	492.8	517.8	511.7	489.1
Kolkata	0.501	0.566	0.549	0.513
Solar	252.8	288.8	244.3	254.3
Turbine	314.3	304.4	319.7	307.1
Joho	1233.5	1489.2	1247.7	1300.0
Iot	1.776	2.073	1.612	1.898
Taxi	1141.8	1102.4	1074.1	1067.3

Πίνακας 6.13: Random Forest & Gradient Boosting RMSE

Dataset	Base	Second Model	Cascade	Averaging
Traffic	4.186	5.129	4.315	4.387
Energy	429.6	5064.0	4628.7	2567.8
Power	266.1	2878.1	659.2	1465.5
Parking	492.8	1385.7	590.2	816.3
Kolkata	0.501	0.550	0.512	0.499
Solar	252.8	2631.7	1350.7	1340.4
Turbine	314.3	860.1	366.4	509.0
Joho	1233.5	13009.3	12469.5	6600.2
Iot	1.776	2.657	1.761	2.133
Taxi	1141.8	6762.6	6313.0	3548.4

Πίνακας 6.14: Random Forest & SVR RMSE

Dataset	Base	Second Model	Cascade	Averaging
Traffic	4.056	5.129	4.183	4.293
Energy	417.0	5064.0	4625.3	2557.2
Power	421.2	2878.1	1028.4	1492.5
Parking	492.1	1385.7	593.2	800.0
Kolkata	0.503	0.550	0.508	0.501
Solar	244.5	2631.7	1347.5	1334.5
Turbine	329.3	860.1	367.4	507.0
Joho	1337.6	13009.3	12461.9	6588.9
Iot	1.178	2.657	1.194	1.733
Taxi	1011.7	6762.6	6303.6	3497.4

Πίνακας 6.15: XGBoost & SVR RMSE

Κεφάλαιο 7

Υβριδικό Μοντέλο ARIMA-TFT για Δεδομένα Διοξειδίου του Άνθρακα (CO₂)

Τα επίπεδα διοξειδίου του άνθρακα (CO₂) και άλλων αερίων, που συμβάλλουν στο φαινόμενο του θερμοκηπίου, έχουν αυξηθεί σε νέα υψηλά επίπεδα τα τελευταία χρόνια στην ατμόσφαιρα. Όντας ένας από τους κύριους παράγοντες πίσω από την υπερθέρμανση του πλανήτη, οι εκπομπές CO₂ έχουν οδηγήσει σε μερικά από τα θερμότερα χρόνια που έχουν καταγραφεί. Μάλιστα, η δεκαετία 2010-2019 ήταν η θερμότερη που έχει καταγραφεί ποτέ. Πρόσφατες προβλέψεις του Παγκόσμιου Μετεωρολογικού Οργανισμού, από ομάδα 11 προγνωστικών κέντρων, έδειξαν ότι υπάρχει 48% πιθανότητα ο πλανήτης να φτάσει προσωρινά σε ετήσια αύξηση 1,5°C κατά μέσο όρο πάνω από τα προβιομηχανικά επίπεδα στα τέλη του 1800, μεταξύ των ετών 2022 και 2026. Υπάρχει συμφωνία μεταξύ των επιστημόνων ότι μια τέτοια αύξηση, εάν διατηρηθεί μακροπρόθεσμα, κινδυνεύει να προκαλέσει σοβαρές επιπτώσεις στους ανθρώπους, στην άγρια φύση και τα οικοσυστήματα - ορισμένες από τα οποίες μπορεί να είναι μη αναστρέψιμες [15].

Ως αποτέλεσμα, η Συμφωνία του Παρισιού, η οποία εγκρίθηκε το 2015, είχε ως στόχο να ενισχύσει την παγκόσμια απόκριση στην απειλή της κλιματικής αλλαγής, διατηρώντας την παγκόσμια αύξηση της θερμοκρασίας για αυτόν τον αιώνα πολύ κάτω από 2 βαθμούς Κελσίου πάνω από τα προβιομηχανικά επίπεδα και λαμβάνοντας υπ' όψη τους σοβαρούς κινδύνους, να προσπαθήσει για το όριο

των 1,5°C. Για την επίτευξη αυτού του στόχου, η συμφωνία περιλαμβάνει σχέδιο δράσης των χωρών παγκοσμίως, για τον περιορισμό της υπερθέρμανσης του πλανήτη και την ικανότητά τους ν' αντιμετωπίζουν τις επιπτώσεις της κλιματικής αλλαγής και να διατηρούν την περιβαλλοντική βιωσιμότητα μέσω κατάλληλων χρηματοοικονομικών ροών, ενός νέου τεχνολογικού πλαισίου και ενός ενισχυμένου πλαισίου ανάπτυξης [321]. Ένας από τους κύριους στόχους της συμφωνίας είναι ότι προκειμένου ν' αναχαιτιστεί πλήρως η υπερθέρμανση του πλανήτη, οι κυβερνήσεις των χωρών να φέρουν την ευθύνη για τη μείωση των εκπομπών CO₂ τους. Πιο συγκεκριμένα, η επίτευξη του φιλόδοξου όριου του 1,5°C απαιτεί σχεδόν κατά το ήμισυ τη μείωση των παγκόσμιων εκπομπών CO₂ από τα επίπεδα του 2010 έως το 2030 και τη μείωση τους στο μηδέν έως το 2050. Η εφαρμογή της Συμφωνίας του Παρισιού είναι επίσης απαραίτητη για την επίτευξη των Στόχων Βιώσιμης Ανάπτυξης που ορίζονται από τον ΟΗΕ [38].

Κατά συνέπεια, υπό το φως των συνεχώς αυξανόμενων σοβαρών προβλημάτων που προκύπτουν από τις εκπομπές CO₂, η σημασία της παρακολούθησης και της πρόβλεψης των επιπέδων του, έχει αναγνωριστεί ως ένα σημαντικό μέσο για την εφαρμογή κατάλληλων μέτρων πρόληψης και αντίδρασης. Για τον σκοπό αυτό, πολλά έργα έξυπνων πόλεων, ενσωματώνουν συστήματα Διαδικτύου των Πραγμάτων (IoT) για να παρακολουθούν συνεχώς το περιβάλλον, καταγράφοντας μετρήσεις όπως τη συγκέντρωση του διοξειδίου του άνθρακα (CO₂) μαζί με άλλους περιβαλλοντικούς δείκτες. Οι πρόσφατες εξελίξεις στις τεχνολογίες και τις συσκευές IoT έχουν οδηγήσει στην ανάπτυξη συστημάτων παρακολούθησης που βασίζονται σε χαμηλού κόστους ασύρματα δίκτυα αισθητήρων (WSN) για τη συλλογή δεδομένων CO₂ σε πραγματικό χρόνο, τόσο σε εξωτερικά όσο και σε εσωτερικά περιβάλλοντα. Τέτοια συστήματα επιδιώκουν να προσφέρουν αποδοτικότητα σε τομείς όπως η κατανάλωση ή η μεταφορά ενέργειας, χρησιμοποιώντας μικροαισθητήρες, μικροελεγκτές, τεχνολογίες ασύρματης επικοινωνίας, πλατφόρμες cloud IoT καθώς και προηγμένες μεθόδους ανάλυσης δεδομέ-

νων για τη συλλογή, επεξεργασία και αποθήκευση δεδομένων, όπως και για την παραγωγή προβλέψεων και απεικονίσεων για τους χρήστες.

Στην παρούσα διατριβή, χρησιμοποιήθηκε ένα πολυμεταβλητό σύνολο δεδομένων που περιλαμβάνει μετρήσεις από αισθητήρες IoT πολλαπλών περιβαλλοντικών παραγόντων, για την ανάπτυξη ενός υβριδικού μοντέλου χρονοσειρών, με στόχο την πρόβλεψη της συγκέντρωσης του CO₂ στο πλαίσιο μιας έξυπνης πόλης. Η προσέγγιση αυτή αποτελείται από μία στατιστική μέθοδο, τον Αυτο-Παλινδρόμενο Ολοκληρωμένο Κινητό Μέσο (AutoRegressive Integrated Moving Average - ARIMA) και μία μέθοδο Βαθιάς Μηχανικής Μάθησης, τους Μετασχηματιστές Χρονικής Ένωσης (Temporal Fusion Transformers - TFT). Η χρήση μοντέλων χρονοσειρών σε συνδυασμό με τεχνολογίες IoT για την πρόβλεψη των εκπομπών CO₂ είναι σχετικά σπάνια στην επιστημονική βιβλιογραφία. Το προτεινόμενο σύστημα διακρίνεται για την υψηλή ερμηνευσιμότητά του, επιτρέποντας την ερμηνεία των προβλέψεων του, βάση των δεδομένων εισόδου, κάτι το οποίο αποτελεί έναν κρίσιμο παράγοντα για την εφαρμογή τέτοιων συστημάτων σε πραγματικές εφαρμογές. Η υβριδική προσέγγιση που αναπτύχθηκε συγκρίθηκε με τα βασικά της μοντέλα, ARIMA και TFT, αλλά και με διάφορες άλλες μεθόδους, όπως η Εκθετική Εξομάλυνση (Exponential Smoothing), ο Γρήγορος Μετασχηματισμός Fourier (Fast Fourier Transform - FFT), η μέθοδος Theta, DeepAR, N-BEATS, Δίκτυα Μετασχηματιστών (Transformer Networks), Χρονικά Συνελκτικά Νευρωνικά Δίκτυα (Temporal Convolutional Networks - TCN), και Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης (Long Short-Term Memory Networks - LSTM).

Ευρέως τα Μοντέλα Πρόβλεψης CO₂ διακρίνονται σε τέσσερις βασικές κατηγορίες: Στατιστικά Μοντέλα Χρονοσειρών, Παραδοσιακά Μοντέλα Μηχανικής Μάθησης, Μοντέλα Βαθιάς Μηχανικής Μάθησης για χρονοσειρές και Υβριδικά Μοντέλα, τα οποία ενσωματώνουν στοιχεία από μία ή περισσότερες από τις προηγούμενες κατηγορίες.

Οι Στατιστικές Μέθοδοι, χρησιμοποιούνται συχνά για τη μοντελοποίηση δεδομένων που παρουσιάζονται ως ακολουθίες. Ειδικά στο πεδίο της πρόβλεψης εκπομπών CO₂, μπορεί ν' αφορούν ακολουθίες μετρήσεων που λαμβάνονται σε τακτικά χρονικά διαστήματα, όπως για παράδειγμα, η συγκέντρωση CO₂ γύρω από μια συγκεκριμένη περιοχή όπου καταγράφεται ανά λεπτό ή ανά κάποιο άλλο χρονικό διάστημα. Τέτοια μοντέλα, όπως τα Αυτο-παλινδρομικά Μοντέλα (AR), τα Μοντέλα Κινητού Μέσου (MA) [57], η Εκθετική Εξομάλυνση [125, 127] και τα Μοντέλα Δομικών Χρονοσειρών [147, 172], είναι κατάλληλα για το χειρισμό της διαδοχικής φύσης των δεδομένων αυτών. Μεταξύ των στατιστικών μεθόδων, το μοντέλο ARIMA εμφανίζεται να είναι μία από τις πιο δημοφιλείς επιλογές, ενώ πολλά μοντέλα, όπως τα ARMA [361], [7], ARIMAX [363], NARX [406], SARIMAX [348], [374], [9], [348] και το πιο πρόσφατο μοντέλο Prophet [276], έχουν εφαρμοστεί επίσης στην πρόβλεψη εκπομπών CO₂.

Τα Στατιστικά Μοντέλα Χρονοσειρών, συναντούν συνήθως δύο βασικούς περιορισμούς. Πρώτον, συχνά βασίζονται σε ισχυρές υποθέσεις για τις ιδιότητες των δεδομένων, την κατανομή τους και τις χρονικές εξαρτήσεις, οι οποίες αν δεν ικανοποιηθούν, ενδέχεται να περιορίσουν την αποτελεσματικότητα της μοντελοποίησης. Δεύτερον, η ορθή απόδοσή τους εξαρτάται συχνά από την εξειδικευμένη γνώση και εμπειρία ενός ειδικού, πράγμα το οποίο μπορεί να είναι δύσκολο να αποκτηθεί.

Τα Παραδοσιακά Μοντέλα Μηχανικής Μάθησης, έχουν αποδείξει την ικανότητά τους ν' ανακαλύπτουν πολύπλοκες σχέσεις μέσα από τα δεδομένα, απαιτώντας ελάχιστη ή καμία ανθρώπινη παρέμβαση [5]. Τα μοντέλα αυτά, όπως η Γραμμική Παλινδρόμηση (Linear Regression - LR) [366], [263], οι Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines - SVM) [263], [348], το Τυχαίο Δάσος (Random Forest - RF) [263], [348], [333] και τα Νευρωνικά Δίκτυα (Artificial Neural Networks - ANN) [17], [9], είναι ορισμένες από τις πιο διαδεδομένες τεχνικές. Άλλες προσεγγίσεις Εποπτευόμενης Μάθησης που έχουν εφαρ-

μοστεί περιλαμβάνουν την Παλινδρόμηση Κορυφογραμμής (Ridge Regression - RR) [395], [263], την Πολυωνυμική Παλινδρόμηση (Polynomial Regression) [162], τον Αλγόριθμο k-Πλησιέστερων Γειτόνων (k-Nearest Neighbors - k-NN) [263], την Ακραία Μηχανή Μάθησης (Extreme Learning Machine - ELM) [361], [389], τα Δέντρα Απόφασης (Decision Trees - DT) [395], [263], την Ενίσχυση Κλίσης (Gradient Boosting - GB) [395], [110], Νευρο-Ασφαή Συστήματα (Neuro-Fuzzy Systems) [254] καθώς και Εξελικτικούς Αλγόριθμους (Evolutionary Algorithms) [160]. Μεγάλος περιορισμός των Παραδοσιακών Μοντέλων Μηχανικής Μάθησης για την πρόβλεψη CO₂ αποτελεί η αδυναμία τους να διαχειριστούν εγγενώς τη χρονική διάσταση των δεδομένων. Τα εν λόγω μοντέλα, σε αντίθεση με τις στατιστικές μεθόδους, συχνά προϋποθέτουν ότι τα δεδομένα είναι ανεξάρτητα και ομοιόμορφα κατανομημένα (i.i.d.). Ωστόσο, οι παρατηρήσεις σ' ένα σύνολο δεδομένων χρονοσειρών, συνδέονται στενά εμφανίζοντας σύνθετες χρονικές εξαρτήσεις. Επιπλέον, τα δεδομένα χρονοσειρών συχνά παρουσιάζουν εποχικότητα και τάσεις, χαρακτηριστικά στενά συνδεδεμένα με τον χρόνο, όπου τα Παραδοσιακά Μοντέλα Μηχανικής Μάθησης, δυσκολεύονται συνήθως να μοντελοποιήσουν αποτελεσματικά χωρίς επιπλέον βήματα προεπεξεργασίας, όπως οι μετασχηματισμοί δεδομένων και η δημιουργία χαρακτηριστικών. Τα Μοντέλα Βαθιάς Μηχανικής Μάθησης, παρόμοια με τις Στατιστικές Μεθόδους, μπορούν εγγενώς να χειριστούν δεδομένα ακολουθίας [235]. Εντούτοις, αντί να βασίζονται στην ανθρώπινη εμπειρία για να τα καθοδηγήσουν, επιτρέπουν την απευθείας μάθηση πολύπλοκων σχέσεων, συμπεριλαμβανομένων και των χρονικών σχέσεων, από τα ίδια τα δεδομένα. Ειδικότερα, τέτοια μοντέλα έχουν αποδειχθεί ιδιαίτερα αποδοτικά στην μάθηση αναπαραστάσεων των δεδομένων που προκύπτουν από πολύπλοκες σχέσεις των μεταβλητών [46]. Τα μοντέλα Βαθιάς Μηχανικής Μάθησης για χρονοσειρές συνήθως χρησιμοποιούν ένα ή περισσότερα από τα ακόλουθα Νευρωνικά Δίκτυα ως τα δομικά τους στοιχεία: Επαναλαμβανόμενα Νευρωνικά Δίκτυα [152], Συνελκτικά Νευρωνικά Δίκτυα [433] και πιο πρόσφατα, Δίκτυα

βασισμένα στην Προσοχή, όπως οι μετασχηματιστές [380]. Σε σύγκριση με άλλες μεθόδους, οι προσεγγίσεις που βασίζονται σε Βαθιά Μηχανική Μάθηση, είτε καθαρές είτε υβριδικές, για την πρόβλεψη εκπομπών CO₂ είναι πολύ λιγότερο κοινές στη βιβλιογραφία. Οι περισσότερες προσεγγίσεις χρησιμοποιούν Επαναλαμβανόμενα Νευρωνικά Δίκτυα [19] και τις παραλλαγές τους, όπως Δίκτυα Μακροπρόθεσμης Μνήμης [442], [268], [347] και Αμφίδρομα Δίκτυα Μακροπρόθεσμης Μνήμης [20], ενώ έχουν επίσης εφαρμοστεί Επαναλαμβανόμενα Νευρωνικά Δίκτυα που βασίζονται στην Προσοχή [237]. Τα μοντέλα Βαθιάς Μηχανικής Μάθησης, είναι πολύ ισχυρά, αλλά δεν έρχονται χωρίς μειονεκτήματα. Είναι επιρρεπή στην υπερπροσαρμογή [43] και συχνά απαιτούν μεγάλο όγκο δεδομένων εκπαίδευσης για να γενικευτούν καλά. Συμπληρωματικά, η πλειοψηφία των μοντέλων Βαθιάς Μηχανικής Μάθησης, υποφέρει από προβλήματα ερμηνείας καθώς συχνά λειτουργούν ως «μαύρα κουτιά» και οι αποφάσεις τους δεν μπορούν να εξηγηθούν καλά [430].

Για ν' αντιμετωπιστούν οι ελλείψεις καθεμιάς από τις προαναφερόμενες κατηγορίες, χρησιμοποιούνται συχνά υβριδικές προσεγγίσεις που συνδυάζουν ένα ή περισσότερα μοντέλα από μία ή περισσότερες κατηγορίες. Ειδικά για την πρόβλεψη εκπομπών CO₂, χρησιμοποιήθηκε στο [290] μια δομή που ενσωματώνει ανάλυση αποσύνθεσης δεικτών (IDA) μαζί με Νευρωνικά Δίκτυα και Ανάλυση Περιβλήματος Δεδομένων (DEA) για τη μοντελοποίηση αερίων που παράγονται ετησίως από τον βιομηχανικό τομέα του Καναδά, ενώ ένα μοντέλο που συνδυάζει ένα Νευρωνικό Δίκτυο Παλινδρόμησης και Ανάλυση Σεναρίων κατασκευάστηκε στο [283], προκειμένου να προβλεφθούν οι εκπομπές άνθρακα της Κίνας μεταξύ 2016 και 2040, κάτω από διαφορετικά σενάρια, με βάση ορισμένους παράγοντες που τα επηρεάζουν. Στο [18], προτάθηκε ένα υβρίδιο Βαθιάς Μηχανικής Μάθησης, καθώς Δίκτυα Μακροπρόθεσμης Μνήμης συνδυάστηκαν με Συνεληκτικά Νευρωνικά Δίκτυα, για την πρόβλεψη των επιπέδων CO₂ για το έτος 2020. Σε παλαιότερη μελέτη [255], η μέθοδος εκμάθησης του συνδυαστικού μοντέλου

Adaptive Neuro-Fuzzy Inference System (ANFIS), το οποίο ενσωματώνει τα πλεονεκτήματα τόσο των Ασαφών Συστημάτων όσο και των Νευρωνικών Δικτύων, εφαρμόστηκε για τη πρόβλεψη εκπομπών CO₂. Επιπροσθέτως, στο [175], αναπτύχθηκε μια υβριδική προσέγγιση όπου συνδυάζει τα αποτελέσματα εννέα διαφορετικών αλγορίθμων (Παραδοσιακής Μηχανικής Μάθησης, Στατιστικές Μεθόδους και Βαθιάς Μηχανικής Μάθησης), μαζί με μαθηματικό προγραμματισμό για την πρόβλεψη του ρυθμού εκπομπής αερίων στο Ιράν μεταξύ 2018 και 2028, ενώ στο [386] προτάθηκαν δύο υβρίδια. Το πρώτο συνδύασε το Μεταβολικό μη Γραμμικό Γκρι Μοντέλο (MNGM) με το ARIMA, ενώ το δεύτερο συνδύασε το MNGM μ' ένα μοντέλο Νευρωνικών Δικτύων BPNN. Και τα δύο μοντέλα εφαρμόστηκαν για την πρόβλεψη της εκπομπής άνθρακα της Κίνας, των ΗΠΑ και της Ινδίας για την περίοδο 2019-2030. Μια υβριδική μέθοδος δύο σταδίων αναπτύχθηκε στο [342]: Στο πρώτο στάδιο, οι εκπομπές CO₂ προβλέπονται χρησιμοποιώντας πολλαπλή Παλινδρόμηση, Παλινδρόμηση Gauss και Νευρωνικά Δίκτυα ξεχωριστά, των οποίων οι προβλέψεις τροφοδοτούνται στη συνέχεια ως είσοδος σ' ένα Νευρωνικό Δίκτυο για την παραγωγή της τελικής πρόβλεψης. Στο δεύτερο στάδιο τρία διαφορετικά μοντέλα, συγκεκριμένα Νευρωνικά Δίκτυα (ANN), Τυχαία Δάση (RF) και Βελτιστοποίηση Σμήνους Σωματιδίων (PSO) ενσωματώθηκαν σε μια ενιαία προσέγγιση στο [392] για να γίνουν προβλέψεις σχετικά με τις εκπομπές CO₂ του κινεζικού εμπορικού τομέα από το 1997 έως το 2017.

Παρόλο που πρόσφατες μελέτες έχουν αναπτύξει υβριδικές μεθόδους για την πρόβλεψη των εκπομπών CO₂, οι υφιστάμενες λύσεις δεν επικεντρώνονται στα πλεονεκτήματα της χρήσης μοντέλων με Μηχανισμούς Προσοχής, όπως οι Μετασχηματιστές Χρονικής Ένωσης (TFT). Αυτοί οι μετασχηματιστές έχουν αποδειχθεί ότι παρέχουν βελτιωμένη απόδοση σε σχέση με άλλα Επαναλαμβανόμενα Νευρωνικά Δίκτυα και προσφέρουν επίσης μεγαλύτερο βαθμό ερμηνείας μέσω των βαρών Προσοχής [233]. Ειδικότερα, οι δυνατότητες του TFT αποδείχθηκαν στο [167], όπου οι Huy et al., το συνδύασαν με Γραμμική Παλινδρόμηση για τη

βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου. Η Υβριδική προσέγγισή τους, συγκρίθηκε με μια σειρά μοντέλων τόσο Στατιστικών όσο και Βαθιάς Μηχανικής Μάθησης, αποδεικνύοντας την ανωτερότητά της. Παρόμοια αποτελέσματα αναφέρθηκαν στο [399], όπου τα υβρίδια που βασίζονται στον TFT, είχαν καλύτερη απόδοση από άλλα αντίστοιχα μοντέλα, στη συντριπτική πλειοψηφία των μετρήσεων απόδοσης για την πρόβλεψη της ταχύτητας του ανέμου. Ταυτόχρονα, απεικονίστηκε η ερμηνευσιμότητα του μοντέλου, προσφέροντας πληροφορίες για τους σημαντικότερους παράγοντες, όσον αφορά την πρόβλεψη της ταχύτητας του ανέμου κατά τη διάρκεια κάθε εποχής (Άνοιξη, Καλοκαίρι, Φθινόπωρο, και Χειμώνας). Η ερμηνεύσιμη φύση του TFT απεικονίστηκε περαιτέρω στο [398], όπου εφαρμόστηκε σ' ένα πολυμεταβλητό σύνολο δεδομένων, συμπεριλαμβανομένων τόμων ιστορικού τουρισμού, δεδομένα από ταξιδιωτικά φόρουμ, δεδομένα μηχανών αναζήτησης, καθώς και μηνιαία δεδομένα επιβεβαιωμένων τουριστών σε ταξιδιωτικούς προορισμούς, για την πρόβλεψη όγκου τουριστών εν μέσω της πανδημίας COVID-19. Η ανάλυση αποκάλυψε μεταξύ άλλων, σε τι βαθμό τα δεδομένα μηχανών αναζήτησης, που σχετίζονται με την πανδημία, επηρέασαν τον όγκο των ταξιδιών.

7.1 Προτεινόμενη Μεθοδολογία

Η ενότητα αυτή κάνει αναφορά στην παρουσίαση και την ανάλυση του συνόλου δεδομένων που χρησιμοποιήθηκε στην παρούσα μελέτη καθώς και τις διαδικασίες προεπεξεργασίας που εφαρμόστηκαν προκειμένου να προετοιμαστούν τα δεδομένα για τη μοντελοποίηση. Αναλύεται η προτεινόμενη υβριδική λύση, παρουσιάζοντας το κίνητρο πίσω από την επιλογή της και τις προκλήσεις που αντιμετωπίζει. Επιπλέον, περιγράφονται λεπτομερώς οι τεχνικές και οι μέθοδοι υλοποίησης όπου χρησιμοποιήθηκαν κατά την πειραματική διαδικασία, καθώς και τα βήματα που ακολουθήθηκαν για την αξιολόγηση της αποδοτικότητας του προτεινόμενου Υβριδικού Μοντέλου.

7.1.1 Περιγραφή και Προεπεξεργασία Δεδομένων

Για την μοντελοποίηση και αξιολόγηση, χρησιμοποιήθηκε ένα πολυμεταβλητό σύνολο δεδομένων CO₂, το οποίο προτάθηκε αρχικά στο [395], και περιείχε μετρήσεις που παρατηρήθηκαν από ένα ασύρματο δίκτυο αισθητήρων (Wireless Sensor Network - WSN). Πιο συγκεκριμένα, το δίκτυο αποτελείτο από τρία κύρια μέρη, συμπεριλαμβανομένου του αισθητήρα, του κόμβου και του διακομιστή. Όλες οι συσκευές IoT έχουν σχεδιαστεί για να καταγράφουν μετρήσεις των περιβαλλοντικών συνθηκών κάθε ένα (1) δευτερόλεπτο, είκοσι τέσσερις (24) ώρες την ημέρα, για μια περίοδο τριών (3) μηνών. Για την ακρίβεια, καταγράφηκαν οι ακόλουθοι περιβαλλοντικοί παράγοντες: συγκέντρωση CO₂ σε ppm (μέρη στο εκατομμύριο), η θερμοκρασία σε °C, η ένταση του φωτός σε καντέλες (περίπου 0 – 1000) και το ποσοστό υγρασίας. Ο Πίνακας 7.1 περιέχει μια περίληψη του συνόλου δεδομένων. Ακόμη, στην αριστερή πλευρά του σχήματος 7.1, η ακατέργαστη χρονική σειρά κάθε μεταβλητής απεικονίζεται σε μια περίοδο τριών (3) ημερών, ενώ στη δεξιά πλευρά ολόκληρη η κατανομή δεδομένων κάθε μεταβλητής φαίνεται ως θηκόγραμμα. Όπως προαναφέρθηκε, περισσότερες πληροφορίες σχετικά


με το σύνολο δεδομένων και τη διαδικασία συλλογής μπορεί να βρεθεί στο [395].

Περιβαλλοντικός Παράγοντας	Μονάδα Μέτρησης	Συνολικές Εγγραφές	Εσφαλμένες Εγγραφές	Κενές Εγγραφές	Εύρος Εγγραφών
Συγκέντρωση CO ₂	ppt	6114708	0	32	0-1000
Θερμοκρασία	°C	6114708	9	0	20-40
Υγρασία	%	6114708	3	0	0-100
Ένταση του φωτός	Καντέλες	6114708	0	40	0-1000

Πίνακας 7.1: Σύνοψη του συνόλου δεδομένων CO₂. Για κάθε περιβαλλοντικό παράγοντα, υπάρχουν μετρήσεις από τρεις διαφορετικούς αισθητήρες IoT.

Η προεπεξεργασία των δεδομένων αποτελούσε ένα κρίσιμο βήμα πριν από τη διαδικασία μοντελοποίησης. Αρχικά αφαιρέθηκαν όλες οι διπλές τιμές για να διασφαλιστεί η μοναδικότητα των εγγραφών στο σύνολο δεδομένων. Στη συνέχεια εξαλείφθηκαν εσφαλμένες εγγραφές, δηλαδή εκείνες που δεν ακολουθούσαν το προκαθορισμένο μοτίβο των δεδομένων, ενισχύοντας περαιτέρω την ποιότητα και την ακρίβεια της ανάλυσης. Η διαχείριση ακραίων τιμών ήταν το επόμενο βήμα, όπου τιμές εκτός λογικών ορίων, πιθανόν αποτέλεσμα λαθών λογισμικού ή υλικού, περιορίστηκαν με βάση τα ακόλουθα εύρη για κάθε μεταβλητή: 0-1000 για τη συγκέντρωση CO₂, 20-40 για τη θερμοκρασία, 0-100 για την υγρασία και 0-1000 για την ένταση φωτός. Τα εν λόγω εύρη ορίστηκαν βάσει της ανάλυσης που έγινε στις κατανομές των δεδομένων και των θηκογραμμάτων που παρουσιάζονται στο Σχήμα 7.1. Κατά τη διαδικασία αυτή, απορρίφθηκαν συνολικά 19492 τιμές, από τις οποίες 18162 αφορούσαν τη συγκέντρωση CO₂, 582 την υγρασία, 374 τη θερμοκρασία και 374 την ένταση φωτός, διατηρώντας έτσι τις τιμές εντός των προαναφερθέντων ορίων.

Η ανάπτυξη τριών αισθητήρων IoT οδηγεί στη δημιουργία ενός πλούσιου συνόλου δεδομένων, καθώς για κάθε δευτερόλεπτο καταγράφονται τρεις διαφορετικές τιμές ανά περιβαλλοντικό παράγοντα, με κάθε μία τιμή να προέρχεται από διαφορετικό αισθητήρα. Η πρόκληση του μεγάλου όγκου δεδομένων, σε συνδυασμό με τους περιορισμένους υπολογιστικούς πόρους, οδήγησαν στην από-



Σχήμα 7.1: Κατανομή ακατέργαστων δεδομένων για κάθε μεταβλητή σε περίοδο τριών ημερών (αριστερά). Θηκόγραμμα για κάθε μεταβλητή την ίδια περίοδο 3 μηνών (δεξιά)

φαση να υπολογιστούν κατά μέσο όρο οι τιμές σε ωριαία βάση για την ευκολία της μοντελοποίησης και αξιολόγησης. Τούτο σημαίνει ότι για κάθε μεταβλητή, οι τιμές από όλους τους αισθητήρες, εντός μιας συγκεκριμένης ώρας, συγκεντρώθηκαν και υπολογίστηκαν κατά μέσο όρο, για να δημιουργηθεί ένα μεμονωμένο χρονικό σημείο για την εκάστοτε ωριαία περίοδο. Κατά τη διάρκεια αυτής της διαδικασίας, οι τυχόν κενές τιμές στα δεδομένα αγνοήθηκαν. Σε περιπτώσεις όπου ο υπολογισμός του μέσου όρου για μια συγκεκριμένη ώρα έδινε κενή τιμή, εξαιτίας της πλήρους απουσίας μετρήσεων από όλους τους αισθητήρες για την εν λόγω ώρα, τότε αυτή η ώρα αποκλειόταν από την ανάλυση.

7.1.2 Προτεινόμενη Υβριδική Προσέγγιση

Στην παρούσα ενότητα, εξετάζονται τα θεμέλια της προτεινόμενης Υβριδικής Προσέγγισης, εστιάζοντας στα κύρια συστατικά της: τον Αυτοπαλινδρόμενο Ολοκληρωμένο Κινητό Μέσο (ARIMA) και τους Μετασχηματιστές Χρονικής Ένωσης (TFT). Τα μοντέλα αυτά αποτελούν την καρδιά της προσέγγισης, συνδυάζοντας την ακρίβεια και την ευελιξία της στατιστικής ανάλυσης χρονοσειρών, με τις προηγμένες δυνατότητες μάθησης των Νευρωνικών Δικτύων, προσφέροντας έτσι μια ισχυρή εργαλειοθήκη για την αντιμετώπιση περίπλοκων προβλημάτων πρόβλεψης.

7.1.2.1 Κίνητρο

Στο πλαίσιο της εφαρμογής συστημάτων Μηχανικής Μάθησης για έξυπνες πόλεις, αν και έχουν διεξαχθεί πολλές μελέτες την τελευταία δεκαετία, ο αριθμός των ερευνών ο οποίος επικεντρώνεται συγκεκριμένα στην πρόβλεψη των εκπομπών CO₂ με τη χρήση τεχνολογιών IoT παραμένει σχετικά περιορισμένος, συγκριτικά με άλλους τομείς εφαρμογής [357], [271]. Σε μια πρώιμη εργασία [88], αναπτύχθηκαν τρία διαφορετικά μοντέλα Μηχανικής Μάθησης - Αφελής Bayes, Νευρωνικά Δίκτυα (ANN) και Δέντρα Απόφασης (DT) - χρησιμοποιώντας δεδο-

μένα από αισθητήρες για την πρόβλεψη των επιπέδων CO₂, ως δείκτη της ποιότητας του αέρα. Σε μια πιο πρόσφατη μελέτη [378], ο Αλγόριθμος Τυχαίου Δάσους (Random Forest, RF) εφαρμόστηκε για την εκτίμηση της περιεκτικότητας CO₂ στον αέρα ενός έξυπνου σπιτιού, με βάση παράγοντες όπως η εσωτερική και εξωτερική θερμοκρασία, η εσωτερική σχετική υγρασία καθώς και η ημερομηνία και η ώρα της ημέρας. Ενώ στην έρευνα [395] αναπτύχθηκε μια ποικιλία μοντέλων όπως, Τυχαίο Δάσος (Random Forest, RF), Ενίσχυση Κλίσης (Gradient Boosting, GB), Γραμμική Παλινδρόμηση (Linear Regression, LR), Παλινδρόμηση Κορυφογραμμής (Ridge Regression, RR), Δέντρα Απόφασης (Decision Trees, DT), Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης (Long Short-Term Memory, LSTM) και στη συνέχεια συγκρίθηκαν για την εκτίμηση συγκέντρωσης CO₂. Περαιτέρω μελέτες πραγματοποιήθηκαν τα τελευταία δύο χρόνια: το 2021 προτάθηκε [347] ένα σύστημα το οποίο χρησιμοποιούσε δεδομένα αισθητήρων σε πραγματικό χρόνο σ' ένα όχημα, με σκοπό να προβλεφθούν τα επίπεδα CO₂ του οχήματος, χρησιμοποιώντας Νευρωνικά Δίκτυα Μακροπρόθεσμης Μνήμης (Long Short-Term Memory, LSTM). Στη συνέχεια το 2022, υιοθετήθηκε μια προσέγγιση Πολυ - γραμμικής Παλινδρόμησης [51] για την πρόβλεψη των εκπομπών CO₂, σε δεδομένα ροής κυκλοφορίας, λαμβάνοντας υπ' όψη και τις συνθήκες συμφόρησης.

Στην παρούσα διατριβή, κατασκευάστηκε ένα νέο, ερμηνεύσιμο, Υβριδικό Μοντέλο, ικανό να διαχειρίζεται δεδομένα χρονοσειρών. Σε αντίθεση με τα Παραδοσιακά Μοντέλα Μηχανικής Μάθησης, όπως τα Τυχαία Δάση (Random Forests - RF), τα Δέντρα Απόφασης (Decision Trees - DT), η Λογιστική Παλινδρόμηση (Logistic Regression - LR), η Παλινδρόμηση Ενίσχυση Κλίσης (Gradient Boosting - GB) κ.λ.π., το νέο μοντέλο είναι ιδανικό για την πρόβλεψη συγκέντρωσης CO₂. Οι Υβριδικές προσεγγίσεις έχουν μακράν ιστορία στην πρόβλεψη χρονοσειρών [141]. Ένα από τα πρώτα και πιο σημαντικά έργα σε Υβριδικά Μοντέλα για χρονοσειρές, ήταν του Zhang [426], όπου συνδύαζε το ARIMA (Αυτοπαλινδρομούμενο Ολοκληρωμένο Κινούμενο Μέσο) με ένα μοντέλο Νευρωνικών Δικτύων (Neural

Network Model). Έκτοτε τα Υβριδικά μοντέλα για χρονοσειρές, έχουν κερδίσει μεγάλη δημοτικότητα και έχει προταθεί μια μεγάλη ποικιλία συνδυασμών [196], [303], [350].

Το θεμελιώδες κίνητρο πίσω από την ανάπτυξη Υβριδικών μεθόδων, είναι η πεποίθηση ότι ο συνδυασμός των καλύτερων τεχνικών, τόσο από τον τομέα της Στατιστικής, όσο και από τον τομέα της Μηχανικής Μάθησης, θα καταφέρει να αναδείξει τα θετικά σημεία και των δύο πεδίων, ενώ παράλληλα θ' αντισταθμίσει τους περιορισμούς που φέρει η κάθε προσέγγιση, χρησιμοποιώντας τα δυνατά σημεία της άλλης. Επίσης, ένα σημαντικό επιχείρημα υπέρ της υιοθέτησης Υβριδικών προσεγγίσεων έγκειται στο γεγονός ότι, παρ'ότι που οι μέθοδοι Βαθιάς Μηχανικής Μάθησης, έχουν επιδείξει εντυπωσιακά αποτελέσματα σε εφαρμογές, σχετικά με τη φυσική γλώσσα και την υπολογιστική όραση, φαίνεται ότι δεν έχουν ακόμα εκπληρώσει τις υψηλές προσδοκίες που υπήρχαν για αυτές στο πεδίο της πρόβλεψης χρονοσειρών.

Τούτο επιβεβαιώθηκε στον διαγωνισμό M4 [251], όπου διάφορα μοντέλα χρονοσειρών συγκρίθηκαν σε 100.000 σύνολα δεδομένων χρονοσειρών. Τα αποτελέσματα της μελέτης έδειξαν, μεταξύ άλλων, ότι: (α) οι προσεγγίσεις με τις κορυφαίες επιδόσεις αφορούσαν συνδυασμούς μοντέλων, (β) οι προσεγγίσεις με τη μικρότερη απόδοση ήταν είτε αμιγώς Στατιστικά, είτε αμιγώς μοντέλα Μηχανικής Μάθησης, (γ) η καλύτερη συνολική προσέγγιση ήταν μια Υβριδική λύση η οποία χρησιμοποιούσε χαρακτηριστικά Στατιστικής και Μηχανικής Μάθησης και (δ) η αυξημένη πολυπλοκότητα του μοντέλου οδηγεί ενδεχομένως σε βελτιωμένη απόδοση πρόβλεψης. Τέλος, οι προσεγγίσεις που βασίζονται καθαρά σε μεθόδους Βαθιάς Μηχανικής Μάθησης, συνήθως λειτουργούν ως μαύρα κουτιά, καθιστώντας το αποτέλεσμά τους δύσκολο να ερμηνευτεί [96], γεγονός που καθιστά τις απλούστερες προσεγγίσεις συχνά πιο επιθυμητές σε πραγματικές εφαρμογές, ειδικά εάν η απώλεια στην απόδοση δεν είναι σημαντική.

Ο πιο κοινός και ευρέως χρησιμοποιούμενος Υβριδικός συνδυασμός είναι

αυτός που αποτελείται από ARIMA και τεχνητά Νευρωνικά Δίκτυα [141], υπογραμμίζοντας έτσι την ευελιξία και των δύο μεθόδων σε μια ποικιλία τομέων χρονοσειρών. Η διατριβή αυτή, βασίζεται στην καθιερωμένη τάση, συνδυάζοντας τον ARIMA και τον TFT, μια αρχιτεκτονική βασισμένη σε Νευρωνικά Δίκτυα, ως τα δύο κυριότερα μέρη για την πρόβλεψη της συγκέντρωσης του CO₂. Η σημασία της ενσωμάτωσης του TFT είναι διπλή: πρώτον, όταν συγκρίνεται με άλλες προσεγγίσεις Βαθιάς Μηχανικής Μάθησης, όπως τα απλά LSTM, ο TFT έχει επιδείξει βελτιωμένη απόδοση σε διάφορες εργασίες πρόβλεψης χρονοσειρών [167], [399] και δεύτερον, μέσω της ανάλυσης των Βαρών του Μηχανισμού Προσοχής μπορεί να επιτύχει μεγαλύτερο βαθμό ερμηνευσιμότητας [233], [399], [398].

7.1.2.2 Βήμα 1: Πρόβλεψη με τον ARIMA

Το πρώτο βήμα της προτεινόμενης μεθοδολογίας, εστιάζει στην πρόβλεψη των τιμών συγκέντρωσης διοξειδίου του άνθρακα (CO₂), με τη χρήση ενός μοντέλου Αυτοπαλινδρόμενου Ολοκληρωμένου Κινητού Μέσου (ARIMA). Δεδομένου ότι τα μοντέλα ARIMA, δεν έχουν την δυνατότητα να διαχειριστούν δεδομένα πολυμεταβλητών χρονοσειρών, για την μοντελοποίηση, χρησιμοποιήθηκαν μόνο παρελθοντικές τιμές της συγκεκριμένης μεταβλητής-στόχου (συγκέντρωση CO₂). Κατ' αυτόν τον τρόπο, οι προβλέψεις οι οποίες προκύπτουν από την συγκεκριμένη φάση δεν λαμβάνουν υπ' όψη πρόσθετες πληροφορίες ζωτικής σημασίας, από άλλους περιβαλλοντικούς παράγοντες που υπάρχουν στο σύνολο δεδομένων, όπως η υγρασία, η θερμοκρασία και η ένταση φωτός, όπως περιγράφονται στην υποενότητα Περιγραφή και Προεπεξεργασία Δεδομένων. Ωστόσο, εστιάζοντας καθαρά στις προηγούμενες τιμές του CO₂, αυτό το βήμα εξασφαλίζει ότι αυτού του είδους οι πληροφορίες – που είναι αναμφισβήτητα το πιο σημαντικό στοιχείο πληροφορίας – λαμβάνουν περισσότερη έμφαση, όταν οι έξοδοι των μοντέλων συνδυαστούν στο τρίτο βήμα.

7.1.2.3 Βήμα 2: Πρόβλεψη με τον TFT

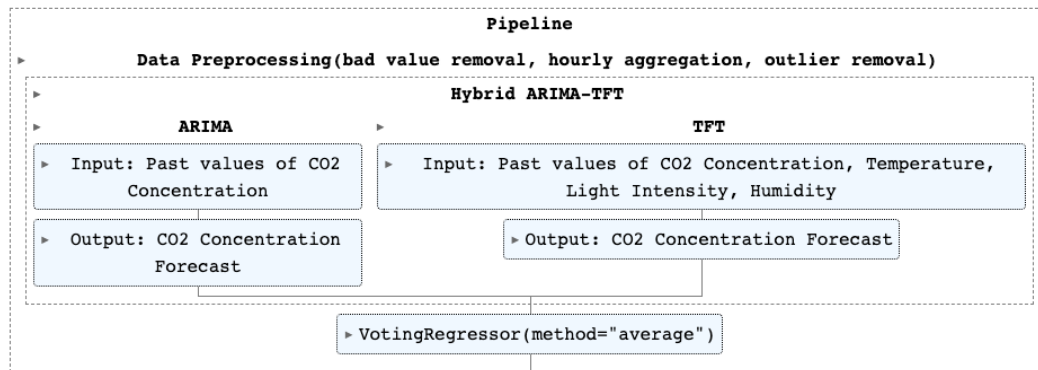
Αυτό το βήμα επιχειρεί ν' αντιμετωπίσει τις κύριες ελλείψεις του ARIMA, που χρησιμοποιούνται στο βήμα 1. Παρά την ισχύ του ARIMA ως εργαλείο για την πρόβλεψη χρονοσειρών, οι παραδοχές του σχετικά με τη γραμμικότητα και τη σταθερότητα, περιορίζουν την αποτελεσματικότητά του στη μοντελοποίηση πιο πολύπλοκων σχέσεων μεταξύ των δεδομένων, που συχνά παρατηρούνται σε χρονοσειρές που υπάρχουν στον πραγματικό κόσμο. Επιπροσθέτως, ο ARIMA, καθώς μπορεί να μάθει μόνο από τις προηγούμενες τιμές μιας συγκεκριμένης χρονοσειράς, δεν έχει τη δυνατότητα να ενσωματώσει και να εκμεταλλευτεί πληροφορίες από εξωτερικές χρονοσειρές ή άλλες μεταβλητές.

Τα πιο σύγχρονα μοντέλα Βαθιάς Μηχανικής Μάθησης, όπως οι Μετασχηματιστές Χρονικής Ένωσης (TFT), αντιμετωπίζουν τις προαναφερθείσες περιορισμένες δυνατότητες του ARIMA, καθώς είναι ικανά να μοντελοποιήσουν δεδομένα χρονοσειρών πολλαπλών μεταβλητών και να ανακαλύψουν σημαντικές πληροφορίες σχετικά με την αλληλεπίδραση μεταξύ τους. Κατά συνέπεια, οι προβλέψεις που προκύπτουν από τη διαδικασία αυτή, συμπεριλαμβάνουν όχι μόνο τις προηγούμενες τιμές της μεταβλητής-στόχου (συγκέντρωση CO₂) αλλά και τους εξωτερικούς περιβαλλοντικούς παράγοντες που διατίθενται στο σύνολο δεδομένων, όπως η θερμοκρασία, η υγρασία και η ένταση του φωτός.

7.1.2.4 Βήμα 3: Υβριδική Μοντελοποίηση ARIMA-TFT

Δεδομένου ότι ο ARIMA αναλύει αποκλειστικά τις γραμμικές σχέσεις στα δεδομένα, είναι πιο ικανός ως προς την αποτύπωση των προβλέψεων του σε σύγκριση με τον TFT. Από την άλλη πλευρά, οι προβλέψεις του TFT, λαμβάνουν υπ' όψη τις μη γραμμικές σχέσεις, ενώ εκμεταλλεύονται επίσης τον πλούσιο όγκο πρόσθετων πληροφοριών, αξιοποιώντας έτσι πλήρως την πολυμεταβλητή φύση του συνόλου δεδομένων. Σ' αυτό το βήμα, προκειμένου να χρησιμοποιηθούν τα δυνατά σημεία και των δύο, ενώ εξισορροπούνται οι μεμονωμένες αδυναμίες τους,

οι προβλέψεις από τα βήματα 1 και 2 συνδυάζονται, χρησιμοποιώντας ένα μετα-εκτιμητή παλινδρόμησης, με βάση την ψηφοφορία, παράγοντας τον μέσο όρο των δύο ανεξάρτητων προβλέψεων συγκέντρωσης CO₂. Ένα διάγραμμα ροής της όλης διαδικασίας παρουσιάζεται στο Σχήμα 7.2.



Σχήμα 7.2: Υβριδική Μοντελοποίηση ARIMA-TFT

7.1.2.5 Ερμηνευσιμότητα

Η Ερμηνευσιμότητα, αναφέρεται στον βαθμό που η έξοδος ενός μοντέλου μπορεί να εξηγηθεί και να αποδοθεί στις αντίστοιχες μεταβλητές εισόδου. Όσο υψηλότερη είναι η Ερμηνευσιμότητα ενός μοντέλου, τόσο πιο εύκολο είναι να κατανοήσουμε, γιατί έγιναν ορισμένες προβλέψεις από ένα μοντέλο δεδομένων, των αντίστοιχων δεδομένων εισόδου που έλαβε το μοντέλο [264]. Η Ερμηνευσιμότητα είναι ζωτικής σημασίας και μια πολυπόθητη ιδιότητα για όλα τα αυτοματοποιημένα συστήματα, αλλά ειδικά γι' αυτά που πρέπει να υιοθετηθούν σε ευαίσθητους τομείς, όπου οι ανθρώπινες ζωές μπορούν να επηρεαστούν άμεσα [96], όπως ο τομέας των έξυπνων πόλεων.

Και τα δύο συστατικά του Υβριδικού μοντέλου είναι ερμηνεύσιμα από μόνα τους, χωρίς την ανάγκη εφαρμογής μεθόδων ερμηνείας post-hoc. Πιο συγκεκριμένα, ο ARIMA είναι ένα μοντέλο κατηγορίας «λευκού-κουτιού». Είναι γραμμικό, με απλό σχεδιασμό και επομένως φυσικά ερμηνεύσιμο. Επιπλέον, η αρ-

χιτεκτονική του TFT, βασίζεται σε μετασχηματιστές και χρησιμοποιεί έναν νέο Μηχανισμό Προσοχής, πολλαπλών κεφαλών που μπορεί να παρέχει επιπλέον ερμηνεύσιμες πληροφορίες, μετρώντας και ταξινομώντας τη σημασία κάθε μεταβλητής εισόδου σε σχέση με τις προβλέψεις της. Ως αποτέλεσμα, το προτεινόμενο υβριδικό σύνολο είναι επίσης εγγενώς ερμηνεύσιμο.

7.1.3 Άλλα Μοντέλα Χρονοσειρών που Χρησιμοποιούνται για Σύγκριση

Για την αξιολόγηση των προγνωστικών δυνατοτήτων καθώς και της ευρωστίας της προτεινόμενης μεθόδου σε διαφορετικά σενάρια, έγιναν συγκρίσεις με άλλες δέκα προσεγγίσεις πρόβλεψης. Αυτές μπορούν να χωριστούν σε δύο μεγάλες κατηγορίες: Στατιστικές μεθόδους και μεθόδους Χρονοσειρών Βαθιάς Μηχανικής Μάθησης. Η πρώτη κατηγορία περιλαμβάνει τις μεθόδους ARIMA [57], την Εκθετική Εξομάλυνση (Exponential Smoothing) [125], Γρήγορος Μετασχηματισμός Fourier (FFT) [287] και Theta [28].

Η δεύτερη κατηγορία περιλαμβάνει τις ακόλουθες μεθόδους: DeepAR [336], N-BEATS [296], ένα Δίκτυο Μετασχηματιστή (Transformers) [380], τον TFT [233], TCN [36] και ένα LSTM [133]. Τα περισσότερα στατιστικά μοντέλα χρονοσειρών μπορούν να δέχονται μόνο δεδομένα μίας μεταβλητής, δηλαδή στην περίπτωση αυτή δέχονται μόνο τις προηγούμενες τιμές του CO₂, αγνοώντας τις άλλες περιβαλλοντικές μεταβλητές. Αντίθετα, τα μοντέλα Βαθιάς Μηχανικής Μάθησης, έχουν την δυνατότητα να χειριστούν δεδομένα πολυμεταβλητών χρονοσειρών και να μοντελοποιήσουν πολύπλοκες σχέσεις. Ο πίνακας 7.2 δείχνει ποιοι τύποι δεδομένων υποστηρίζονται ανά μοντέλο, καθώς και πληροφορίες για τους τύπους μεταβλητών, οι οποίοι αναλύονται λεπτομερέστερα στην υποενότητα Παρελθοντικές και Μελλοντικές Μεταβλητές.

Μοντέλο	Μια με- ταβλητή	Πολλές μεταβλη- τές	Παρελθοντικές μεταβλητές	Μελλοντικές μεταβλητές
ARIMA	✓			
DeepAR		✓		✓
ES	✓			
FFT	✓			
Hybrid		✓	✓	✓
LSTM		✓	✓	
N-BEATS		✓	✓	
TCN		✓	✓	
TFT		✓	✓	
Theta	✓			✓
Transformer		✓	✓	

Πίνακας 7.2: Ανάλυση των μοντέλων πρόβλεψης και των τύπων μεταβλητών που χρησιμοποιήθηκαν.

7.1.4 Παρελθοντικές και Μελλοντικές Μεταβλητές

Στα προβλήματα χρονοσειρών, γίνεται συνήθως διάκριση μεταξύ της μεταβλητής - στόχου και των εξωγενών μεταβλητών. Ο όρος «μεταβλητής-στόχου» αναφέρεται στην χρονοσειρά, η οποία πρέπει να προβλεφθεί, με βάση το ιστορικό της. Για τους σκοπούς αυτής της διατριβής, η τιμή της συγκέντρωσης CO₂ θεωρείται η μεταβλητή-στόχος. Ο όρος «εξωγενείς μεταβλητές» αναφέρεται σε χρονοσειρές, οι οποίες μπορεί να είναι χρήσιμες για την πρόβλεψη της μεταβλητής-στόχου, αλλά δεν γίνεται καμία πρόβλεψη για τις εν λόγω χρονοσειρές.

Οι εξωγενείς μεταβλητές, είναι σε θέση να χωριστούν περαιτέρω σε παρελθοντικές και μελλοντικές μεταβλητές, ανάλογα με το αν μπορούν να είναι γνωστές εκ των προτέρων ή όχι. Οι μεταβλητές των οποίων οι προηγούμενες τιμές είναι γνωστές κατά τον χρόνο πρόβλεψης, αναφέρονται ως παρελθοντικές μεταβλητές. Στην παρούσα διατριβή, οι τιμές της θερμοκρασίας, της υγρασίας και της έντασης του φωτός που περιέχονται στο σύνολο των δεδομένων, θεωρούνται όλες παρελθοντικές μεταβλητές. Οι μεταβλητές των οποίων οι μελλοντικές τιμές

είναι ήδη γνωστές κατά τον χρόνο πρόβλεψης, αναφέρονται ως μελλοντικές μεταβλητές. Αυτές, μπορεί να αντιπροσωπεύουν γνωστές μελλοντικές πληροφορίες, όπως αργίες ή ακόμα και προβλέψεις, όπως η πρόγνωση του καιρού, είναι απολύτως έγκυρες για να ενσωματωθούν στη μοντελοποίηση χρονοσειρών, όταν τούτο είναι δυνατόν. Στην προκειμένη μελέτη, η «ώρα της ημέρας» (1-24), η «ημέρα της εβδομάδας» (1-7), η «ημέρα του μήνα» (1-31) και ο «μήνας του έτους» (1-12) χρησιμοποιήθηκαν όλα ως μελλοντικές μεταβλητές. Τέτοια χρονικά χαρακτηριστικά μπορεί να είναι πολύ ισχυρά, καθώς επιτρέπουν στα μοντέλα να αποτυπώνουν καλύτερα και πιο εύκολα την τάση και την εποχικότητα της μεταβλητής-στόχου.

Θα πρέπει να σημειωθεί, ότι δεν υποστηρίζουν όλα τα μοντέλα τη χρήση παρελθοντικών και μελλοντικών μεταβλητών. Γενικά, απλούστερα Στατιστικά μοντέλα, όπως ο ARIMA και η Εκθετική Εξομάλυνση, δεν έχουν την δυνατότητα να αντιμετωπίσουν κανένα είδος εξωγενών μεταβλητών και μπορούν να δεχτούν μόνο μία μεταβλητή-στόχο. Συγκριτικά, η πλειονότητα των μεθόδων Βαθιάς Μηχανικής Μάθησης, είναι ικανή να χειρίζεται εγγενώς παρελθοντικές μεταβλητές ωστόσο, μόνο ένας περιορισμένος αριθμός μοντέλων μπορεί να κάνει χρήση μελλοντικών μεταβλητών. Στον πίνακα 7.2, παρουσιάζονται αναλυτικά οι τύποι μεταβλητών που υποστηρίζονται και χρησιμοποιούνται από κάθε μοντέλο σε αυτή τη μελέτη.

7.1.5 Μεθοδολογία Πειραμάτων

Εξετάστηκαν συνολικά 30 περιπτώσεις, χρησιμοποιώντας διαφορετικούς διαχωρισμούς δεδομένων, ορίζοντες πρόβλεψης, μεθοδολογίες εκπαίδευσης και μετρικές. Αυτές οι περιπτώσεις παρουσιάζονται αναλυτικά στον πίνακα 7.3. Επίσης για όλα τα πειράματα, χρησιμοποιήθηκε εκτενώς η βιβλιοθήκη Darts της Python [150].

Περίπτωση #	Ορίζοντας	Διαχωρισμός Δεδομένων (Εκπαίδευση - Δοκιμή)	Επανεκπαίδευση	Μετρική
Περίπτωση 1	Βραχυπρόθεσμος (1ω)	80-20	ναι	RMSE
Περίπτωση 2	Βραχυπρόθεσμος (1ω)	80-20	όχι	RMSE
Περίπτωση 3	Βραχυπρόθεσμος (1ω)	90-10	ναι	RMSE
Περίπτωση 4	Βραχυπρόθεσμος (1ω)	90-10	όχι	RMSE
Περίπτωση 5	Μεσοπρόθεσμος (24ω)	80-20	ναι	RMSE
Περίπτωση 6	Μεσοπρόθεσμος (24ω)	80-20	όχι	RMSE
Περίπτωση 7	Μεσοπρόθεσμος (24ω)	90-10	ναι	RMSE
Περίπτωση 8	Μεσοπρόθεσμος (24ω)	90-10	όχι	RMSE
Περίπτωση 9	Μακροπρόθεσμος (168ω)	80-20	ναι	RMSE
Περίπτωση 10	Μακροπρόθεσμος (168ω)	80-20	όχι	RMSE
Περίπτωση 11	Βραχυπρόθεσμος (1ω)	80-20	ναι	MAE
Περίπτωση 12	Βραχυπρόθεσμος (1ω)	80-20	όχι	MAE
Περίπτωση 13	Βραχυπρόθεσμος (1ω)	90-10	ναι	MAE
Περίπτωση 14	Βραχυπρόθεσμος (1ω)	90-10	όχι	MAE
Περίπτωση 15	Μεσοπρόθεσμος (24ω)	80-20	ναι	MAE
Περίπτωση 16	Μεσοπρόθεσμος (24ω)	80-20	όχι	MAE
Περίπτωση 17	Μεσοπρόθεσμος (24ω)	90-10	ναι	MAE
Περίπτωση 18	Μεσοπρόθεσμος (24ω)	90-10	όχι	MAE
Περίπτωση 19	Μακροπρόθεσμος (168ω)	80-20	ναι	MAE
Περίπτωση 20	Μακροπρόθεσμος (168ω)	80-20	όχι	MAE
Περίπτωση 21	Βραχυπρόθεσμος (1ω)	80-20	ναι	MAPE
Περίπτωση 22	Βραχυπρόθεσμος (1ω)	80-20	όχι	MAPE
Περίπτωση 23	Βραχυπρόθεσμος (1ω)	90-10	ναι	MAPE
Περίπτωση 24	Βραχυπρόθεσμος (1ω)	90-10	όχι	MAPE
Περίπτωση 25	Μεσοπρόθεσμος (24ω)	80-20	ναι	MAPE
Περίπτωση 26	Μεσοπρόθεσμος (24ω)	80-20	όχι	MAPE
Περίπτωση 27	Μεσοπρόθεσμος (24ω)	90-10	ναι	MAPE
Περίπτωση 28	Μεσοπρόθεσμος (24ω)	90-10	όχι	MAPE
Περίπτωση 29	Μακροπρόθεσμος (168ω)	80-20	ναι	MAPE
Περίπτωση 30	Μακροπρόθεσμος (168ω)	80-20	όχι	MAPE

Πίνακας 7.3: Περιγραφή μεθοδολογίας πειραμάτων.

7.1.5.1 Παράθυρο Αναδρομής (Look-back Window) και Ορίζοντες Πρόβλεψη (Forecasting Horizons)

Ένα παράθυρο αναδρομής αναφέρεται σε μια δεδομένη χρονική περίοδο, που προηγείται του χρόνου της πρόβλεψης, κατά την οποία το μοντέλο έχει πρό-

σβαση σε πληροφορίες από τις οποίες μαθαίνει για να κάνει προβλέψεις. Από την άλλη πλευρά, ένας ορίζοντας πρόβλεψης δείχνει πόσο μακριά, στο μέλλον, προβλέπει ένα μοντέλο. Σε μία έξυπνη πόλη, οι προβλέψεις με διαφορετικούς συνδυασμούς παραθύρων αναδρομής και οριζόντων πρόβλεψης, έχουν την δυνατότητα να χρησιμοποιηθούν για διαφορετικούς σκοπούς. Στην παρούσα μελέτη, χρησιμοποιήθηκαν τρεις διαφορετικές ρυθμίσεις παραθύρων αναδρομής και οριζόντων πρόβλεψης:

- ▶ Ορίζοντας βραχυπρόθεσμης πρόβλεψης: Πρόβλεψη της συγκέντρωσης CO₂ μετά από (1) μία ώρα μ' ένα παράθυρο αναδρομής 24 ωρών.
- ▶ Ορίζοντας μεσοπρόθεσμης πρόβλεψης: Πρόβλεψη της συγκέντρωσης CO₂ μετά από (1) μία ημέρα (24 ώρες), δεδομένου του παραθύρου αναδρομής 168 ωρών.
- ▶ Ορίζοντας μακροπρόθεσμης πρόβλεψης: Πρόβλεψη της συγκέντρωσης CO₂ μετά από (1) μία εβδομάδα (168 ώρες), δεδομένου του παραθύρου αναδρομής 240 ωρών.

7.1.5.2 Διαχωρισμός Δεδομένων

Για όλα τα πειράματα, το σύνολο δεδομένων χωρίστηκε μεταξύ δεδομένων εκπαίδευσης και δεδομένων δοκιμής. Το πρώτο σετ δεδομένων ήταν διαθέσιμο στα μοντέλα, κατά τη διάρκεια της διαδικασίας της εκπαίδευσης, δηλαδή της ελαχιστοποίησης των σφαλμάτων, ενώ το δεύτερο παρέμεινε άγνωστο στα μοντέλα και χρησιμοποιήθηκε μόνο για σκοπούς αξιολόγησης. Πιο συγκεκριμένα, τα πειράματα για τους βραχυπρόθεσμους και τους μεσοπρόθεσμους ορίζοντες πρόβλεψης, πραγματοποιήθηκαν για δύο διαφορετικές υποδιαιρέσεις των δεδομένων εκπαίδευσης-δοκιμής, 90-10 και 80-20. Ωστόσο, στην περίπτωση του μακροπρόθεσμου ορίζοντα πρόβλεψης, η διάσπαση 90-10 δεν ήταν δυνατή λόγω έλλειψης του απαιτούμενου αριθμού δεδομένων για την πρόβλεψη.

7.1.5.3 Μεθοδολογία Εκπαίδευσης (με Επανεκπαίδευση vs Χωρίς Επανεκπαίδευση)

Τα Στατιστικά μοντέλα χρονοσειρών, επανεκπαιδεύονται πάντα σε ολόκληρο το διαθέσιμο ιστορικό, μόλις γίνουν διαθέσιμα νέα χρονικά σημεία, επεκτείνοντας έτσι πάντα το παράθυρο αναδρομής τους. Όμως αυτή η διαδικασία επανεκπαίδευσης από το μηδέν, κάθε φορά που παρατηρούνται νέα σημεία δεδομένων, δύναται να καταναλώσει πολλούς πόρους, ειδικά εαν πρόκειται για μοντέλα Βαθιάς Μηχανικής Μάθησης, τα οποία είναι γνωστό ότι έχουν μεγάλες απαιτήσεις. Για τον λόγο αυτό, οι μέθοδοι Βαθιάς Μηχανικής Μάθησης προσφέρουν την εναλλακτική της εκπαίδευσης μόνο μία φορά στο αρχικό σύνολο δεδομένων εκπαίδευσης και στη συνέχεια την εκμάθησης από νέες παρατηρήσεις με αναδρομικό τρόπο, χωρίς να επεξεργάζονται ξανά ολόκληρο το σετ δεδομένων εκπαίδευσης. Στην εν λόγω μελέτη, όλα τα πειράματα αναφορικά με μοντέλα Βαθιάς Μηχανικής Μάθησης πραγματοποιήθηκαν και με τους δύο τρόπους δηλαδή με διαδικασία επανεκπαίδευσης και χωρίς.

7.1.5.4 Μετρικές Αξιολόγησης

Όσον αφορά τις Μετρικές Αξιολόγησης, η ρίζα μέσου τετραγωνικού σφάλματος (RMSE), το μέσο απόλυτο σφάλμα (MAE), καθώς και το μέσο απόλυτο ποσοστό σφάλματος (MAPE), χρησιμοποιήθηκαν για την Αξιολόγηση της Απόδοσης κάθε μοντέλου. Τόσο το RMSE όσο και το MAE μετρούν τις διαφορές μεταξύ των προβλεπόμενων και των πραγματικών τιμών. Θα πρέπει να σημειωθεί ότι τα μεγάλα σφάλματα έχουν δυσανάλογα αρνητική επίδραση και στα δύο και, ως εκ τούτου, είναι ευαίσθητα σε ακραίες τιμές. Η χρήση της διαφοράς μεταξύ των προβλεπόμενων και των πραγματικών τιμών, χωρίς να λαμβάνεται υπ' όψη το μέγεθος τους, είναι μη διαισθητικό, καθώς οι εμπλεκόμενες τιμές μπορεί να διαφέρουν πολύ μεταξύ των διαφορετικών προβλημάτων. Το MAPE προσπαθεί λύσει αυτό το πρόβλημα, επιστρέφοντας το σφάλμα ως ποσοστό της αρχικής τιμής που

προσπάθησε να προβλέψει το μοντέλο.

Το RMSE ενός μοντέλου για ένα σύνολο n σημείων, ορίζεται όπως φαίνεται στην εξίσωση 7.1:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7.1)$$

όπου y_i είναι η πραγματική τιμή του i -ου σημείου και $\hat{y}_i$ η προβλεπόμενη τιμή του i -ου σημείου.

Το MAE ενός μοντέλου για ένα σύνολο n σημείων, ορίζεται όπως φαίνεται στην εξίσωση 7.2:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n (|y_i - \hat{y}_i|) \quad (7.2)$$

όπου y_i είναι η πραγματική τιμή του i -ου σημείου και $\hat{y}_i$ η προβλεπόμενη τιμή του i -ου σημείου δεδομένων.

Το MAPE ενός μοντέλου για ένα σύνολο n σημείων, ορίζεται όπως φαίνεται στην εξίσωση 7.3:

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left(\left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \quad (7.3)$$


όπου y_i είναι η πραγματική τιμή του i -ου σημείου δεδομένων και $\hat{y}_i$ η προβλεπόμενη τιμή του i -ου σημείου δεδομένων.

7.2 Αποτελέσματα Πειραμάτων


7.2.1 Βραχυπρόθεσμος Ορίζοντας Πρόβλεψης

Τα μοντέλα τα οποία κάνουν χρήση του Βραχυπρόθεσμου Ορίζοντα Πρόβλεψης, χρησιμοποιούν ουσιαστικά τη χαμηλότερη μονάδα χρόνου στο σύνολο δεδομένων, μετά την προεπεξεργασία του, η οποία είναι η μία (1) ώρα. Σ' αυτήν την περίπτωση η αξιολόγηση είναι απλή. Τέτοια μοντέλα παράγουν μόνο μία πρόβλεψη, μία ώρα στο μέλλον και αυτή η προβλεπόμενη τιμή συγκρίνεται με την πραγματική τιμή. Πραγματοποιήθηκαν συνολικά τέσσερα διαφορετικά πειράματα, με βάση τον διαχωρισμό του σετ δεδομένων Εκπαίδευσης-Δοκιμής (80-20 και 90-10) καθώς και με τον Μηχανισμό Επανεκπαίδευσης (ναι/όχι). Τα αποτελέσματα για κάθε πείραμα παρουσιάζονται στους πίνακες 7.4 και 7.5 αντίστοιχα. Τα αποτελέσματα της Επανεκπαίδευσης των μοντέλων Βαθιάς Μηχανικής Μάθησης ήταν εμφανή σ' έναν τόσο σύντομο χρονικά Ορίζοντα Πρόβλεψης, καθώς στη συντριπτική πλειονότητα των περιπτώσεων, παρατηρήθηκε βελτίωση της απόδοσης τους, υπογραμμίζοντας τη σημασία της γνώσης της προηγούμενης ώρας για την πρόβλεψη της επόμενης ώρας. Κυρίως, το μέσο απόλυτο σφάλμα του TCN μειώθηκε από 37.876 σε 13.8507 μετά την εφαρμογή της προσέγγισης επανεκπαίδευσης. Οι προβλέψεις των τριών συνολικά καλύτερων μοντέλων για εκείνη την περίοδο εμφανίζονται στο Σχήμα 7.3 και στο Σχήμα 7.4 για τους διαχωρισμούς 80-20 και 90-10 αντίστοιχα.

Όσον αφορά την ερμηνευσιμότητα, το Σχήμα 7.5 εμφανίζει την κατάταξη της συνεισφοράς των χαρακτηριστικών ως ποσοστά για το μοντέλο TFT όταν πρόκειται για βραχυπρόθεσμη πρόβλεψη. Η θερμοκρασία είναι μακράν το πιο σημαντικό χαρακτηριστικό, συνεισφέροντας σχεδόν κατά 50% στις μελλοντικές προβλέψεις του CO₂. Ακολουθείται από προηγούμενες τιμές συγκέντρωσης CO₂, έντασης φωτός και χρόνου, ενώ ο λιγότερο σημαντικός προγνωστικός παράγο-



Σχήμα 7.3: Προβλέψεις για τον Βραχυπρόθεσμο Ορίζοντα Πρόβλεψης (1 ώρα) έναντι των πραγματικών τιμών για το σετ δεδομένων δοκιμής· διαχωρισμός: 80-20.



Σχήμα 7.4: Προβλέψεις για τον Βραχυπρόθεσμο Ορίζοντα Πρόβλεψης (1 ώρα) έναντι των πραγματικών τιμών για το σετ δεδομένων δοκιμής· διαχωρισμός: 90-10.

Μοντέλο	MAE	RMSE	MAPE	Επανεκ.
ARIMA	17.448	24.6932	7.1174	όχι
ARIMA	17.448	24.6932	7.1174	ναι
DeepAR	64.7228	77.2451	27.4174	ναι
DeepAR	131.7028	138.3546	55.5346	όχι
ES	18.8689	26.4666	7.6474	όχι
ES	18.8689	26.4666	7.6474	ναι
FFT	58.8585	79.6313	20.9765	όχι
FFT	58.8585	79.6313	20.9765	ναι
Hybrid	14.8924	21.8897	6.0875	όχι
Hybrid	15.3382	21.7836	6.2550	ναι
LSTM	22.8856	30.9246	9.1051	ναι
LSTM	41.7699	46.5224	17.0413	όχι
N-BEATS	20.0911	27.3967	8.0493	ναι
N-BEATS	27.8837	36.5021	10.9623	όχι
TCN	15.3361	22.6401	6.2671	ναι
TCN	47.6637	52.0583	19.5002	όχι
TFT	15.7214	22.2269	6.4413	όχι
TFT	17.1849	23.1732	6.9738	ναι
Theta	18.4945	26.0843	7.548	όχι
Theta	18.4945	26.0843	7.548	ναι
Transformer	19.8563	26.7944	8.0028	ναι
Transformer	41.826	47.7851	16.483	όχι

Πίνακας 7.4: Αποτελέσματα για τον Βραχυπρόθεσμο Ορίζοντα Πρόβλεψης (1 ώρα)- διαχωρισμός 80-20. Κατάταξη βάσει ονόματος αύξουσα, MAE φθίνουσα.


ντας για την πρόβλεψη του CO₂ είναι η υγρασία. Οι πίνακες με την συνεισφοράς των χαρακτηριστικών εμφανίζεται μόνο για τη διαίρεση 80-20 για όλους τους ορίζοντες. Ο αντίστοιχος πίνακας για το διαχωρισμό 90-10 είναι αρκετά παρόμοιος και δεν προσφέρει νέες σημαντικές πληροφορίες για τη λειτουργία του μοντέλου.

Μοντέλο	MAE	RMSE	MAPE	Επανεκ.
ARIMA	16.5583	25.0833	6.947	όχι
ARIMA	16.5583	25.0833	6.947	ναι
DeepAR	35.9894	46.7989	16.2622	όχι
DeepAR	54.9676	64.7337	23.6953	ναι
ES	18.2426	26.3802	7.6694	όχι
ES	18.2426	26.3802	7.6694	ναι
FFT	40.0957	47.9071	16.6586	όχι
FFT	40.0957	47.9071	16.6586	ναι
Hybrid	14.4070	22.0454	6.0505	ναι
Hybrid	14.8782	23.0485	6.2390	όχι
LSTM	18.5033	26.8	7.7944	ναι
LSTM	26.3356	32.4004	11.2312	όχι
N-BEATS	20.0553	28.7076	8.4444	ναι
N-BEATS	32.9029	45.9709	13.3077	όχι
TCN	13.8507	22.3402	5.8706	ναι
TCN	37.876	42.9418	16.4676	όχι
TFT	14.9456	22.6287	6.2223	ναι
TFT	15.2929	23.151	6.3806	όχι
Theta	17.7509	25.8706	7.4749	όχι
Theta	17.7509	25.8706	7.4749	ναι
Transformer	18.466	25.2346	7.7625	ναι
Transformer	31.7511	38.764	13.6757	όχι

Πίνακας 7.5: Αποτελέσματα για τον Βραχυπρόθεσμο Ορίζοντα Πρόβλεψης (1 ώρα)- διαχωρισμός 90-10. Κατάταξη βάσει ονόματος αύξουσα, MAE φθίνουσα.

7.2.2 Μεσοπρόθεσμος Ορίζοντας Πρόβλεψης

Τα μοντέλα που χρησιμοποιούν τον Μεσοπρόθεσμο Ορίζοντα Πρόβλεψης (24 ώρες), πρέπει να βασίζονται στις δικές τους προβλέψεις προκειμένου να έχουν την δυνατότητα να κάνουν προβλέψεις στα επόμενα χρονικά βήματα. Για κάθε δείγμα του συνόλου δεδομένων δοκιμής, και σε κάθε βήμα εντός του χρονικού Ορίζοντα Πρόβλεψης, γίνεται χρήση Αυτόματης Παλινδρόμησης: δηλαδή η πρόβλεψη για ένα χρονικό βήμα τη χρονική στιγμή t χρησιμοποιείται για την πρόβλεψη του επόμενου χρονικού βήματος $t+1$ και αυτό συνεχίζεται για κάθε t μέχρι το τέλος του χρονικού ορίζοντα πρόβλεψης, το οποίο τέλος αντιστοιχεί στο τελευταίο χρονικό βήμα του Ορίζοντα. Στην περίπτωση αυτή, μόνο η πρόβλεψη




Σχήμα 7.5: Συνεισφορά των χαρακτηριστικών για Βραχυπρόθεσμο Ορίζοντα Πρόβλεψης (1 ώρα). διαχωρισμός: 80-20


για την 24η ώρα συγκρίνεται με την αντίστοιχη πραγματική τιμή. Στο Σχ. 7.6, εμφανίζεται η διαδικασία δημιουργίας και αξιολόγησης βάση του Μεσοπρόθεσμου Ορίζοντα Πρόβλεψης.

Παρόμοια με τα πειράματα Βραχυπρόθεσμου Ορίζοντα, εξετάστηκαν συνολικά τέσσερις διαφορετικοί διαχωρισμοί (80-20 και 90-10) καθώς και ο Μηχανισμός Επανεκπαίδευσης (ναι/όχι). Για κάθε διαχωρισμό, τα αντίστοιχα αποτελέσματα παρουσιάζονται στους πίνακες 7.6 και 7.7. Στα πειράματα Μεσοπρόθεσμου Ορίζοντα, η Επανεκπαίδευση των μοντέλων Βαθιάς Μηχανικής Μάθησης με τις νέες ωριαίες παρατηρήσεις, όπως γίνονται γνωστές/διαθέσιμες, δεν αποδείχθηκε τόσο σημαντική κατά την πρόβλεψη της 24ης ώρας στο μέλλον. Αυτό βέβαια σε μεγάλο βαθμό ήταν αναμενόμενο, καθώς η συσχέτιση μεταξύ των τιμών δύο διαδοχικών χρονικών βημάτων είναι συνήθως υψηλότερη, σε σύγκριση με δύο τιμές που απέχουν 24 χρονικά βήματα μεταξύ τους.

Στο Σχ. 7.9 η συνεισφορά των χαρακτηριστικών για το μοντέλο παρουσιάζονται ως ποσοστά. Η κατάταξη των χαρακτηριστικών, διατηρείται ίδια με αυτή της βραχυπρόθεσμης πρόβλεψης, με τη θερμοκρασία να παραμένει ως ο πιο κρίσιμος παράγοντας, αν και το ποσοστό της συνεισφοράς της μειώνεται



Σχήμα 7.6: Μεσοπρόθεσμος Ορίζοντας Πρόβλεψης: παράθυρο ανασκόπησης, πρόβλεψη και αξιολόγηση




Σχήμα 7.7: Προβλέψεις για τον Μεσοπρόθεσμο Ορίζοντα Πρόβλεψης (24 ώρες) έναντι των πραγματικών τιμών για το σετ δεδομένων δοκιμής· Διαχωρισμός: 80-20.


Μοντέλο	MAE	RMSE	MAPE	Επανεκ.
ARIMA	50.4179	66.5427	20.3895	όχι
ARIMA	50.4179	66.5427	20.3895	ναι
DeepAR	51.5311	65.1488	19.3256	ναι
DeepAR	148.1671	163.798	64.5237	όχι
ES	62.3673	80.3399	24.9125	όχι
ES	62.3673	80.3399	24.9125	ναι
FFT	78.2073	106.9273	26.0654	όχι
FFT	78.2073	106.9273	26.0654	ναι
Hybrid	37.2767	50.2714	14.0757	όχι
Hybrid	37.3014	49.1574	14.0701	ναι
LSTM	69.8758	88.1066	28.7614	ναι
LSTM	74.4279	90.2769	26.9331	όχι
N-BEATS	77.1808	94.3703	27.9407	όχι
N-BEATS	77.3075	95.9042	29.0755	ναι
TCN	76.0906	94.678	26.9718	όχι
TCN	85.9327	109.742	35.625	ναι
TFT	36.2344	49.7219	13.1591	όχι
TFT	51.2105	62.8617	19.2797	ναι
Theta	61.4604	79.2995	24.6313	όχι
Theta	61.4604	79.2995	24.6313	ναι
Transformer	67.2404	86.1076	23.2706	όχι
Transformer	76.9394	99.9903	32.1631	ναι

Πίνακας 7.6: Αποτελέσματα για τον Μεσοπρόθεσμο ορίζοντα πρόβλεψης (24 ώρες)· διαχωρισμός 80-20. Κατάταξη βάσει ονόματος αύξουσα, MAE φθίνουσα.

σε περίπου 35%. Επιπλέον, τόσο η συνεισφορά της συγκέντρωσης CO₂ όσο και της έντασης του φωτός αυξάνονται, ενώ η συνεισφορά του χρόνου μειώνεται καθώς αυξάνεται ο Ορίζοντας Πρόβλεψης. Επομένως όπως και στην περίπτωση της Βραχυπρόθεσμης Πρόβλεψης, έτσι και στην περίπτωση του Μεσοπρόθεσμου Ορίζοντα Πρόβλεψης, η συνεισφορά των χαρακτηριστικών περιορίζεται στον διαχωρισμό 80-20, δεδομένου ότι οι αντίστοιχες τιμές για τον διαχωρισμό 90-10 είναι ανάλογες και δεν παρέχουν πρόσθετες πληροφορίες.



Σχήμα 7.8: Προβλέψεις για τον Μεσοπρόθεσμο Ορίζοντα Πρόβλεψης (24 ώρες) έναντι των πραγματικών τιμών για το σετ δεδομένων δοκιμής· Διαχωρισμός: 90-10.



Σχήμα 7.9: Συνεισφορά των χαρακτηριστικών για Μεσοπρόθεσμο Ορίζοντα Πρόβλεψης (24 ώρες). Διαχωρισμός: 80-20

Μοντέλο	MAE	RMSE	MAPE	Επανεκ.
ARIMA	52.0185	63.5268	23.424	όχι
ARIMA	52.0185	63.5268	23.424	ναι
DeepAR	35.4227	45.8422	14.8968	ναι
DeepAR	83.7181	103.7674	37.3648	όχι
ES	65.3607	78.0223	29.1344	όχι
ES	65.3607	78.0223	29.1344	ναι
FFT	42.2596	52.1752	16.9636	όχι
FFT	42.2596	52.1752	16.9636	ναι
Hybrid	29.4695	36.5776	13.164	όχι
Hybrid	30.7673	38.0473	13.682	ναι
LSTM	78.7371	95.8902	36.6992	όχι
LSTM	86.3846	106.3583	39.5714	ναι
N-BEATS	55.2179	68.9673	24.7866	όχι
N-BEATS	65.2014	83.7045	29.6462	ναι
TCN	58.733	70.0161	24.57	όχι
TCN	92.241	120.2069	42.0035	ναι
TFT	31.5093	37.5722	13.7158	όχι
TFT	46.5937	53.5309	19.7722	ναι
Theta	64.6421	77.2401	28.9297	όχι
Theta	64.6421	77.2401	28.9297	ναι
Transformer	51.3384	60.9133	21.1374	όχι
Transformer	78.3312	98.7249	36.9034	ναι

Πίνακας 7.7: Αποτελέσματα για τον Μεσοπρόθεσμο Ορίζοντα Πρόβλεψης (24 ώρες)· Διαχωρισμός 90-10. Κατάταξη βάσει ονόματος αύξουσας, MAE φθίνουσας.

7.2.3 Μακροπρόθεσμος Ορίζοντας Πρόβλεψης


Ομοίως με τα πειράματα Μεσοπρόθεσμης Πρόβλεψης, τα μοντέλα με Μακροπρόθεσμο Ορίζοντα Πρόβλεψης, ακολουθούν παρόμοια διαδικασία αξιολόγησης, βασιζόμενα στις δικές τους προβλέψεις για τη δημιουργία μελλοντικών εκτιμήσεων. Συγκεκριμένα, η αξιολόγηση επικεντρώνεται μόνο στην πρόβλεψη της τελευταίας χρονικής στιγμής του Ορίζοντα Πρόβλεψης, δηλαδή της 168ης ώρας. Λόγω του περιορισμένου όγκου δεδομένων, το πείραμα για τον Μακροπρόθεσμο Ορίζοντα, πραγματοποιήθηκε μόνο με έναν διαχωρισμό (80-20). Εξετάστηκαν δύο διαφορετικές ρυθμίσεις, βασιζόμενες στην εφαρμογή ή όχι του Μηχανισμού Επανεκπαίδευσης. Τα σχετικά αποτελέσματα παρουσιάζονται στον πίνακα 7.8. Στο

πλαίσιο της Μακροπρόθεσμης Πρόβλεψης, τα αποτελέσματα παρουσιάζουν αυξημένη αστάθεια καθώς η πρόβλεψη επεκτείνεται πολύ μακριά στο μέλλον. Αυτή η τάση αποτυπώνεται στο Σχήμα 7.10, όπου παρουσιάζονται οι προβλέψεις των τριών συνολικά καλύτερων μοντέλων, σε σύγκριση με τις πραγματικές τιμές για την αντίστοιχη περίοδο, χρησιμοποιώντας τον διαχωρισμό 80-20.

Μοντέλο	MAE	RMSE	MAPE	Επανεκ.
ARIMA	50.0553	59.9567	22.4499	όχι
ARIMA	50.0553	59.9567	22.4499	ναι
DeepAR	53.6133	65.1733	21.681	όχι
DeepAR	361.8434	383.8009	162.3037	ναι
ES	59.5156	70.124	25.3462	όχι
ES	59.5156	70.124	25.3462	ναι
FFT	41.4947	57.8828	16.0627	όχι
FFT	41.4947	57.8828	16.0627	ναι
Hybrid	27.60433	40.0019	11.0065	ναι
Hybrid	52.01891	61.6153	21.8509	όχι
LSTM	36.3327	45.9371	14.5081	όχι
LSTM	47.7941	60.1755	20.4239	ναι
N-BEATS	67.8996	91.989	27.0301	ναι
N-BEATS	69.2761	87.3965	27.3918	όχι
TCN	41.112	53.0607	16.4957	όχι
TCN	57.9019	74.9861	23.097	ναι
TFT	42.7254	50.6654	18.6652	ναι
TFT	69.4283	93.8396	29.4499	όχι
Theta	52.4786	64.0677	22.3683	όχι
Theta	52.4786	64.0677	22.3683	ναι
Transformer	35.0836	44.6991	14.2247	όχι
Transformer	56.2405	71.9889	22.4218	ναι


Πίνακας 7.8: Αποτελέσματα για τον Μακροπρόθεσμο Ορίζοντα Πρόβλεψης (168 ώρες)· διαχωρισμός 80-20. Κατάταξη βάσει ονόματος αύξουσα, MAE φθίνουσα.

Στο Σχ. 7.11 παρουσιάζεται συνεισφορά των χαρακτηριστικών για το μοντέλο Μακροπρόθεσμης Πρόβλεψης, όπου παρατηρείτε μια παρόμοια τάση με τις προηγούμενες αναλύσεις Βραχυπρόθεσμης και Μεσοπρόθεσμης Πρόβλεψης. Η θερμοκρασία και οι τιμές του CO₂ παραμένουν στις δύο κορυφαίες θέσεις, ως οι πλέον πιο σημαντικοί προγνωστικοί παράγοντες. Είναι αξιοσημείωτο ότι (1) η



Σχήμα 7.10: Προβλέψεις για τον Μακροπρόθεσμο Ορίζοντα Πρόβλεψης (168 ώρες) έναντι των πραγματικών τιμών για το σετ δεδομένων δοκιμής· διαχωρισμός: 80-20.

υγρασία ανεβαίνει από την τελευταία στην τρίτη θέση, συνεισφέροντας περίπου το 10% στις προβλέψεις, και (2) η συνεισφορά του χρόνου ως προγνωστική μεταβλητή μειώνεται συνεχώς καθώς αυξάνεται το μήκος του Ορίζοντα Πρόβλεψης.



Σχήμα 7.11: Συνεισφορά των χαρακτηριστικών για τον Μακροπρόθεσμο Ορίζοντα Πρόβλεψης (168 ώρες). Διαχωρισμός: 80-20

7.2.4 Friedman τεστ & Holm post-hoc τεστ

Για την καλύτερη κατανόηση της συνολικής απόδοσης των μοντέλων και την κατάταξη των διαφορετικών πειραματισμών, εφαρμόστηκε το μη παραμετρικό στατιστικό τεστ Friedman [121]. Οι τελικές βαθμολογίες για τα MAE, RMSE και MAPE παρουσιάζονται στους πίνακες 7.9, 7.10 και 7.11 αντίστοιχα. Τα ευρήματα δείχνουν ότι η υβριδική προσέγγιση, παρήγαγε τα καλύτερα αποτελέσματα συνολικά, σε σύγκριση με τις άλλες προσεγγίσεις για όλες τις μετρήσεις και σε πολλές περιπτώσεις οι διαφορές ήταν στατιστικά σημαντικές, όπως επιβεβαιώθηκε από την εφαρμογή του post-hoc τεστ Holm [158]. Πιο συγκεκριμένα, όταν η υβριδική προσέγγιση επανεκπαιδευόταν με κάθε νέο σημείο δεδομένων, καθώς αυτό γινόταν διαθέσιμο, η διαφορά στην απόδοση ήταν στατιστικά σημαντική (με επίπεδο σημαντικότητας 5%) σε 13 από τις 20 περιπτώσεις όσον αφορά το RMSE, σε 5 από τις 20 περιπτώσεις για το MAE και σε 6 από τις 20 περιπτώσεις όσον αφορά το MAPE.

Όπως ήταν αναμενόμενο, στην μη εφαρμογή της μεθοδολογίας επανεκπαίδευσης, οι επιδόσεις μειώθηκαν και η διαφορά στην απόδοση ήταν στατιστικά σημαντική σε 2 από τις 20 περιπτώσεις για τη μέτρηση RMSE, σε 3 από τις 20

για το MAE και σε μόλις 1 από τις 20 για το MAPE. Όμως, η επανεκπαίδευση δεν έρχεται χωρίς κόστος, καθώς απαιτεί σημαντικούς υπολογιστικούς πόρους. Επομένως θα πρέπει να προτιμάται, μόνο εφόσον το επιτρέπουν οι διαθέσιμοι πόροι και οι συγκεκριμένες περιστάσεις.

Μοντέλο	Κατάταξη (MAE)
Hybrid με επανεκπαίδευση	2.2
Hybrid χωρίς επανεκπαίδευση	4.0
TFT με επανεκπαίδευση	5.8
TFT χωρίς επανεκπαίδευση	7.2
ARIMA χωρίς επανεκπαίδευση	7.3
ARIMA με επανεκπαίδευση	7.3
Theta χωρίς επανεκπαίδευση	11.5
Theta με επανεκπαίδευση	11.5
Transformer χωρίς επανεκπαίδευση	12.2
TCN με επανεκπαίδευση	13.6
TCN χωρίς επανεκπαίδευση	14.8
LSTM χωρίς επανεκπαίδευση	15.0
ES με επανεκπαίδευση	15.1
ES χωρίς επανεκπαίδευση	15.1
FFT με επανεκπαίδευση	15.3
FFT χωρίς επανεκπαίδευση	15.3
LSTM με επανεκπαίδευση	15.4
DeepAR με επανεκπαίδευση	16.4
Transformer με επανεκπαίδευση	16.6
N-BEATS χωρίς επανεκπαίδευση	17.6
N-BEATS με επανεκπαίδευση	17.8
DeepAR χωρίς επανεκπαίδευση	21.2

Πίνακας 7.9: Στατιστικό τεστ Friedman χρησιμοποιώντας το MAE.

Μοντέλο	Κατάταξη (RMSE)
Hybrid με επανεκπαίδευση	1.4
Hybrid χωρίς επανεκπαίδευση	4.2
TFT με επανεκπαίδευση	4.6
TFT χωρίς επανεκπαίδευση	7.0
ARIMA χωρίς επανεκπαίδευση	7.5
ARIMA με επανεκπαίδευση	7.5
Theta χωρίς επανεκπαίδευση	12.1
Theta με επανεκπαίδευση	12.1
Transformer χωρίς επανεκπαίδευση	12.2
TCN με επανεκπαίδευση	14.6
ES με επανεκπαίδευση	14.7
ES χωρίς επανεκπαίδευση	14.7
TCN χωρίς επανεκπαίδευση	14.8
LSTM χωρίς επανεκπαίδευση	14.8
DeepAR με επανεκπαίδευση	15.6
FFT χωρίς επανεκπαίδευση	15.7
FFT με επανεκπαίδευση	15.7
LSTM με επανεκπαίδευση	15.8
Transformer με επανεκπαίδευση	16.4
N-BEATS χωρίς επανεκπαίδευση	17.2
N-BEATS με επανεκπαίδευση	18.2
DeepAR χωρίς επανεκπαίδευση	21.4

Πίνακας 7.10: Στατιστικό τεστ Friedman χρησιμοποιώντας το RMSE.

Μοντέλο	Κατάταξη (MAPE)
Hybrid με επανεκπαίδευση	1.8
Hybrid χωρίς επανεκπαίδευση	4.2
TFT με επανεκπαίδευση	5.2
TFT χωρίς επανεκπαίδευση	7.2
ARIMA χωρίς επανεκπαίδευση	9.1
ARIMA με επανεκπαίδευση	9.1
Transformer χωρίς επανεκπαίδευση	11.0
Theta χωρίς επανεκπαίδευση	11.5
Theta με επανεκπαίδευση	11.5
TCN με επανεκπαίδευση	13.8
FFT χωρίς επανεκπαίδευση	13.9
FFT με επανεκπαίδευση	13.9
ES με επανεκπαίδευση	15.1
ES χωρίς επανεκπαίδευση	15.1
TCN χωρίς επανεκπαίδευση	15.2
LSTM χωρίς επανεκπαίδευση	15.2
DeepAR με επανεκπαίδευση	16.0
LSTM με επανεκπαίδευση	16.4
Transformer με επανεκπαίδευση	17.2
N-BEATS χωρίς επανεκπαίδευση	17.6
N-BEATS με επανεκπαίδευση	18.4
DeepAR χωρίς επανεκπαίδευση	20.2

Πίνακας 7.11: Στατιστικό τεστ Friedman χρησιμοποιώντας το MAPE.

Κεφάλαιο 8

Συμπεράσματα και Μελλοντικές Επεκτάσεις

Καθώς η διατριβή πλησιάζει στην ολοκλήρωσή της, στο τελευταίο κεφάλαιο πραγματοποιείται μια εμπεριστατωμένη ανασκόπηση και αξιολόγηση των σημαντικότερων ευρημάτων και συμπερασμάτων που προέκυψαν κατά τη διάρκεια της έρευνας. Στόχος είναι να υπογραμμίσει την έκταση και την επίδραση των συνεισφορών, στους σχετικούς επιστημονικούς και ερευνητικούς τομείς, παρουσιάζοντας μια κριτική θεώρηση των κατακτήσεων και των προκλήσεων. Παράλληλα, θα προταθούν κατευθύνσεις για μελλοντική έρευνα που στοχεύουν στην περαιτέρω ανάπτυξη και περαιτέρω εξέλιξη της υπάρχουσας γνώσης.

Μεταξύ των διαφόρων θεμάτων που εξετάστηκαν στη διατριβή, οι έξυπνες πόλεις ξεχωρίζουν ως ένας από τους πιο ενεργούς και εξελισσόμενους τομείς. Εστιάζοντας στην αξιοποίηση των δεδομένων IoT και την προώθηση της Βαθιάς Μηχανικής Μάθησης.

Οι έξυπνες πόλεις αναμένεται να αναπτυχθούν γρήγορα τα επόμενα χρόνια και, ως αποτέλεσμα, η χρήση δεδομένων IoT που συλλέγονται από ασύρματα δίκτυα αισθητήρων και η ανάπτυξη και εφαρμογή σχετικών τεχνολογιών, αναμένεται να παίξουν τεράστιο ρόλο στη εξέλιξη της ζωής των αστικών πληθυσμών. Για το λόγο αυτό, η παρούσα διατριβή προσπάθησε να παρουσιάσει τις πιο πρόσφατες εξελίξεις στις μεθόδους Βαθιάς Μηχανικής Μάθησης για την πρόβλεψη πολυμεταβλητών χρονοσειρών και να εξετάσει, πώς αυτές έχουν χρησιμοποιηθεί πρόσφατα για την εκμετάλλευση τέτοιων δεδομένων IoT, για την

επιτάχυνση αυτών των προσπαθειών. Πιο συγκεκριμένα, επιλέχθηκαν έξι τομείς έξυπνων πόλεων με μεγάλη επίδραση: ποιότητα αέρα (*air quality*), πληρότητα στάθμευσης αυτοκινήτων (*car parking occupancy*), διαχείριση ζήτησης ενέργειας (*energy demand management*), ροή επιβατών (*passenger flow*), ροή κυκλοφορίας (*traffic flow*) και ποιότητα νερού (*water quality*).

Η πρόβλεψη της ποιότητας του αέρα, είναι ένα από τα πιο σοβαρά προβλήματα γύρω από τις έξυπνες πόλεις, με ένα ολοκληρωμένο σώμα πρόσφατης βιβλιογραφίας. Προηγούμενες μελέτες χρησιμοποιούσαν δίκτυα LSTM (*Long Short-Term Memory*), ενώ οι πιο δημοφιλείς μεταγενέστερες μελέτες συνδύαζαν CNN (*Convolutional Neural Networks*) με LSTM ή GRU (*Gated Recurrent Unit*) ή τις αμφίδρομες παραλλαγές τους για να βελτιώσουν την ποιότητα πρόβλεψης. Επιπλέον, ορισμένες μελέτες ενσωματώνουν τον Μηχανισμό Προσοχής (*attention mechanism*), αλλά αυτή η τάση δεν φαίνεται τόσο ισχυρή όσο σε άλλους τομείς, όπως η πρόβλεψη της κίνησης. Από την άλλη πλευρά, το ερευνητικό ενδιαφέρον για την πρόβλεψη της ποιότητας του νερού με χρήση Βαθιάς Μηχανικής Μάθησης δεν φαίνεται τόσο ισχυρό, καθώς ο αριθμός των πρόσφατων μελετών γύρω από αυτό είναι συνολικά λιγότερος. Παρόμοια με την πρόβλεψη της ποιότητας του αέρα, οι προηγούμενες εργασίες σχετικά με την πρόβλεψη της ποιότητας του νερού αποτελούνταν από αρχιτεκτονικές που ήταν κυρίως ενός μοντέλου. Ενώ σε πιο πρόσφατες μελέτες, οι αρχιτεκτονικές επεκτάθηκαν για να συμπεριλάβουν επίσης CNN και ακόμη και επίπεδα Προσοχής.

Έχει δοθεί μεγάλη προσοχή στην πρόβλεψη της ενεργειακής ζήτησης, πιθανότατα στα τεράστια οφέλη που ενδέχεται να αποφέρει η καλύτερη διαχείριση ενέργειας σε πολλούς τομείς ταυτόχρονα (κοινωνία, οικονομία, περιβάλλον και άλλα). Οι αρχιτεκτονικές που συνδυάζουν CNN (*Convolutional Neural Networks*) με GRU (*Gated Recurrent Unit*) ή LSTM (*Long Short-Term Memory*) ή τις αμφίδρομες παραλλαγές τους, μερικές φορές ενισχυμένες με επίπεδα Προσοχής, φαίνεται ότι κυριαρχούν στον εν λόγω τομέα.

Αν και η πληρότητα του χώρου στάθμευσης αυτοκινήτων, η πρόβλεψη ροής επιβατών και η πρόβλεψη ροής κυκλοφορίας, αντιμετωπίζονται χωριστά από τους ερευνητές, ο τελικός στόχος είναι ο ίδιος: αποτελεσματικές μεταφορές. Στο μέλλον, τέτοια συστήματα θα πρέπει να ενσωματώσουν, τη διαθέσιμη γνώση από όλα τα διαφορετικά συστήματα μεταφορών τα οποία εξαρτώνται σε μεγάλο βαθμό το ένα από το άλλο. Δεδομένου ότι και τα τρία προβλήματα αφορούν τα δίκτυα μεταφορών, μοιράζονται κοινά υποκείμενα χαρακτηριστικά. Αυτό γίνεται πιο εμφανές καθώς ο ίδιος τύπος αρχιτεκτονικών (*αρχιτεκτονικές που βασίζονται σε GNN, Graph Neural Networks*) κυριαρχεί στα ανωτέρω πεδία. Τέτοιες αρχιτεκτονικές έχουν την δυνατότητα να χειριστούν την γραφική φύση των δεδομένων και να αναγνωρίσουν τις εξαρτήσεις μεταξύ των διαφορετικών κόμβων μεταφοράς. Ως αποτέλεσμα, τα GNN έχουν καθιερωθεί ως το επιστημονικό στάνταρ για πολλά προβλήματα πρόβλεψης που σχετίζονται με τις μεταφορές.

Σε κάθε τομέα όπου μελετήθηκε, η πλειονότητα των ερευνών έχει χρησιμοποιήσει πραγματικά δεδομένα ανοιχτού κώδικα, τα οποία ενισχύουν τόσο την αξιοπιστία όσο και την αναπαραγωγικότητά τους. Υπάρχει επίσης ένας καλός αριθμός μελετών σε κάθε τομέα που συγκρίνονται τόσο με μοντέλα Βαθιάς Μηχανικής Μάθησης, όσο και με μοντέλα Ρηχής Μηχανικής Μάθησης, δίνοντας έμφαση και παγιώνοντας την ανωτερότητα των αρχιτεκτονικών Βαθιάς Μηχανικής Μάθησης σε προβλήματα χρονοσειρών πολυμεταβλητών έξυπνων πόλεων. Αν και τα συστήματα Βαθιάς Μηχανικής Μάθησης ενδεχομένως να είναι βαριά σε πόρους ώστε να λειτουργήσουν στις συσκευές, έχει δοθεί λίγη προσοχή στην υποδομή και τις γενικές υπολογιστικές απαιτήσεις που απαιτούνται για τη λειτουργία των ανεπτυγμένων μοντέλων, τα οποία μπορεί να αποδειχθούν προβληματικά εάν εφαρμοστούν στον πραγματικό κόσμο.

Οι μελλοντικές εργασίες μπορούν να επικεντρωθούν στην ενσωμάτωση πιο πρόσφατων τεχνικών, οι οποίες θα έχουν τη δυνατότητα να βελτιώνουν την απόδοση στους αλγορίθμους Βαθιάς Μηχανικής Μάθησης και να περιλαμβάν-

νουν περαιτέρω πληροφορίες από άλλους τομείς. Οι καινοτομίες της Βαθιάς Μηχανικής Μάθησης, περιλαμβάνουν την Μετα-Μάθηση (Meta-Learning), η οποία επιτρέπει στα μοντέλα να προσαρμοστούν γρήγορα σε νέα σενάρια, με περιορισμένα δεδομένα ή ακόμη και σε σενάρια που δεν εμφανίστηκαν κατά τη διάρκεια της εκπαίδευσης, καθώς και την εφαρμογή Βαθιάς Ενισχυτικής Μάθησης και της Αυτο-εποπτευόμενης Μάθησης. Επιπλέον καινοτόμες προσεγγίσεις μπορούν να περιλαμβάνουν όχι μόνο την ενσωμάτωση δεδομένων από διάφορες πηγές δεδομένων αστικών περιοχών, αλλά και την ενσωμάτωση της ανθρώπινης τεχνογνωσίας στα μοντέλα (human-in-the-loop συστήματα), τα οποία έχουν την δυνατότητα να ενισχύσουν περαιτέρω την αποτελεσματικότητα.

Παρά την εμφανή επικέντρωση στη βελτίωση της απόδοσης των μοντέλων, υπάρχουν πολλές άλλες σημαντικές πτυχές που απαιτούν προσοχή. Η μεγάλη πλειοψηφία των μελετών τείνει να υπερτονίζει την απόδοση, παραβλέποντας πολλούς πραγματικούς περιορισμούς που συνδέονται με την πρακτική εφαρμογή των προτεινόμενων μοντέλων. Αυτό αφήνει αρκετό πεδίο για βελτιώσεις σε μελλοντικές έρευνες, ιδιαίτερα σε θέματα που δεν αφορούν αποκλειστικά την απόδοση. Ανάμεσα σε αυτά, περιλαμβάνονται η ενίσχυση της ερμηνευσιμότητας και της δυνατότητας μεταφοράς των μοντέλων, οι υπολογιστικές απαιτήσεις, η συνεχής παρακολούθηση των μοντέλων μετά την ανάπτυξη και τα ζητήματα που αφορούν το απόρρητο των δεδομένων.

Στη διατριβή, άλλη μια σημαντική πτυχή που αναλύθηκε ήταν η πανδημία του COVID-19. Η ανάλυση της πανδημίας COVID-19 απαιτεί μια σύνθετη κατανόηση πολλαπλών δεδομένων και παραμέτρων, προκειμένου να διαμορφωθούν αποτελεσματικές στρατηγικές αντιμετώπισης. Η εκτίμηση του ποσοστού του πληθυσμού, που έχει μολυνθεί από τον COVID-19 σε κάθε χώρα και η πρόβλεψη της στιγμής κορύφωσης της επιδημίας, αποτελούν κρίσιμα εργαλεία για τη μείωση των επιπτώσεων της πανδημίας. Αυτή η γνώση επιτρέπει στις κυβερνήσεις, να προσαρμόσουν τις πολιτικές τους σχετικά με την κοινωνική απόσταση

και τα μέτρα υγείας αναλόγως.

Στην παρούσα διατριβή, αναπτύχθηκαν και εφαρμόστηκαν έξι διαφορετικές μέθοδοι πρόβλεψης χρονοσειρών, τόσο Στατιστικές όσο και βασισμένες στη Μηχανική Μάθηση, για την εκτίμηση του ποσοστού ενεργών κρουσμάτων COVID-19 επί του συνολικού πληθυσμού, με σκοπό την πρόβλεψη επτά ημερών εκ των προτέρων, για τις δέκα χώρες με τον μεγαλύτερο αριθμό επιβεβαιωμένων κρουσμάτων μέχρι τις 4 Μαΐου 2020.

Η εν λόγω μελέτη μελέτη χρησιμοποίησε την ρίζα μέσου τετραγωνικού σφάλματος (RMSE), για την αξιολόγηση της απόδοσης των διαφόρων μοντέλων χρονοσειρών, συγκρίνοντας πολλαπλές προσεγγίσεις στην πρόβλεψη των ενεργών κρουσμάτων COVID-19. Από τη σύγκριση προέκυψε ότι δεν υπάρχει μοναδική προσέγγιση ιδανική για όλες τις περιπτώσεις. Ωστόσο, οι Παραδοσιακές Στατιστικές μέθοδοι, όπως ο ARIMA και ο TBAT, αποδείχθηκαν συνολικά ανώτερες σε σύγκριση με τις σύγχρονες τεχνικές Βαθιάς Μηχανικής Μάθησης όπως ο DeepAR και ο N-BEATS. Το αποτέλεσμα αυτό δεν αποτελεί έκπληξη, δεδομένης της ανάγκης για μεγάλο όγκο δεδομένων που είναι απαραίτητος για την επιτυχή εφαρμογή των μεθόδων Βαθιάς Μηχανικής Μάθησης. Συγκεκριμένα, ο ARIMA και ο TBAT απέδειξαν την καλύτερη προγνωστική ισχύ στην πλειονότητα των περιπτώσεων, καταλαμβάνοντας την πρώτη ή δεύτερη θέση σε πολλές από αυτές. Η Στατιστική ανάλυση μέσω του τεστ Friedman χρησιμοποιήθηκε για την κατάταξη των αλγορίθμων, ενώ η εφαρμογή της post-hoc ανάλυσης του Holm επιβεβαίωσε ότι το TBAT υπερτερεί σημαντικά έναντι των Prophet, DeepAR (Gluonts) και N-BEATS, με βάση ένα επίπεδο σημαντικότητας $\alpha = 0,02$.

Η απόδοση των διάφορων μοντέλων χρονοσειρών στις επιμέρους χώρες παρουσιάζει σημαντικές διακυμάνσεις, οι οποίες δεν είναι πάντα εύκολο να εξηγηθούν ή να ερμηνευτούν λόγω της πληθώρας επιδραστικών παραγόντων. Μεταξύ αυτών, οι διαφορές σε κλιματικά και γεωγραφικά χαρακτηριστικά, η πυκνότητα του πληθυσμού και άλλα δημογραφικά στοιχεία, οι διαδικασίες δοκι-

μών, οι μετρήσεις του COVID-19, καθώς και οι διάφορες προσεγγίσεις στην εφαρμογή μέτρων κοινωνικής αποστασιοποίησης, είναι κάποιοι από τους παράγοντες που επηρεάζουν την απόδοση των προβλεπτικών μοντέλων. Οι διαφορές αυτές αντικατοπτρίζουν την πολυπλοκότητα της επιδημιολογικής κατάστασης σε κάθε χώρα, καθιστώντας την πρόβλεψη και την ανάλυση των χρονοσειρών μια προκλητική διαδικασία.

Τέλος, για να ενισχυθεί περαιτέρω η προγνωστική ακρίβεια των μοντέλων, η μελέτη προτείνει, ως μελλοντική επέκταση, την ανάπτυξη Συνδυαστικών μοντέλων όπου ενσωματώνουν τα δυνατά σημεία πολλαπλών προσεγγίσεων για τη μείωση του συνολικού σφάλματος. Επιπλέον, προτείνεται η υιοθέτηση πολυμεταβλητής μοντελοποίησης χρονοσειρών η οποία λαμβάνει υπ' όψη παράγοντες άμεσα ή έμμεσα που σχετίζονται με την εξάπλωση της πανδημίας. Τα δεδομένα έχουν την δυνατότητα να περιλαμβάνουν στατικά χαρακτηριστικά όπως η πυκνότητα πληθυσμού, γεωγραφικά χαρακτηριστικά, καθώς και δυναμικά χαρακτηριστικά όπως οι αλλαγές στη θερμοκρασία ή την υγρασία κατά τη διάρκεια της πανδημίας. Επιπρόσθετα, η ποιότητα του αέρα και άλλες μετρήσεις δύναται να εξεταστούν για την κατανόηση της επίδρασής τους στην εξάπλωση του ιού. Η μεταφορά μάθησης, που επιτρέπει την εφαρμογή γνώσης από την έρευνα σε μία χώρα στην επόμενη, προτείνεται ως μία ακόμη στρατηγική για τη βελτίωση των προγνωστικών μοντέλων, ενισχύοντας την ικανότητά τους να προβλέπουν την εξάπλωση του COVID-19 με μεγαλύτερη ακρίβεια.

Στην παρούσα διατριβή, εξετάστηκε επίσης η σημασία του Bitcoin στο σύγχρονο οικονομικό τοπίο. Από την πρώτη του εμφάνιση το 2009, το Bitcoin έχει γίνει ένας καθοριστικός παράγοντας στην αγορά κρυπτονομισμάτων, επηρεάζοντας τις οικονομικές αντιλήψεις και πρακτικές σε παγκόσμιο επίπεδο. Το Bitcoin υιοθετήθηκε αρχικά ως μέσο εναλλακτικής διακίνησης πληροφοριών και αξιών, υποστηρίζοντας την ιδέα μιας αποκεντρωμένης και ανώνυμης οικονομίας. Η αξιολόγηση της επίδρασής του στις αγορές, καθώς και η πολυπλοκότητα των

τεχνολογιών που το υποστηρίζουν, αποτελεί κρίσιμο στοιχείο για την κατανόηση του μέλλοντος των ψηφιακών νομισμάτων.

Στα πλαίσια της διατριβής, υλοποιήθηκε ένα μοντέλο Μηχανικής Μάθησης, όπου για την εκπαίδευσή του χρησιμοποιήθηκαν προηγούμενες τιμές του Bitcoin, δεδομένα τάσεων του Google και δεδομένα που δημιουργήθηκαν μέσω της εξόρυξης κειμένου σε tweets σχετικά με το Bitcoin. Ο στόχος της μελέτης ήταν η πρόβλεψη των μελλοντικών τιμών του Bitcoin. Για το σκοπό αυτό, συγκρίθηκαν ένα Βαθύ Νευρωνικό Δίκτυο (Deep Neural Network), και πιο συγκεκριμένα ένα δίκτυο Μακροπρόθεσμης Μνήμης (LSTM), ένα μοντέλο Ενισχυμένης Κλίσης (Gradient Boosting) και ένα μοντέλο XGBoost. Σύμφωνα με τα αποτελέσματα, το Βαθύ Νευρωνικό Δίκτυο είχε την καλύτερη απόδοση, με ρίζα μέσου τετραγωνικού σφάλματος 0,999% στα δεδομένα δοκιμής.

Υπάρχουν πολλές ιδέες οι οποίες μπορούν να οδηγήσουν στην περαιτέρω εξέλιξη αυτής της έρευνας και να επιτύχουν καλύτερα αποτελέσματα. Μία από τις πρωταρχικές ιδέες, είναι η εφαρμογή της μοντελοποίησης θεμάτων [199], για τη βελτίωση της απόδοσης των υφιστάμενων μοντέλων. Μια άλλη προσέγγιση θα μπορούσε να είναι, η εστίαση στην πρόβλεψη της διακύμανσης των τιμών του Bitcoin, χρησιμοποιώντας τα χαρακτηριστικά που αναπτύχθηκαν στην παρούσα μελέτη και προσεγγίζοντας το πρόβλημα ως μια εργασία ταξινόμησης.

Ακόμη, θα ήταν εφικτή η δοκιμή διάφορων συνδυασμών των δημιουργηθέντων μοντέλων ή η εξέταση άλλων μοντέλων σε συνδυασμό με αυτά. Μια ελάχιστη τροποποίηση στα τρέχοντα μοντέλα, όπως η αλλαγή του αριθμού των ημερών που λαμβάνουν υπόψιν τους, η χρήση διαφορετικών μετρήσεων ή η προσθήκη περισσότερων δεδομένων, αποτελούν επιπρόσθετες εναλλακτικές για βελτίωση.

Τέλος, μια ιδιαίτερα ενδιαφέρουσα εφαρμογή θα ήταν η χρήση των τεχνικών που περιγράφονται σ' αυτή την μελέτη, για την πρόβλεψη των τιμών άλλων κρυπτονομισμάτων.

Στην διατριβή αυτή, περαιτέρω εμβαθύνθηκε η τεχνική της γενίκευσης της Αλληλουχίας (Cascade Generalization) με στόχο την ενίσχυση της ακρίβειας στις προβλέψεις χρονοσειρών. Αναλύθηκε πώς αυτή η μέθοδος μπορεί να βελτιώσει την πρόβλεψη μελλοντικών τιμών, χρησιμοποιώντας ιστορικά δεδομένα, προσφέροντας έτσι λύσεις στις κύριες προκλήσεις που επηρεάζουν την ακρίβεια των προβλέψεων. Η μελέτη κάλυψε δέκα διαφορετικά σύνολα δεδομένων και παρουσίασε μια ειδική προσαρμογή της γενίκευσης της Αλληλουχίας, προσφέροντας μια εκτενή σύγκριση με τον συνδυασμό δύο μοντέλων με βάση την ψηφοφορία.

Τα ευρήματα κατέδειξαν μια σημαντική τάση: Η γενίκευση Αλληλουχίας (Cascade Generalization) υπερέβαινε ή ισοδυναμούσε με την προβλεπτική δύναμη της Ψηφοφορίας, με βάση τον μέσο όρο στην πλειοψηφία των περιπτώσεων. Αυτό ήταν εξαιρετικά φανερό σε σενάρια που εμπλέκονταν SVR σε συνδυασμό με άλλα μοντέλα, όπου η διαδικασία διαδοχικής βελτίωσης της Αλληλουχίας, εκμεταλλεύτηκε τις συγκλίνουσες δυνάμεις των μοντέλων για την ενίσχυση της συνολικής προγνωστικής ικανότητας. Τα ευρήματα αυτά ενισχύθηκαν περαιτέρω από την στατιστική επιβεβαίωση, μέσω του τεστ Friedman, το οποίο αν και δεν έδειξε πάντα στατιστικά σημαντικές διαφορές, κατέδειξε μια σταθερή προτίμηση προς τη μέθοδο Αλληλουχίας, σε πολλές από τις διενεργηθείσες συγκρίσεις. Αυτό δείχνει ότι, παρά την έλλειψη γενικά σημαντικών βελτιώσεων, η προτίμηση προς την υπεροχή της Γενίκευσης Αλληλουχίας (Cascade Generalization) ήταν εμφανής. Η έρευνά έδειξε ότι η Γενίκευση Αλληλουχίας προσφέρει μια ισχυρή εναλλακτική σε Παραδοσιακές μεθόδους Συνδυασμού μοντέλων, με την ικανότητά της να βελτιώνει τις προβλέψεις και να προσαρμόζεται στην πολυπλοκότητα διάφορων συνόλων δεδομένων, κάτι που την καθιστά πολύτιμο εργαλείο για την ενίσχυση της προβλεπτικής ακρίβειας. Ωστόσο είναι σημαντικό να υπογραμμιστεί ότι η επιλογή μεταξύ της Αλληλουχίας και της Ψηφοφορίας, θα πρέπει να εξαρτάται από τα ειδικά χαρακτηριστικά και τις απαιτήσεις της εκάστοτε εργασίας πρόβλεψης. Οι διαφορές απόδοσης σε διαφορετικά σύνολα δεδομένων

στην έρευνα, υποδεικνύουν ότι δεν υπάρχει μοναδική λύση η οποία να είναι κατάλληλη για όλες τις περιπτώσεις στις μεθοδολογίες πρόβλεψης.

Καταλήγοντας, η παρούσα διατριβή έδειξε τις δυνατότητες της Αλληλουχίας στην πρόβλεψη χρονοσειρών, ανοίγοντας παράλληλα δρόμους για μελλοντική εξερεύνηση. Μελλοντικές έρευνες θα μπορούσαν να επικεντρωθούν στην ενσωμάτωση πιο πολύπλοκων μοντέλων στην προσέγγιση της Αλληλουχίας, την εφαρμογή της μεθοδολογίας σ' ένα ακόμα ευρύτερο φάσμα χρονοσειρών και την εξερεύνηση δυναμικών συστημάτων πρόβλεψης σε πραγματικό χρόνο, όπου η Αλληλουχία θα μπορούσε να προσαρμόζεται συνεχώς στις εισερχόμενες ροές δεδομένων.

Ως τελευταίο θέμα προς ανάλυση στη διατριβή, η έρευνα εστίασε στην ακριβή πρόβλεψη των επιπέδων διοξειδίου του άνθρακα (CO_2), που μπορεί να παίξει σημαντικό ρόλο στη λήψη αποφάσεων με βάση τα δεδομένα, όσον αφορά τον χειρισμό των εκπομπών άνθρακα και τελικά να συμβάλλει στην αυτοματοποίηση των διαδικασιών στο μέλλον, καθώς τα έργα έξυπνων πόλεων αναπτύσσονται παγκοσμίως. Στην παρούσα διατριβή, προτείνεται ένα Υβριδικό σύστημα για την πρόβλεψη της συγκέντρωσης CO_2 , χρησιμοποιώντας ένα σύνολο δεδομένων πολυμεταβλητών χρονοσειρών από μετρήσεις αισθητήρων IoT. Στην προσπάθεια αξιολόγησης των διαφορετικών μεθόδων πρόβλεψης, πραγματοποιήθηκε σύγκριση μεταξύ Παραδοσιακών μοντέλων χρονοσειρών και Μοντέλων Βαθιάς Μηχανικής Μάθησης, με έμφαση σε προηγμένες αρχιτεκτονικές όπως τα δίκτυα Μετασχηματιστών που βασίζονται στην Προσοχή. Αυτή η αξιολόγηση διεξήχθη μέσω μιας σειράς πειραμάτων, τα οποία κάλυπταν τρεις διαφορετικούς ορίζοντες πρόβλεψης: Βραχυπρόθεσμο, Μεσοπρόθεσμο και Μακροπρόθεσμο.

Η αξιολόγηση της απόδοσης, διεξήχθη μέσω της μέτρησης και της αναφοράς των τιμών τριών κριτηρίων: του Μέσου Απόλυτου Σφάλματος (MAE), της Ρίζας Μέσου Τετραγωνικού Σφάλματος (RMSE), και του Ποσοστιαίου Απόλυτου Σφάλματος (MAPE). Παρ' ότι δεν υπάρχει μία προσέγγιση που να αποδεικνύεται

ιδανική για κάθε περίπτωση, τα ευρήματα Βαθιάς Μηχανικής Μάθησης, καταφέρνουν να εκμεταλλευτούν πιο αποτελεσματικά τις πολύπλοκες σχέσεις σε πολυδιάστατα δεδομένα, ξεπερνώντας έτσι τις Παραδοσιακές τεχνικές ανάλυσης χρονοσειρών. Η χρήση της δοκιμής Friedman για την κατάταξη των αλγορίθμων, επιβεβαίωσε την υπεροχή της Υβριδικής προσέγγισης σε σύγκριση με άλλες μεθοδολογίες, όταν αυτή αξιολογήθηκε σε διάφορες ρυθμίσεις. Επιπλέον, παρείχθησαν πληροφορίες σχετικά με τις λειτουργίες του πιο σύνθετου στοιχείου του Υβριδικού συστήματος, του Temporal Fusion Transformer, αναδεικνύοντας την σημασία των χαρακτηριστικών του και τις δυνατότητές του στην ανάλυση και ερμηνεία των δεδομένων.

Για την αναβάθμιση του προτεινόμενου συστήματος πρόβλεψης, μια σειρά από τεχνικές βελτίωσης μπορεί να συμβάλει στην αύξηση της ακρίβειας και της εγκυρότητάς του. Κρίσιμης σημασίας θεωρείται η ενίσχυση της ποιότητας των δεδομένων πριν από την επεξεργασία τους μέσω των μοντέλων. Συμπεριλαμβάνεται η βελτίωση της διαχείρισης των ελλείψεων στα δεδομένα, η πιο προχωρημένη ανίχνευση και επεξεργασία των ακραίων τιμών, καθώς και η ενίσχυση της δημιουργίας χαρακτηριστικών μέσω καινοτόμων τεχνικών. Από τη βελτίωση της ποιότητας των δεδομένων εισόδου εξασφαλίζεται μεγαλύτερη ακρίβεια και αυξημένη αξιοπιστία στη λειτουργία του συστήματος.

Επιπρόσθετα, ένας ακόμη κρίσιμος παράγοντας, για την επιτυχία συστημάτων τα οποία επιδιώκουν την εφαρμογή τους σε πραγματικές συνθήκες, όπως ένα έξυπνο σύστημα διαχείρισης πόλης, είναι η συνεχής παρακολούθηση και ενημέρωση των δεδομένων. Η διαδικασία αυτή εξασφαλίζει ότι, οι προβλέψεις παραμένουν ενημερωμένες και συμμορφώνονται με τα πρότυπα ποιότητας που έχουν καθοριστεί. Μέσω της διαρκούς επικαιροποίησης των δεδομένων και της υιοθέτησης προηγμένων μεθόδων για τη βελτίωση των εισόδων, το σύστημα μπορεί να παράγει ακριβέστερες και αξιόπιστες προβλέψεις. Αυτό είναι ιδιαίτερα σημαντικό σε δυναμικά περιβάλλοντα, όπου οι συνθήκες μπορεί να αλλάζουν γρή-

γορα, και η δυνατότητα προσαρμογής του συστήματος στις νέες παραμέτρους είναι κρίσιμη για την αποτελεσματικότητά του.

Η παρούσα διδακτορική διατριβή εξέτασε πέντε κρίσιμες επιστημονικές πτυχές, προσφέροντας σημαντικές συνεισφορές στον τομέα της επεξεργασίας και ανάλυσης δεδομένων χρονοσειρών. Η έρευνα αυτή κατάφερε να εντάξει επιτυχώς υπάρχουσες μεθόδους Μηχανικής Μάθησης σε νέα δεδομένα που κάλυπταν διάφορους τομείς, όπως η υγεία και το περιβάλλον, προσαρμόζοντας αυτές τις τεχνικές στις ιδιαιτερότητες των καινοτόμων αυτών δεδομένων. Παράλληλα, αναπτύχθηκαν καινοτόμοι αλγόριθμοι ικανοί να αναλύουν και να εξάγουν σημαντικές πληροφορίες με μεγαλύτερη ακρίβεια, αυξάνοντας έτσι την αποτελεσματικότητα των προβλέψεων και επεκτείνοντας την εφαρμογή της Μηχανικής Μάθησης σε διαφορετικά ερευνητικά πεδία, εκπληρώνοντας έτσι τους δύο βασικούς στόχους της.

Οι επιτεύξεις αυτής της διατριβής αποδεικνύουν την ικανότητα της Μηχανικής Μάθησης να αναλύει και να προβλέπει δεδομένα χρονοσειρών, ενισχύοντας την επιστημονική γνώση και την τεχνολογική πρόοδο σε διάφορους τομείς.

Βιβλιογραφία

- [1] Novel corona virus 2019 dataset. <https://www.kaggle.com/sudalairajkumar/novel-corona-virus-2019-dataset>. Accessed: 2020-05-04.
- [2] Population by country dataset - 2020. <https://www.kaggle.com/tanuprabhu/population-by-country-2020>. Accessed: 2020-05-04.
- [3] Ratnadip Adhikari and Ramesh K Agrawal. An introductory study on time series modeling and forecasting. *arXiv preprint arXiv:1302.6613*, 2013.
- [4] Elena Agliari, Adriano Barra, Orazio Antonio Barra, Alberto Fachechi, Lorenzo Franceschi Vento, and Luciano Moretti. Detecting cardiac pathologies via machine learning on heart-rate variability time series and related markers. *Scientific Reports*, 10(1):8845, 2020.
- [5] Nesreen K Ahmed, Amir F Atiya, Neamat El Gayar, and Hisham El-Shishiny. An empirical comparison of machine learning models for time series forecasting. *Econometric Reviews*, 29(5-6):594–621, 2010.
- [6] Dayo Akindipe, Opeoluwa Wonuola Olawale, and Richard Bujko. Techno-economic and social aspects of smart street lighting for small cities—a case study. *Sustainable Cities and Society*, 84:103989, 2022.
- [7] Qasem Abu Al-Haija and Mahmoud A Smadi. Parametric prediction study of global energy-related carbon dioxide emissions. In *2020 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)*, pages 1–5. IEEE, 2020.

-
- [8] Mohammed AA Al-qaness, Ahmed A Ewees, Hong Fan, and Mohamed Abd El Aziz. Optimization method for forecasting confirmed cases of covid-19 in china. *Journal of Clinical Medicine*, 9(3):674, 2020.
- [9] Teg Alam and Ali AlArjani. A comparative study of co2 emission forecasting in the gulf countries using autoregressive integrated moving average, artificial neural network, and holt-winters exponential smoothing models. *Advances in Meteorology*, 2021, 2021.
- [10] Theyazn HH Aldhyani, Mohammed Al-Yaari, Hasan Alkahtani, and Mashael Maashi. Water quality prediction using artificial intelligence algorithms. *Applied Bionics and Biomechanics*, 2020, 2020.
- [11] Alexander Alexandrov, Konstantinos Benidis, Michael Bohlke-Schneider, Valentin Flunkert, Jan Gasthaus, Tim Januschowski, Danielle C Maddix, Syama Rangapuram, David Salinas, Jasper Schulz, et al. Gluonts: Probabilistic time series models in python. *arXiv preprint arXiv:1906.05264*, 2019.
- [12] Shaheen Alhirmizy and Banaz Qader. Multivariate time series forecasting with lstm for madrid, spain pollution. In *2019 International Conference on Computing and Information Science and Technology and Their Applications (ICCISTA)*, pages 1–5. IEEE, 2019.
- [13] Ghulam Ali, Tariq Ali, Muhammad Irfan, Umar Draz, Muhammad Sohail, Adam Glowacz, Maciej Sulowicz, Ryszard Mielnik, Zaid Bin Faheem, and Claudia Martis. Iot based smart parking system using deep long short memory network. *Electronics*, 9(10):1696, 2020.
- [14] Kamal M Ali and Michael J Pazzani. Error reduction through learning multiple descriptions. *Machine learning*, 24:173–202, 1996.

- [15] M Allen, P Antwi-Agyei, F Aragon-Durand, M Babiker, P Bertoldi, M Bind, S Brown, M Buckeridge, I Camilloni, A Cartwright, et al. Technical summary: Global warming of 1.5° c. an ipcc special report on the impacts of global warming of 1.5° c above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty. 2019.
- [16] Héctor Allende and Carlos Valle. Ensemble methods for time series forecasting. *Claudio Moraga: A passion for multi-valued logic and soft computing*, pages 217–232, 2017.
- [17] S Altikat. Prediction of co2 emission from greenhouse to atmosphere with artificial neural networks and deep learning neural networks. *International Journal of Environmental Science and Technology*, 18(10):3169–3178, 2021.
- [18] Lakshay Amarpuri, Navdeep Yadav, Girish Kumar, and Saurabh Agrawal. Prediction of co 2 emissions using deep learning hybrid approach: A case study in indian context. In *2019 Twelfth International Conference on Contemporary Computing (IC3)*, pages 1–6. IEEE, 2019.
- [19] Bismark Ameyaw, Yao Li, Augustine Annan, and Joy Korang Agyeman. West africa’s co2 emissions: investigating the economic indicators, forecasting, and proposing pathways to reduce carbon emission levels. *Environmental Science and Pollution Research*, 27(12):13276–13300, 2020.
- [20] Bismark Ameyaw and Li Yao. Analyzing the impact of gdp on co2 emissions and forecasting africa’s total co2 emissions with non-assumption driven bidirectional long short-term memory. *Sustainability*, 10(9):3110, 2018.
- [21] Theodoros Anagnostopoulos, Petr Fedchenkov, Nikos Tsotsolas, Klimis Ntalianis, Arkady Zaslavsky, and Ioannis Salmon. Distributed modeling

- of smart parking system using lstm with stochastic periodic predictions. *Neural Computing and Applications*, 32(14):10783–10796, 2020.
- [22] Cleo Anastassopoulou, Lucia Russo, Athanasios Tsakris, and Constantinos Siettos. Data-based analysis, modelling and forecasting of the covid-19 outbreak. *PloS one*, 15(3):e0230405, 2020.
- [23] Mosbah Aouad, Hazem Hajj, Khaled Shaban, Rabih A Jabr, and Wassim El-Hajj. A cnn-sequence-to-sequence network with attention for residential short-term load forecasting. *Electric Power Systems Research*, 211:108152, 2022.
- [24] Francesco Paolo Appio, Marcos Lima, and Sotirios Paroutis. Understanding smart cities: Innovation ecosystems, technological advancements, and societal challenges. *Technological Forecasting and Social Change*, 142:1–14, 2019.
- [25] J Arjona, Mari Paz Linares, and Josep Casanovas. A deep learning approach to real-time parking availability prediction for smart cities. In *Proceedings of the Second International Conference on Data Science, E-Learning and Information Systems*, pages 1–7, 2019.
- [26] Kai Arulkumaran, Marc Peter Deisenroth, Miles Brundage, and Anil Anthony Bharath. Deep reinforcement learning: A brief survey. *IEEE Signal Processing Magazine*, 34(6):26–38, 2017.
- [27] Shahzad Aslam, Nasir Ayub, Umer Farooq, Muhammad Junaid Alvi, Fahad R Albogamy, Gul Rukh, Syed Irtaza Haider, Ahmad Taher Azar, and Rasool Bukhsh. Towards electric price and load forecasting using cnn-based ensembler in smart grid. *Sustainability*, 13(22):12653, 2021.

- [28] Vassilis Assimakopoulos and Konstantinos Nikolopoulos. The theta model: a decomposition approach to forecasting. *International journal of forecasting*, 16(4):521–530, 2000.
- [29] Safa Ben Atitallah, Maha Driss, Wadii Boulila, and Henda Ben Ghézala. Leveraging deep learning and iot big data analytics to support the smart cities development: Review and future directions. *Computer Science Review*, 38:100303, 2020.
- [30] Faraz Malik Awan, Roberto Minerva, and Noel Crespi. Improving road traffic forecasting using air pollution and atmospheric data: Experiments based on lstm recurrent neural networks. *Sensors*, 20(13):3749, 2020.
- [31] Temesegan Walelign Ayele and Rutvik Mehta. Air pollution monitoring and prediction using iot. In *2018 second international conference on inventive communication and computational technologies (ICICCT)*, pages 1741–1745. IEEE, 2018.
- [32] AA Aziz, B Sartono, et al. Improving prediction accuracy of classification model using cascading ensemble classifiers. In *IOP Conference Series: Earth and Environmental Science*, volume 299, page 012025. IOP Publishing, 2019.
- [33] Jimmy Lei Ba, Jamie Ryan Kiros, and Geoffrey E Hinton. Layer normalization. *arXiv preprint arXiv:1607.06450*, 2016.
- [34] Claudio Badii, Pierfrancesco Bellini, Angelo Difino, and Paolo Nesi. Smart city iot platform respecting gdpr privacy and security aspects. *IEEE Access*, 8:23601–23623, 2020.
- [35] Dzmitry Bahdanau, Kyunghyun Cho, and Yoshua Bengio. Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473*, 2014.

- [36] Shaojie Bai, J Zico Kolter, and Vladlen Koltun. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *Universal Language Model Fine-tuning for Text Classification*.
- [37] Abdullateef O Balogun, Kayode S Adewole, Amos O Bajeh, and Rasheed G Jimoh. Cascade generalization based functional tree for website phishing detection. In *Advances in Cyber Security: Third International Conference, ACeS 2021, Penang, Malaysia, August 24–25, 2021, Revised Selected Papers 3*, pages 288–306. Springer, 2021.
- [38] Ki-moon Ban. Sustainable development goals. 2016.
- [39] Piotr Baranowski, Jaromir Krzyszcak, Cezary Slawinski, Holger Hoffmann, Jerzy Kozyra, Anna Nieróbca, Krzysztof Siwek, and Andrzej Gluza. Multifractal analysis of meteorological time series to assess climate impacts. *Climate Research*, 65:39–52, 2015.
- [40] Manuele Barraco, Nicola Bicocchi, Marco Mamei, and Franco Zambonelli. Forecasting parking lots availability: Analysis from a real-world deployment. In *2021 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)*, pages 299–304. IEEE, 2021.
- [41] Rahim Barzegar, Mohammad Taghi Aalami, and Jan Adamowski. Short-term water quality variable prediction using a hybrid cnn-lstm deep learning model. *Stochastic Environmental Research and Risk Assessment*, 34(2):415–433, 2020.
- [42] Mohammad Bawaneh and Vilmos Simon. Anomaly detection in smart city traffic based on time series analysis. In *2019 International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, pages 1–6. IEEE, 2019.

- [43] Mohammad Mahdi Bejani and Mehdi Ghatee. A systematic review on overfitting control in shallow and deep neural networks. *Artificial Intelligence Review*, pages 1–48, 2021.
- [44] Abdellatif Bekkar, Badr Hssina, Samira Douzi, and Khadija Douzi. Air-pollution prediction in smart city, deep learning approach. *Journal of big Data*, 8(1):1–21, 2021.
- [45] Riccardo Bellazzi, Cristiana Larizza, Paolo Magni, Stefania Montani, and Mario Stefanelli. Intelligent analysis of clinical time series: an application in the diabetes mellitus domain. *Artificial intelligence in medicine*, 20(1):37–57, 2000.
- [46] Yoshua Bengio, Aaron Courville, and Pascal Vincent. Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8):1798–1828, 2013.
- [47] Yoshua Bengio, Patrice Simard, and Paolo Frasconi. Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks*, 5(2):157–166, 1994.
- [48] Yoshua Bengio, Patrice Simard, Paolo Frasconi, et al. Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks*, 5(2):157–166, 1994.
- [49] Samit Bhanja and Abhishek Das. Electrical power demand forecasting of smart buildings: a deep learning approach. In *Proceedings of International Conference on Computational Intelligence, Data Science and Cloud Computing: IEM-ICDC 2020*, pages 71–82. Springer, 2021.
- [50] Naman Bhoj and Robin Singh Bhadoria. Time-series based prediction for energy consumption of smart home data using hybrid convolution-recurrent neural network. *Telematics and Informatics*, 75:101907, 2022.

- [51] Stefano Bilotta and Paolo Nesi. Estimating co2 emissions from iot traffic flow sensors and reconstruction. *Sensors*, 22(9):3382, 2022.
- [52] Steven Bird, Ewan Klein, and Edward Loper. *Natural language processing with Python: analyzing text with the natural language toolkit*. « O'Reilly Media, Inc.», 2009.
- [53] Stefan Bloemheuvel, Jurgen van den Hoogen, Dario Jozinović, Alberto Michelini, and Martin Atzmueller. Graph neural networks for multivariate time series regression with application to seismic data. *International Journal of Data Science and Analytics*, pages 1–16, 2022.
- [54] Anastasia Borovykh, Sander Bohte, and Cornelis W Oosterlee. Conditional time series forecasting with convolutional neural networks. *stat*, 1050:16, 2017.
- [55] Joos-Hendrik Böse, Valentin Flunkert, Jan Gasthaus, Tim Januschowski, Dustin Lange, David Salinas, Sebastian Schelter, Matthias Seeger, and Yuyang Wang. Probabilistic demand forecasting at scale. *Proceedings of the VLDB Endowment*, 10(12):1694–1705, 2017.
- [56] George EP Box, Gwilym M Jenkins, Gregory C Reinsel, and Greta M Ljung. *Time series analysis: forecasting and control*. John Wiley & Sons, 2015.
- [57] George EP Box, Gwilym M Jenkins, Gregory C Reinsel, and Greta M Ljung. *Time series analysis: forecasting and control*. John Wiley & Sons, 2015.
- [58] Leo Breiman. Random forests. *Machine learning*, 45:5–32, 2001.
- [59] Erik Brynjolfsson, Danielle Li, and Lindsey R Raymond. Generative ai at work. Technical report, National Bureau of Economic Research, 2023.

- [60] Seok-Jun Bu and Sung-Bae Cho. Time series forecasting with multi-headed attention-based deep learning for residential energy consumption. *Energies*, 13(18):4722, 2020.
- [61] Andrés Camero, Jamal Toutouh, Daniel H Stolfi, and Enrique Alba. Evolutionary deep learning for car park occupancy prediction in smart cities. In *International conference on learning and intelligent optimization*, pages 386–401. Springer, 2018.
- [62] Hikmet Canlı and SİNAN Toklu. Design and implementation of a prediction approach using big data and deep learning techniques for parking occupancy. *Arabian Journal for Science and Engineering*, 47(2):1955–1970, 2022.
- [63] Defu Cao, Yujing Wang, Juanyong Duan, Ce Zhang, Xia Zhu, Congrui Huang, Yunhai Tong, Bixiong Xu, Jing Bai, Jie Tong, et al. Spectral temporal graph neural network for multivariate time-series forecasting. *Advances in neural information processing systems*, 33:17766–17778, 2020.
- [64] Leopoldo Catania, Stefano Grassi, and Francesco Ravazzolo. Predicting the volatility of cryptocurrency time-series. *Mathematical and Statistical Methods for Actuarial Sciences and Finance: MAF 2018*, pages 203–207, 2018.
- [65] Sudarat Chadsuthi, Charin Modchang, Yongwimon Lenbury, Sopon Iamsirithaworn, and Wannapong Triampo. Modeling seasonal leptospirosis transmission and its association with rainfall and temperature in thailand using time-series and arimax analyses. *Asian Pacific journal of tropical medicine*, 5(7):539–546, 2012.
- [66] Rohitash Chandra, Shaurya Goyal, and Rishabh Gupta. Evaluation of deep learning models for multi-step ahead time series prediction. *IEEE Access*, 9:83105–83123, 2021.

- [67] Chris Chatfield. The holt-winters forecasting procedure. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 27(3):264–279, 1978.
- [68] Chris Chatfield and Mohammad Yar. Holt-winters forecasting: some practical issues. *Journal of the Royal Statistical Society: Series D (The Statistician)*, 37(2):129–140, 1988.
- [69] Honglei Chen, Junbo Yang, Xiaohua Fu, Qingxing Zheng, Xinyu Song, Zeding Fu, Jiacheng Wang, Yingqi Liang, Hailong Yin, Zhiming Liu, et al. Water quality prediction based on lstm and attention mechanism: A case study of the burnett river, australia. *Sustainability*, 14(20):13231, 2022.
- [70] Qi Chen, Wei Wang, Fangyu Wu, Suparna De, Ruili Wang, Bailing Zhang, and Xin Huang. A survey on an emerging area: Deep learning for smart city data. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 3(5):392–410, 2019.
- [71] Tianqi Chen and Carlos Guestrin. Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pages 785–794. ACM, 2016.
- [72] Tianqi Chen, Tong He, Michael Benesty, Vadim Khotilovich, Yuan Tang, Hyunsu Cho, Kailong Chen, Rory Mitchell, Ignacio Cano, Tianyi Zhou, et al. Xgboost: extreme gradient boosting. *R package version 0.4-2*, 1(4):1–4, 2015.
- [73] Yutao Chen, Chengxu Ye, Wentao Wang, and Ping Yang. Research on air quality prediction model based on bidirectional gated recurrent unit and attention mechanism. In *2020 4th International Conference on Advances in Image Processing*, pages 172–177, 2020.
- [74] Kyunghyun Cho, Bart Van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, and Yoshua Bengio. Learning

- phrase representations using rnn encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*, 2014.
- [75] Jui-Sheng Chou and Duc-Son Tran. Forecasting energy consumption time series using machine learning techniques based on usage patterns of residential householders. *Energy*, 165:709–726, 2018.
- [76] Junyoung Chung, Caglar Gulcehre, Kyunghyun Cho, and Yoshua Bengio. Empirical evaluation of gated recurrent neural networks on sequence modeling. In *NIPS 2014 Workshop on Deep Learning, December 2014*, 2014.
- [77] Giuseppe Ciaburro. Time series data analysis using deep learning methods for smart cities monitoring. In *Big Data Intelligence for Smart Applications*, pages 93–116. Springer, 2022.
- [78] Djork-Arné Clevert, Thomas Unterthiner, and Sepp Hochreiter. Fast and accurate deep network learning by exponential linear units (elus). In Yoshua Bengio and Yann LeCun, editors, *4th International Conference on Learning Representations, ICLR 2016, San Juan, Puerto Rico, May 2-4, 2016, Conference Track Proceedings*, 2016.
- [79] David Camilo Corrales, Apolinar Figueroa, Agapito Ledezma, and Juan Carlos Corrales. An empirical multi-classifier for coffee rust detection in colombian crops. In *Computational Science and Its Applications–ICCSA 2015: 15th International Conference, Banff, AB, Canada, June 22-25, 2015, Proceedings, Part I 15*, pages 60–74. Springer, 2015.
- [80] Simon Corston-Oliver, Michael Gamon, and Chris Brickett. A machine learning approach to the automatic evaluation of machine translation. In *Proceedings of the 39th Annual Meeting of the Association for Computational Linguistics*, pages 148–155, 2001.

- [81] JHU CSSE. Coronavirus covid-19 global cases by the center for systems science and engineering (csse) at johns hopkins university (jhu), 2020.
- [82] Yanling Cui, Beihong Jin, Fusang Zhang, and Xingwu Sun. A deep spatio-temporal attention-based neural network for passenger flow prediction. In *Proceedings of the 16th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, pages 20–30, 2019.
- [83] Zihang Dai, Zhilin Yang, Yiming Yang, Jaime Carbonell, Quoc V Le, and Ruslan Salakhutdinov. Transformer-xl: Attentive language models beyond a fixed-length context. *arXiv preprint arXiv:1901.02860*, 2019.
- [84] Yann N Dauphin, Angela Fan, Michael Auli, and David Grangier. Language modeling with gated convolutional networks. In *International conference on machine learning*, pages 933–941. PMLR, 2017.
- [85] Jan G De Gooijer and Rob J Hyndman. 25 years of time series forecasting. *International journal of forecasting*, 22(3):443–473, 2006.
- [86] Alysha M De Livera, Rob J Hyndman, and Ralph D Snyder. Forecasting time series with complex seasonal patterns using exponential smoothing. *Journal of the American statistical association*, 106(496):1513–1527, 2011.
- [87] Chirag Deb, Fan Zhang, Junjing Yang, Siew Eang Lee, and Kwok Wei Shah. A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, 74:902–924, 2017.
- [88] Seun Deleawe, Jim Kusznir, Brian Lamb, and Diane J Cook. Predicting air quality in smart environments. *Journal of ambient intelligence and smart environments*, 2(2):145–154, 2010.
- [89] Alexi Delgado, Ramiro Ricardo Maque Acuña, and Chiara Carbajal. Air quality prediction (pm2. 5 and pm10) at the upper hunter town-

- muswellbrook using the long-short-term memory method. *International Journal of Advanced Computer Science and Applications*, 11(4), 2020.
- [90] Li Deng and Xiao Li. Machine learning paradigms for speech recognition: An overview. *IEEE Transactions on Audio, Speech, and Language Processing*, 21(5):1060–1089, 2013.
- [91] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*, 2018.
- [92] Thomas G Dietterich. Ensemble methods in machine learning. In *International workshop on multiple classifier systems*, pages 1–15. Springer, 2000.
- [93] Bhanuka Dissanayake, Osanda Hemachandra, Nuwan Lakshitha, Dilantha Haputhanthri, and Adeesha Wijayasiri. A comparison of arimax, var and lstm on multivariate short-term traffic volume forecasting. In *Conference of Open Innovations Association, FRUCT*, number 28, pages 564–570. FRUCT Oy, 2021.
- [94] Matthew F Dixon, Igor Halperin, and Paul Bilokon. *Machine learning in finance*, volume 1170. Springer, 2020.
- [95] Angela Dominguez, Pilar Muñoz, Anna Martínez, and Angels Orcau. Monitoring mortality as an indicator of influenza in catalonia, spain. *Journal of Epidemiology & Community Health*, 50(3):293–298, 1996.
- [96] Finale Doshi-Velez and Been Kim. Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*, 2017.

- [97] Harris Drucker, Christopher J Burges, Linda Kaufman, Alex Smola, and Vladimir Vapnik. Support vector regression machines. *Advances in neural information processing systems*, 9, 1996.
- [98] Shengdong Du, Tianrui Li, and Shi-Jinn Horng. Time series forecasting using sequence-to-sequence deep learning framework. In *2018 9th international symposium on parallel architectures, algorithms and programming (PAAP)*, pages 171–176. IEEE, 2018.
- [99] Shengdong Du, Tianrui Li, Yan Yang, Xun Gong, and Shi-Jinn Horng. An lstm based encoder-decoder model for multistep traffic flow prediction. In *2019 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8. IEEE, 2019.
- [100] Shengdong Du, Tianrui Li, Yan Yang, and Shi-Jinn Horng. Deep air quality forecasting using hybrid deep learning framework. *IEEE Transactions on Knowledge and Data Engineering*, 33(6):2412–2424, 2019.
- [101] Shengdong Du, Tianrui Li, Yan Yang, and Shi-Jinn Horng. Multivariate time series forecasting via attention-based encoder–decoder framework. *Neurocomputing*, 388:269–279, 2020.
- [102] Radhika Dua Dua, Divyam Madaan Madaan, Prerana Mukherjee Mukherjee, and Brejesh Lall Lall. Real time attention based bidirectional long short-term memory networks for air pollution forecasting. In *2019 IEEE fifth international conference on Big Data computing service and applications (BigDataService)*, pages 151–158. IEEE, 2019.
- [103] Esraa Elhariri and Shereen A Taie. H-ahead multivariate microclimate forecasting system based on deep learning. In *2019 International Conference on Innovative Trends in Computer Engineering (ITCE)*, pages 168–173. IEEE, 2019.

- [104] Raquel Espinosa, José Palma, Fernando Jiménez, Joanna Kamińska, Guido Sciavicco, and Estrella Lucena-Sánchez. A time series forecasting based multi-criteria methodology for air quality prediction. *Applied Soft Computing*, 113:107850, 2021.
- [105] Aniekan E Essien, Ilias Petrounias, Pedro Sampaio, and Sandra Sampaio. Deep-presimm: integrating deep learning with microsimulation for traffic prediction. In *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*, pages 4257–4262. IEEE, 2019.
- [106] Elias Eze, Sarah Halse, and Tahmina Ajmal. Developing a novel water quality prediction model for a south african aquaculture farm. *Water*, 13(13):1782, 2021.
- [107] Seyedeh Narjes Fallah, Ravinesh Chand Deo, Mohammad Shojafar, Mauro Conti, and Shahaboddin Shamshirband. Computational intelligence approaches for energy load forecasting in smart energy management grids: state of the art, future challenges, and research directions. *Energies*, 11(3):596, 2018.
- [108] Chenyou Fan, Yuze Zhang, Yi Pan, Xiaoyue Li, Chi Zhang, Rong Yuan, Di Wu, Wensheng Wang, Jian Pei, and Heng Huang. Multi-horizon time series forecasting with temporal attention learning. In *Proceedings of the 25th ACM SIGKDD International conference on knowledge discovery & data mining*, pages 2527–2535, 2019.
- [109] Duccio Fanelli and Francesco Piazza. Analysis and forecast of covid-19 spreading in china, italy and france. *Chaos, Solitons & Fractals*, 134:109761, 2020.
- [110] Debin Fang, Xiaoling Zhang, Qian Yu, Trenton Chen Jin, and Luan Tian. A novel method for carbon dioxide emission forecasting based on improved

- gaussian processes regression. *Journal of cleaner production*, 173:143–150, 2018.
- [111] Shen Fang, Xianbing Pan, Shiming Xiang, and Chunhong Pan. Meta-msnet: Meta-learning based multi-source data fusion for traffic flow prediction. *IEEE Signal Processing Letters*, 28:6–10, 2020.
- [112] Shen Fang, Qi Zhang, Gaofeng Meng, Shiming Xiang, and Chunhong Pan. Gstnet: Global spatial-temporal network for traffic flow prediction. In *IJCAI*, pages 2286–2293, 2019.
- [113] Kevin Fauvel, Élisabeth Fromont, Véronique Masson, Philippe Faverdin, and Alexandre Termier. Xem: An explainable-by-design ensemble method for multivariate time series classification. *Data Mining and Knowledge Discovery*, 36(3):917–957, 2022.
- [114] Petr Fedchenkov, Theodoros Anagnostopoulos, Arkady Zaslavsky, Klimis Ntalianis, Inna Sosunova, and Oleg Sadov. An artificial intelligence based forecasting in smart parking with iot. In *Internet of Things, Smart Spaces, and Next Generation Networks and Systems*, pages 33–40. Springer, 2018.
- [115] Nuno Fernandes. Economic effects of coronavirus outbreak (covid-19) on the world economy. *Available at SSRN 3557504*, 2020.
- [116] Manuel Fernández-Delgado, Manisha Sanjay Sirsat, Eva Cernadas, Sadi Alawadi, Senén Barro, and Manuel Febrero-Bande. An extensive experimental survey of regression methods. *Neural Networks*, 111:11–34, 2019.
- [117] Nazanin Fouladgar and Kary Främling. A novel lstm for multivariate time series with massive missingness. *Sensors*, 20(10):2832, 2020.

- [118] Brian S Freeman, Graham Taylor, Bahram Gharabaghi, and Jesse Thé. Forecasting air quality time series using deep learning. *Journal of the Air & Waste Management Association*, 68(8):866–886, 2018.
- [119] Jerome H Friedman. Greedy function approximation: a gradient boosting machine. *Annals of statistics*, pages 1189–1232, 2001.
- [120] Jerome H Friedman. Stochastic gradient boosting. *Computational statistics & data analysis*, 38(4):367–378, 2002.
- [121] Milton Friedman. A comparison of alternative tests of significance for the problem of m rankings. *The Annals of Mathematical Statistics*, 11(1):86–92, 1940.
- [122] Yarin Gal and Zoubin Ghahramani. A theoretically grounded application of dropout in recurrent neural networks. In *Advances in neural information processing systems*, pages 1019–1027, 2016.
- [123] Antonio Galicia, R Talavera-Llames, A Troncoso, Irena Koprinska, and Francisco Martínez-Álvarez. Multi-step forecasting for big data time series based on ensemble learning. *Knowledge-Based Systems*, 163:830–841, 2019.
- [124] Joao Gama and Pavel Brazdil. Cascade generalization. *Machine learning*, 41:315–343, 2000.
- [125] Everette S Gardner Jr. Exponential smoothing: The state of the art. *Journal of forecasting*, 4(1):1–28, 1985.
- [126] Everette S Gardner Jr. Exponential smoothing: The state of the art—part ii. *International journal of forecasting*, 22(4):637–666, 2006.
- [127] Everette S Gardner Jr. Exponential smoothing: The state of the art—part ii. *International journal of forecasting*, 22(4):637–666, 2006.

- [128] Sarah Gelper, Roland Fried, and Christophe Croux. Robust forecasting with exponential and holt–winters smoothing. *Journal of forecasting*, 29(3):285–300, 2010.
- [129] Ammar Gharaibeh, Mohammad Salahuddin, Sayed Hussini, Abdallah Khreishah, Issa Khalil, Mohsen Guizani, and Ala Al-Fuqaha. Smart cities: A survey on data management, security, and enabling technologies. *IEEE Communications Surveys Tutorials*, 19(4):2456–2501, 2017.
- [130] Iffat A Gheyas and Leslie S Smith. A novel neural network ensemble architecture for time series forecasting. *Neurocomputing*, 74(18):3855–3864, 2011.
- [131] Aysenur Gilik, Arif Selcuk Ogrenci, and Atilla Ozmen. Air quality prediction using cnn+ lstm-based hybrid deep learning architecture. *Environmental science and pollution research*, 29(8):11920–11938, 2022.
- [132] Clive William John Granger and Paul Newbold. *Forecasting economic time series*. Academic press, 2014.
- [133] Alex Graves. Long short-term memory. In *Supervised sequence labelling with recurrent neural networks*, pages 37–45. Springer, 2012.
- [134] Alex Graves. Generating sequences with recurrent neural networks. *arXiv preprint arXiv:1308.0850*, 2013.
- [135] Alex Graves and Jürgen Schmidhuber. Framewise phoneme classification with bidirectional lstm and other neural network architectures. *Neural networks*, 18(5-6):602–610, 2005.
- [136] Veena Gugnani and Rajeev Kumar Singh. A deep learning model for air quality forecasting based on 1d convolution and bilstm. In *Proceedings of*

- International Conference on Communication and Computational Technologies*, pages 209–221. Springer, 2023.
- [137] Lei Guo, Linyu Wang, and Hao Chen. Electrical load forecasting based on lstm neural networks. In *2019 International Conference on Big Data, Electronics and Communication Engineering (BDECE 2019)*, pages 107–111. Atlantis Press, 2019.
- [138] Shengnan Guo, Youfang Lin, Ning Feng, Chao Song, and Huaiyu Wan. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting. In *Proceedings of the AAAI conference on artificial intelligence*, volume 33, pages 922–929, 2019.
- [139] Anurag Gupta, Gyan Pratap Singh, Bharat Gupta, and Sanchita Ghosh. Lstm based real-time smart parking system. In *2022 IEEE 7th International conference for Convergence in Technology (I2CT)*, pages 1–7. IEEE, 2022.
- [140] Hadi Habibzadeh, Cem Kaptan, Tolga Soyata, Burak Kantarci, and Azzedine Boukerche. Smart city system design: A comprehensive study of the application and data planes. *ACM Computing Surveys (CSUR)*, 52(2):1–38, 2019.
- [141] Zahra Hajirahimi and Mehdi Khashei. Hybrid structures in time series modeling and forecasting: A review. *Engineering Applications of Artificial Intelligence*, 86:83–106, 2019.
- [142] Rebeen Ali Hamad, Longzhi Yang, Wai Lok Woo, and Bo Wei. Joint learning of temporal models to handle imbalanced data for human activity recognition. *Applied Sciences*, 10(15):5293, 2020.
- [143] Yang Han, Jacqueline CK Lam, Victor OK Li, and Qi Zhang. A domain-specific bayesian deep-learning approach for air pollution forecast. *IEEE Transactions on Big Data*, 2020.

- [144] Yong Han, Cheng Wang, Yibin Ren, Shukang Wang, Huangcheng Zheng, and Ge Chen. Short-term prediction of bus passenger flow based on a hybrid optimized lstm network. *ISPRS International Journal of Geo-Information*, 8(9):366, 2019.
- [145] Yong Han, Shukang Wang, Yibin Ren, Cheng Wang, Peng Gao, and Ge Chen. Predicting station-level short-term passenger flow in a citywide metro network using spatiotemporal graph convolutional neural networks. *ISPRS International Journal of Geo-Information*, 8(6):243, 2019.
- [146] Matthieu Hanf, Antoine Adenis, Mathieu Nacher, and Bernard Carme. The role of el niño southern oscillation (enso) on variations of monthly plasmodium falciparum malaria cases at the cayenne general hospital, 1996-2009, french guiana. *Malaria journal*, 10(1):100, 2011.
- [147] Andrew C Harvey. Forecasting, structural time series models and the kalman filter. 1990.
- [148] Andrew C Harvey and Simon Peters. Estimation procedures for structural time series models. *Journal of Forecasting*, 9(2):89–108, 1990.
- [149] Andrew C Harvey, NG Shephard, et al. Estimation and testing of stochastic variance models. Technical report, Suntory and Toyota International Centres for Economics and Related ..., 1993.
- [150] Julien Herzen, Francesco Lässig, Samuele Giuliano Piazzetta, Thomas Neuer, Léo Tafti, Guillaume Raille, Tomas Van Pottelbergh, Marek Pasieka, Andrzej Skrodzki, Nicolas Huguenin, Maxime Dumonal, Jan Kościsz, Dennis Bader, Frédérick Gusset, Mounir Benheddi, Camila Williamson, Michal Kosinski, Matej Petrik, and Gaël Grosch. Darts: User-friendly modern machine learning for time series, 2021.

- [151] Pradeep Hewage, Ardhendu Behera, Marcello Trovati, Ella Pereira, Morteza Ghahremani, Francesco Palmieri, and Yonghuai Liu. Temporal convolutional neural (tcn) network for an effective weather forecasting using time-series data from the local weather station. *Soft Computing*, 24:16453–16482, 2020.
- [152] Hansika Hewamalage, Christoph Bergmeir, and Kasun Bandara. Recurrent neural networks for time series forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1):388–427, 2021.
- [153] Sepp Hochreiter. The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 6(02):107–116, 1998.
- [154] Sepp Hochreiter, Yoshua Bengio, Paolo Frasconi, Jürgen Schmidhuber, et al. Gradient flow in recurrent nets: the difficulty of learning long-term dependencies, 2001.
- [155] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9(8):1735–1780, 1997.
- [156] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9(8):1735–1780, 1997.
- [157] Sepp Hochreiter and Jürgen Schmidhuber. Lstm can solve hard long time lag problems. In *Advances in neural information processing systems*, pages 473–479, 1997.
- [158] Sture Holm. A simple sequentially rejective multiple test procedure. *Scandinavian journal of statistics*, pages 65–70, 1979.
- [159] Mark Holmstrom, Dylan Liu, and Christopher Vo. Machine learning applied to weather forecasting. *Meteorol. Appl*, 10:1–5, 2016.

- [160] Taehoon Hong, Kwangbok Jeong, and Choongwan Koo. An optimized gene expression programming model for forecasting the national co2 emissions in 2030 using the metaheuristic algorithms. *Applied energy*, 228:808–820, 2018.
- [161] Simran Kaur Hora, Rachana Poongodan, Rocío Pérez de Prado, Marcin Wozniak, and Parameshachari Bidare Divakarachari. Long short-term memory network-based metaheuristic for effective electric energy consumption prediction. *Applied Sciences*, 11(23):11263, 2021.
- [162] Seyed Mohsen Hosseini, Amirali Saifoddin, Reza Shirmohammadi, and Alireza Aslani. Forecasting of co2 emissions in iran based on time series and regression analysis. *Energy Reports*, 5:619–631, 2019.
- [163] Jun Hu and Bo Li. A deep learning framework based on spatio-temporal attention mechanism for traffic prediction. In *2020 IEEE 22nd International Conference on High Performance Computing and Communications; IEEE 18th International Conference on Smart City; IEEE 6th International Conference on Data Science and Systems (HPCC/SmartCity/DSS)*, pages 750–757. IEEE, 2020.
- [164] Zixin Hu, Qiyang Ge, Li Jin, and Momiao Xiong. Artificial intelligence forecasting of covid-19 in china. *arXiv preprint arXiv:2002.07112*, 2020.
- [165] Yujun Huang, Yunpeng Weng, Shuai Yu, and Xu Chen. Diffusion convolutional recurrent neural network with rank influence learning for traffic forecasting. In *2019 18th IEEE International Conference On Trust, Security And Privacy In Computing And Communications/13th IEEE International Conference On Big Data Science And Engineering (TrustCom/BigDataSE)*, pages 678–685. IEEE, 2019.
- [166] George Evelyn Hutchinson. *An introduction to population ecology*. Number 504: 51 HUT. 1978.

- [167] Pham Canh Huy, Nguyen Quoc Minh, Nguyen Dang Tien, and Tao Thi Quynh Anh. Short-term electricity load forecasting based on temporal fusion transformer model. *IEEE Access*, 10:106296–106304, 2022.
- [168] Rob Hyndman, Anne B Koehler, J Keith Ord, and Ralph D Snyder. *Forecasting with exponential smoothing: the state space approach*. Springer Science & Business Media, 2008.
- [169] Bibi Ibrahim and Luis Rabelo. A deep learning approach for peak load forecasting: A case study on panama. *Energies*, 14(11):3039, 2021.
- [170] Sheikh Mohammad Idrees, M Afshar Alam, and Parul Agarwal. A prediction approach for stock market volatility based on time series data. *IEEE Access*, 7:17287–17298, 2019.
- [171] Christopher JL Murray IHME COVID-19 health service utilization forecasting team. Forecasting covid-19 impact on hospital bed-days, icu-days, ventilator-days and deaths by us state in the next 4 months. *medRxiv*, 2020.
- [172] João Tovar Jalles. Structural time series models and the kalman filter: a concise review. 2009.
- [173] Huisu Jang and Jaewook Lee. An empirical study on modeling and prediction of bitcoin prices with bayesian neural networks based on blockchain information. *IEEE Access*, 6:5427–5437, 2018.
- [174] Christian Janiesch, Patrick Zschech, and Kai Heinrich. Machine learning and deep learning. *Electronic Markets*, 31(3):685–695, 2021.
- [175] Majid Emami Javanmard and SF Ghaderi. A hybrid model with applying machine learning algorithms and optimization model to forecast

- greenhouse gas emissions with energy market data. *Sustainable Cities and Society*, 82:103886, 2022.
- [176] Abdul Rehman Javed, Waqas Ahmed, Sharnil Pandya, Praveen Kumar Reddy Maddikunta, Mamoun Alazab, and Thippa Reddy Gadekallu. A survey of explainable artificial intelligence for smart cities. *Electronics*, 12(4):1020, 2023.
- [177] Xinhui Ji, Huijie Huang, Dongsheng Chen, Kangning Yin, Yi Zuo, Zhenping Chen, and Rui Bai. A hybrid residential short-term load forecasting method using attention mechanism and deep learning. *Buildings*, 13(1):72, 2022.
- [178] Ji Chu Jiang, Burak Kantarci, Sema Oktug, and Tolga Soyata. Federated learning in smart city sensing: Challenges and opportunities. *Sensors*, 20(21):6230, 2020.
- [179] Tammy Jiang, Jaimie L Gradus, and Anthony J Rosellini. Supervised machine learning: a brief primer. *Behavior therapy*, 51(5):675–687, 2020.
- [180] Weiwei Jiang and Jiayun Luo. Graph neural network for traffic forecasting: A survey. *Expert Systems with Applications*, page 117921, 2022.
- [181] Wenhua Jiang, Zhenliang Ma, and Haris N Koutsopoulos. Deep learning for short-term origin–destination passenger flow prediction under partial observability in urban railway systems. *Neural Computing and Applications*, 34(6):4813–4830, 2022.
- [182] Feng Jiao, Lei Huang, and Zetian Gao. Multi-step time series forecasting of bus passenger flow with deep learning methods. In *LISS 2020*, pages 539–553. Springer, 2021.
- [183] TU Jichang, YANG Xueqin, CHEN Chaobo, GAO Song, WANG Jingcheng, and SUN Cheng. Water quality prediction model based on gru hybrid

- network. In *2019 Chinese Automation Congress (CAC)*, pages 1893–1898. IEEE, 2019.
- [184] Bowen Jin, Yu Zhao, and Jing Ni. Sustainable transport in a smart city: Prediction of short-term parking space through improvement of lstm algorithm. *Applied Sciences*, 12(21):11046, 2022.
- [185] Ming Jin, Huan Yee Koh, Qingsong Wen, Daniele Zambon, Cesare Alippi, Geoffrey I Webb, Irwin King, and Shirui Pan. A survey on graph neural networks for time series: Forecasting, classification, imputation, and anomaly detection. *arXiv preprint arXiv:2307.03759*, 2023.
- [186] Ning Jin, Yongkang Zeng, Ke Yan, and Zhiwei Ji. Multivariate air quality forecasting with nested long short term memory neural network. *IEEE Transactions on Industrial Informatics*, 17(12):8514–8522, 2021.
- [187] Prajakta S Kalekar. Time series forecasting using holt-winters exponential smoothing. *Kanwal Rekhi School of Information Technology*, 4329008(13), 2004.
- [188] Michael J Kane, Natalie Price, Matthew Scotch, and Peter Rabinowitz. Comparison of arima and random forest time series models for prediction of avian influenza h5n1 outbreaks. *BMC bioinformatics*, 15(1):276, 2014.
- [189] Rohit Kumar Kasera and Tapodhir Acharjee. Parking slot occupancy prediction using lstm. *Innovations in Systems and Software Engineering*, pages 1–13, 2022.
- [190] Christos Katris. Prediction of unemployment rates with time series and machine learning techniques. *Computational Economics*, 55(2):673–706, 2020.

- [191] Shruti Kaushik, Abhinav Choudhury, Pankaj Kumar Sheron, Nataraj Dasgupta, Sayee Natarajan, Larry A Pickett, and Varun Dutt. Ai in healthcare: time-series forecasting using statistical, neural, and ensemble architectures. *Frontiers in big data*, 3:4, 2020.
- [192] Shruti Kaushik, Abhinav Choudhury, Pankaj Kumar Sheron, Nataraj Dasgupta, Sayee Natarajan, Larry A Pickett, and Varun Dutt. Ai in healthcare: time-series forecasting using statistical, neural, and ensemble architectures. *Frontiers in big data*, 3:4, 2020.
- [193] Kang Ke, Sun Hongbin, Zhang Chengkang, and Carl Brown. Short-term electrical load forecasting method based on stacked auto-encoding and gru neural network. *Evolutionary Intelligence*, 12:385–394, 2019.
- [194] Abdullah Ayub Khan, Asif Ali Laghari, and Shafique Ahmed Awan. Machine learning in computer vision: a review. *EAI Endorsed Transactions on Scalable Information Systems*, 8(32):e4–e4, 2021.
- [195] Sulaiman Khan, Shah Nazir, Iván García-Magariño, and Anwar Hussain. Deep learning-based urban big data fusion in smart cities: Towards traffic monitoring and flow-preserving fusion. *Computers & Electrical Engineering*, 89:106906, 2021.
- [196] Ina Khandelwal, Ratnadip Adhikari, and Ghanshyam Verma. Time series forecasting using hybrid arima and ann models based on dwt decomposition. *Procedia Computer Science*, 48:173–179, 2015.
- [197] Sakshi Khullar and Nanhey Singh. Water quality assessment of a river using deep learning bi-lstm methodology: forecasting and validation. *Environmental Science and Pollution Research*, 29(9):12875–12889, 2022.
- [198] Tae-Young Kim and Sung-Bae Cho. Predicting residential energy consumption using cnn-lstm neural networks. *Energy*, 182:72–81, 2019.

- [199] Young Bin Kim, Jurim Lee, Nuri Park, Jaegul Choo, Jong-Hyun Kim, and Chang Hun Kim. When bitcoin encounters information in an online forum: Using text mining to analyse user opinions and predict value fluctuation. *PloS one*, 12(5):e0177630, 2017.
- [200] Michael Klompas. Coronavirus disease 2019 (COVID-19): Protecting hospitals from the invisible. *Annals of Internal Medicine*, 172(9):619–620, May 2020.
- [201] Aishwarya Premal Kogekar, Rashmiranjan Nayak, and Umesh Chandra Pati. A cnn-bilstm-svr based deep hybrid model for water quality forecasting of the river ganga. In *2021 IEEE 18th India Council International Conference (INDICON)*, pages 1–6. IEEE, 2021.
- [202] Brent Komer, James Bergstra, and Chris Eliasmith. Hyperopt-sklearn: automatic hyperparameter configuration for scikit-learn. In *ICML workshop on AutoML*, pages 2825–2830. Citeseer, 2014.
- [203] Xiangyuan Kong, Jian Zhang, Xiang Wei, Weiwei Xing, and Wei Lu. Adaptive spatial-temporal graph attention networks for traffic flow forecasting. *Applied Intelligence*, 52(4):4300–4316, 2022.
- [204] Pawalai Kraipeerapun and Somkid Amornsamankul. Using cascade generalization and neural networks to select cryotherapy method for warts. In *2019 International Conference on Engineering, Science, and Industrial Applications (ICESI)*, pages 1–5. IEEE, 2019.
- [205] Ladislav Kristoufek. Bitcoin meets google trends and wikipedia: Quantifying the relationship between phenomena of the internet era. *Scientific reports*, 3:3415, 2013.

- [206] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25:1097–1105, 2012.
- [207] Mohammad Amin Kuhail, Manohar Boorlu, Neeraj Padarathi, and Collin Rottinghaus. Parking availability forecasting model. In *2019 IEEE International Smart Cities Conference (ISC2)*, pages 619–625. IEEE, 2019.
- [208] Jan Kukačka, Vladimir Golkov, and Daniel Cremers. Regularization for deep learning: A taxonomy. *arXiv preprint arXiv:1710.10686*, 2017.
- [209] B Praveen Kumar and K Hariharan. Multivariate time series traffic forecast with long short term memory based deep learning model. In *2020 International Conference on Power, Instrumentation, Control and Computing (PICC)*, pages 1–5. IEEE, 2020.
- [210] Naresh Kumar and Seba Susan. Covid-19 pandemic prediction using time series forecasting models. In *2020 11th international conference on computing, communication and networking technologies (ICCCNT)*, pages 1–7. IEEE, 2020.
- [211] Haewoon Kwak, Changhyun Lee, Hosung Park, and Sue Moon. What is twitter, a social network or a news media? In *Proceedings of the 19th international conference on World wide web*, pages 591–600. AcM, 2010.
- [212] Do-Hyung Kwon, Ju-Bong Kim, Ju-Sung Heo, Chan-Myung Kim, and Youn-Hee Han. Time series classification of cryptocurrency price trend based on a recurrent lstm neural network. *Journal of Information Processing Systems*, 15(3), 2019.
- [213] Salim Lahmiri and Stelios Bekiros. Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons & Fractals*, 118:35–40, 2019.

- [214] Connor Lamon, Eric Nielsen, and Eric Redondo. Cryptocurrency price prediction using news and social media sentiment. *SMU Data Sci. Rev*, 1(3):1–22, 2017.
- [215] Aristomenis S Lampropoulos, Dionisios N Sotiropoulos, and George A Tsihrintzis. Cascade hybrid recommendation as a combination of one-class classification and collaborative filtering. *International Journal on Artificial Intelligence Tools*, 23(04):1460009, 2014.
- [216] Pedro Lara-Benítez, Manuel Carranza-García, and José C Riquelme. An experimental review on deep learning architectures for time series forecasting. *International Journal of Neural Systems*, 31(03):2130001, 2021.
- [217] Mikel Larrea, Alain Porto, Eloy Irigoyen, Antonio Javier Barragán, and José Manuel Andújar. Extreme learning machine ensemble model for time series forecasting boosted by pso: Application to an electric consumption problem. *Neurocomputing*, 452:465–472, 2021.
- [218] Tuong Le, Minh Thanh Vo, Bay Vo, Eenjun Hwang, Seungmin Rho, and Sung Wook Baik. Improving electric energy consumption prediction using cnn and bi-lstm. *Applied Sciences*, 9(20):4237, 2019.
- [219] Aziliz Le Glaz, Yannis Haralambous, Deok-Hee Kim-Dufor, Philippe Lenca, Romain Billot, Taylor C Ryan, Jonathan Marsh, Jordan Devylder, Michel Walter, Sofian Berrouguet, et al. Machine learning and natural language processing in mental health: systematic review. *Journal of medical Internet research*, 23(5):e15708, 2021.
- [220] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. Deep learning. *nature*, 521(7553):436–444, 2015.

- [221] Kathy Lee, Ankit Agrawal, and Alok Choudhary. Forecasting influenza levels using real-time social media streams. In *2017 IEEE International Conference on Healthcare Informatics (ICHI)*, pages 409–414. IEEE, 2017.
- [222] Yong-Ju Lee and OkGee Min. Long short-term memory recurrent neural network for urban traffic prediction: a case study of seoul. In *2018 21st international conference on intelligent transportation systems (ITSC)*, pages 1279–1284. IEEE, 2018.
- [223] Tanya L Leise. Analysis of nonstationary time series for biological rhythms research. *Journal of biological rhythms*, 32(3):187–194, 2017.
- [224] Fuxian Li, Jie Feng, Huan Yan, Guangyin Jin, Fan Yang, Funing Sun, Depeng Jin, and Yong Li. Dynamic graph convolutional recurrent network for traffic prediction: Benchmark and solution. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 2021.
- [225] Jiachang Li, Jiming Li, and Haitao Zhang. Deep learning based parking prediction on cloud platform. In *2018 4th International Conference on Big Data Computing and Communications (BIGCOM)*, pages 132–137. IEEE, 2018.
- [226] Jing Li, Hao Peng, Lin Liu, Guixi Xiong, Bowen Du, Hongyuan Ma, Lihong Wang, and Md Zakirul Alam Bhuiyan. Graph cnns for urban traffic passenger flows prediction. In *2018 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCom/IOP/SCI)*, pages 29–36. IEEE, 2018.
- [227] Qiang Li, Wei Feng, and Ying-Hui Quan. Trend and forecasting of the covid-19 outbreak in china. *Journal of Infection*, 80(4):469–496, 2020.

- [228] Shiyang Li, Xiaoyong Jin, Yao Xuan, Xiyong Zhou, Wenhui Chen, Yu-Xiang Wang, and Xifeng Yan. Enhancing the locality and breaking the memory bottleneck of transformer on time series forecasting. *Advances in Neural Information Processing Systems*, 32:5243–5253, 2019.
- [229] Songzhou Li, Gang Xie, Jinchang Ren, Lei Guo, Yunyun Yang, and Xinying Xu. Urban pm_{2.5} concentration prediction via attention-based cnn-lstm. *Applied Sciences*, 10(6):1953, 2020.
- [230] Taoying Li, Miao Hua, and XU Wu. A hybrid cnn-lstm model for forecasting particulate matter (pm_{2.5}). *Ieee Access*, 8:26933–26940, 2020.
- [231] Yaguang Li, Rose Yu, Cyrus Shahabi, and Yan Liu. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting. In *International Conference on Learning Representations*, 2018.
- [232] Zhenbo Li, Fang Peng, Bingshan Niu, Guangyao Li, Jing Wu, and Zheng Miao. Water quality prediction model combining sparse auto-encoder and lstm network. *IFAC-PapersOnLine*, 51(17):831–836, 2018.
- [233] Bryan Lim, Serkan Ö Arik, Nicolas Loeff, and Tomas Pfister. Temporal fusion transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 37(4):1748–1764, 2021.
- [234] Bryan Lim, Serkan Ö Arik, Nicolas Loeff, and Tomas Pfister. Temporal fusion transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 2021.
- [235] Bryan Lim and Stefan Zohren. Time-series forecasting with deep learning: a survey. *Philosophical Transactions of the Royal Society A*, 379(2194):20200209, 2021.

- [236] Bryan Lim, Stefan Zohren, and Stephen Roberts. Recurrent neural filters: Learning independent bayesian filtering steps for time series prediction. In *2020 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8. IEEE, 2020.
- [237] Xiaoyong Lin, Xiaopeng Zhu, Mingfei Feng, Yongming Han, and Zhiqiang Geng. Economy and carbon emissions optimization of different countries or areas in the world using an improved attention mechanism based long short term memory neural network. *Science of The Total Environment*, 792:148444, 2021.
- [238] Albin Lindfors. Demand forecasting in retail: A comparison of time series analysis and machine learning models. 2021.
- [239] Zachary Chase Lipton. A critical review of recurrent neural networks for sequence learning. *ArXiv*, abs/1506.00019, 2015.
- [240] Bo Liu, Shuo Yan, Jianqiang Li, Guangzhi Qu, Yong Li, Jianlei Lang, and Rentao Gu. An attention-based air quality forecasting method. In *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*, pages 728–733. IEEE, 2018.
- [241] Lijuan Liu, Rung-Ching Chen, and Shunzhi Zhu. Impacts of weather on short-term metro passenger flow forecasting using a deep lstm neural network. *Applied Sciences*, 10(8):2962, 2020.
- [242] Lingbo Liu, Jingwen Chen, Hefeng Wu, Jiajie Zhen, Guanbin Li, and Liang Lin. Physical-virtual collaboration modeling for intra-and inter-station metro ridership prediction. *IEEE Transactions on Intelligent Transportation Systems*, 23(4):3377–3391, 2022.
- [243] Yibei Liu, Peishun Liu, Xuefang Wang, Xueqing Zhang, and Zifei Qin. A study on water quality prediction by a hybrid dual channel cnn-lstm

- model with attention mechanism. In *International Conference on Smart Transportation and City Engineering 2021*, volume 12050, pages 797–804. SPIE, 2021.
- [244] Manuel Lopez-Martin, Antonio Sanchez-Esguevillas, Luis Hernandez-Callejo, Juan Ignacio Arribas, and Belen Carro. Novel data-driven models applied to short-term electric load forecasting. *Applied Sciences*, 11(12):5708, 2021.
- [245] Hongzhou Lu, Charles W Stratton, and Yi-Wei Tang. Outbreak of pneumonia of unknown etiology in wuhan china: the mystery and the miracle. *Journal of Medical Virology*.
- [246] Huakang Lu, Dongmin Huang, Youyi Song, Dazhi Jiang, Teng Zhou, and Jing Qin. St-trafficnet: A spatial-temporal deep learning network for traffic forecasting. *Electronics*, 9(9):1474, 2020.
- [247] Lawrence A Lynn. Artificial intelligence systems for complex decision-making in acute care medicine: a review. *Patient safety in Surgery*, 13(1):1–8, 2019.
- [248] Jonathan Mackenzie, John F Roddick, and Rocco Zito. An evaluation of htm and lstm for short-term arterial traffic flow prediction. *IEEE Transactions on Intelligent Transportation Systems*, 20(5):1847–1857, 2018.
- [249] Batta Mahesh. Machine learning algorithms-a review. *International Journal of Science and Research (IJSR).[Internet]*, 9(1):381–386, 2020.
- [250] Sharmila Majumdar, Moez M Subhani, Benjamin Roullier, Ashiq Anjum, and Rongbo Zhu. Congestion prediction for smart sustainable cities using iot and machine learning approaches. *Sustainable Cities and Society*, 64:102500, 2021.

- [251] Spyros Makridakis, Evangelos Spiliotis, and Vassilios Assimakopoulos. The m4 competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1):54–74, 2020.
- [252] Spyros Makridakis, Evangelos Spiliotis, and Vassilios Assimakopoulos. M5 accuracy competition: Results, findings, and conclusions. *International Journal of Forecasting*, 38(4):1346–1364, 2022.
- [253] Dennys CA Mallqui and Ricardo AS Fernandes. Predicting the direction, maximum, minimum and closing prices of daily bitcoin exchange rate using machine learning techniques. *Applied Soft Computing*, 75:596–606, 2019.
- [254] Abbas Mardani, Dalia Streimikiene, Mehrbakhsh Nilashi, Daniel Arias Aranda, Nanthakumar Loganathan, and Ahmad Jusoh. Energy consumption, economic growth, and co2 emissions in g20 countries: application of adaptive neuro-fuzzy inference system. *Energies*, 11(10):2771, 2018.
- [255] Abbas Mardani, Yee Van Fan, Mehrbakhsh Nilashi, Robert E Hooker, Seckin Ozkul, Dalia Streimikiene, and Nanthakumar Loganathan. A two-stage methodology based on ensemble adaptive neuro-fuzzy inference system to predict carbon dioxide emissions. *Journal of cleaner production*, 231:446–461, 2019.
- [256] Francisco Martínez-Álvarez, Alicia Troncoso, Gualberto Asencio-Cortés, and José C Riquelme. A survey on data mining techniques applied to electricity-related time series forecasting. *Energies*, 8(11):13162–13193, 2015.
- [257] Ricardo P Masini, Marcelo C Medeiros, and Eduardo F Mendes. Machine learning advances for time series forecasting. *Journal of economic surveys*, 37(1):76–111, 2023.

- [258] Martina Matta, Ilaria Lunesu, and Michele Marchesi. Bitcoin spread prediction using social and web search media. In *UMAP Workshops*, 2015.
- [259] ED McKenzie. General exponential smoothing and the equivalent arma process. *Journal of Forecasting*, 3(3):333–344, 1984.
- [260] Sean McNally, Jason Roche, and Simon Caton. Predicting the price of bitcoin using machine learning. In *Parallel, Distributed and Network-based Processing (PDP), 2018 26th Euromicro International Conference on*, pages 339–343. IEEE, 2018.
- [261] Joao Mendes-Moreira, Carlos Soares, Alípio Mário Jorge, and Jorge Freire De Sousa. Ensemble approaches for regression: A survey. *Acm computing surveys (csur)*, 45(1):1–40, 2012.
- [262] Axel Gedeon Mengara Mengara, Eunyoung Park, Jinho Jang, and Younghwan Yoo. Attention-based distributed deep learning model for air quality forecasting. *Sustainability*, 14(6):3269, 2022.
- [263] Luis FS Merchante, Delia Clar, Alberto Carnicero, Francisco J Lopez-Valdes, and Jesús R Jimenez-Octavio. Real-time co2 emissions estimation in spain and application to the covid-19 pandemic. *Journal of Cleaner Production*, 296:126425, 2021.
- [264] Tim Miller. Explanation in artificial intelligence: Insights from the social sciences. *Artificial intelligence*, 267:1–38, 2019.
- [265] Neelam Mishra, Hemant Kumar Soni, Sanjiv Sharma, and AK Upadhyay. Development and analysis of artificial neural network models for rainfall prediction by using time-series data. *International Journal of Intelligent Systems and Applications*, 10(1):16, 2018.

- [266] Mehdi Mohammadi and Ala Al-Fuqaha. Enabling cognitive smart cities using big data and machine learning: Approaches and challenges. *IEEE Communications Magazine*, 56(2):94–101, 2018.
- [267] Md Ashifuddin Mondal and Zeenat Rehena. Stacked lstm for short-term traffic flow prediction using multivariate time series dataset. *Arabian Journal for Science and Engineering*, pages 1–15, 2022.
- [268] Taewon Moon, Ha Young Choi, Dae Ho Jung, Se Hong Chang, and Jung Eek Son. Prediction of co2 concentration via long short-term memory using environmental factors in greenhouses. 2020.
- [269] Shucheng Mou, Yang Ji, and Chujie Tian. Retail time series prediction based on emd and deep learning. In *2018 International Conference on Network Infrastructure and Digital Content (IC-NIDC)*, pages 425–430. IEEE, 2018.
- [270] Manfred Mudelsee. Trend analysis of climate time series: A review of methods. *Earth-science reviews*, 190:310–322, 2019.
- [271] Amina N Muhammad, Ali M Aseere, Haruna Chiroma, Habib Shah, Abdulsalam Y Gital, and Ibrahim Abaker Targio Hashem. Deep learning application in smart cities: recent development, taxonomy, challenges and research prospects. *Neural computing and applications*, 33:2973–3009, 2021.
- [272] Małgorzata Murat, Iwona Malinowska, Magdalena Gos, and Jaromir Krzyszczak. Forecasting daily meteorological time series using arima and regression models. *International agrophysics*, 32(2), 2018.
- [273] J. N. and Herman Wold. A study in analysis of stationary time series. *Journal of the Royal Statistical Society*, 102(2):295, 1939.

- [274] Attila M Nagy and Vilmos Simon. Improving traffic prediction using congestion propagation patterns in smart cities. *Advanced Engineering Informatics*, 50:101343, 2021.
- [275] Satoshi Nakamoto et al. Bitcoin: A peer-to-peer electronic cash system. 2008.
- [276] Shreeya Namboori. *Forecasting Carbon Dioxide Emissions in the United States using Machine Learning*. PhD thesis, Dublin, National College of Ireland, 2020.
- [277] Paolo Neirotti, Alberto De Marco, Anna Corinna Cagliano, Giulio Mangano, and Francesco Scorrano. Current trends in smart city initiatives: Some stylised facts. *Cities*, 38:25–36, 2014.
- [278] Qingjian Ni, Xuehan Cao, Chaoqun Tan, Wenqiang Peng, and Xuying Kang. An improved graph convolutional network with feature and temporal attention for multivariate water quality prediction. *Environmental Science and Pollution Research*, pages 1–14, 2022.
- [279] David Nigenda, Zohar Karnin, Muhammad Bilal Zafar, Raghu Ramesha, Alan Tan, Michele Donini, and Krishnaram Kenthapadi. Amazon sagemaker model monitor: A system for real-time insights into deployed machine learning models. In *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, pages 3671–3681, 2022.
- [280] Chatree Nilnumpetch, Somkid Amornsamankul, and Pawalai Kraipeerapun. Cancer prediction using cascade generalization and duo output neural network. In *RICE*, pages 65–70, 2021.
- [281] Chatree Nilnumpetch, Somkid Amornsamankul, and Pawalai Kraipeerapun. Cascade generalization and complementary neural networks for multiclass

- classification. In *2022 International Conference on Electrical, Computer and Energy Technologies (ICECET)*, pages 1–5. IEEE, 2022.
- [282] Chatree Nilnumpetch, Somkid Amornsamankul, and Pawalai Kraipeerapun. Health data classification using applied cascade generalization. In *2023 International Conference on Inventive Computation Technologies (ICICT)*, pages 503–507. IEEE, 2023.
- [283] Dongxiao Niu, Keke Wang, Jing Wu, Lijie Sun, Yi Liang, Xiaomin Xu, and Xiaolong Yang. Can china achieve its 2030 carbon emissions commitment? scenario analysis based on an improved general regression neural network. *Journal of Cleaner Production*, 243:118558, 2020.
- [284] Stavros Nousias, Erion-Vasilis Pikoulis, Christos Mavrokefalidis, and Aris Lalos. Accelerating deep neural networks for efficient scene understanding in multi-modal automotive applications. *IEEE ACCESS*, 2023.
- [285] Kuntoro Adi Nugroho, Noor Akhmad Setiawan, and Teguh Bharata Adji. Cascade generalization for breast cancer detection. In *2013 International Conference on Information Technology and Electrical Engineering (ICITEE)*, pages 57–61. IEEE, 2013.
- [286] Kuntoro Adi Nugroho, Noor Akhmad Setiawan, and Teguh Bharata Adji. Coronary heart disease diagnosis based on improved ensemble learning. *Journal of Convergence Information Technology*, 8(13):13, 2013.
- [287] Henri J Nussbaumer. The fast fourier transform. In *Fast Fourier Transform and Convolution Algorithms*, pages 80–111. Springer, 1981.
- [288] Karl J O’Dwyer and David Malone. Bitcoin mining and its energy footprint. 2014. International Conference on Information and Communities Technologies (ISSC 2014/CICT 2014), Limerick, June 26–27, 2014.

- [289] Coronaviridae Study Group of the International et al. The species severe acute respiratory syndrome-related coronavirus: classifying 2019-ncov and naming it sars-cov-2. *Nature Microbiology*, page 1, 2020.
- [290] Oludolapo Akanni Olanrewaju and Charles Mbohwa. Assessing potential reduction in greenhouse gas: An integrated approach. *Journal of Cleaner Production*, 141:891–899, 2017.
- [291] Mariana Oliveira and Luis Torgo. Ensembles for time series forecasting. In *Asian Conference on Machine Learning*, pages 360–370. PMLR, 2015.
- [292] Aaron van den Oord, Sander Dieleman, Heiga Zen, Karen Simonyan, Oriol Vinyals, Alex Graves, Nal Kalchbrenner, Andrew Senior, and Koray Kavukcuoglu. Wavenet: A generative model for raw audio. *arXiv preprint arXiv:1609.03499*, 2016.
- [293] Aaron van den Oord, Sander Dieleman, Heiga Zen, Karen Simonyan, Oriol Vinyals, Alex Graves, Nal Kalchbrenner, Andrew Senior, and Koray Kavukcuoglu. Wavenet: A generative model for raw audio. *arXiv preprint arXiv:1609.03499*, 2016.
- [294] Siim Orasmaa, Timo Petmanson, Alexander Tkachenko, Sven Laur, and Heiki-Jaan Kaalep. Estnltk-nlp toolkit for estonian. In *LREC*, 2016.
- [295] Boris N Oreshkin, Dmitri Carpov, Nicolas Chapados, and Yoshua Bengio. N-beats: Neural basis expansion analysis for interpretable time series forecasting. *arXiv preprint arXiv:1905.10437*, 2019.
- [296] Boris N Oreshkin, Dmitri Carpov, Nicolas Chapados, and Yoshua Bengio. N-beats: Neural basis expansion analysis for interpretable time series forecasting. In *International Conference on Learning Representations*, 2019.

- [297] World Health Organization et al. Laboratory testing for coronavirus disease 2019 (covid-19) in suspected human cases: interim guidance, 2 march 2020. Technical report, World Health Organization, 2020.
- [298] Unjin Pak, Chungsong Kim, Unsok Ryu, Kyongjin Sok, and Sungnam Pak. A hybrid model based on convolutional neural networks and long short-term memory for ozone concentration prediction. *Air Quality, Atmosphere & Health*, 11(8):883–895, 2018.
- [299] Theodor Panagiotakopoulos, Omiros Iatrellis, and Achilles Kameas. Emerging smart city job roles and skills for smart urban governance. In *Building on smart cities skills and competences*, pages 3–19. Springer, 2022.
- [300] Theodor Panagiotakopoulos, Yiannis Kiouvrekis, Loukas-Moysis Mitshos, and Constantine Kappas. Rf-emf exposure assessments in greek schools to support ubiquitous iot-based monitoring in smart cities. *IEEE ACCESS*, 190:7145 – 7156, 2023.
- [301] Theodor Panagiotakopoulos, Dimitrios Vlachos, Thanasis Bakalakos, Andreas Kanavos, and Achhiles Kameas. Fiware-based iot framework for smart water distribution management. In *In 2021 12th International Conference on Information, Intelligence, Systems Applications (IISA)*, pages 1–6, 2021.
- [302] Junxiong Pang, Min Xian Wang, Ian Yi Han Ang, Sharon Hui Xuan Tan, Ruth Frances Lewis, Jacinta I-Pei Chen, Ramona A Gutierrez, Sylvia Xiao Wei Gwee, Pearleen Ee Yong Chua, Qian Yang, et al. Potential rapid diagnostics, vaccine and therapeutics for 2019 novel coronavirus (2019-ncov): a systematic review. *Journal of clinical medicine*, 9(3):623, 2020.

- [303] Sibarama Panigrahi and Himansu Sekhar Behera. A hybrid ets–ann model for time series forecasting. *Engineering applications of artificial intelligence*, 66:49–59, 2017.
- [304] Konstantinos I Papageorgiou, Katarzyna Poczeta, Elpiniki Papageorgiou, Vassilis C Gerogiannis, and George Stamoulis. Exploring an ensemble of methods that combines fuzzy cognitive maps and neural networks in solving the time series prediction problem of gas consumption in greece. *Algorithms*, 12(11):235, 2019.
- [305] Irfan Ramzan Parray, Surinder Singh Khurana, Munish Kumar, and Ali A Altalbe. Time series data analysis of stock price movement using machine learning techniques. *Soft Computing*, 24:16509–16517, 2020.
- [306] Razvan Pascanu, Tomas Mikolov, and Yoshua Bengio. On the difficulty of training recurrent neural networks. In *International conference on machine learning*, pages 1310–1318. PMLR, 2013.
- [307] Nilavra Pathak, Amadou Ba, Joern Ploennigs, and Nirmalya Roy. Forecasting gas usage for big buildings using generalized additive models and deep learning. In *2018 IEEE International Conference on Smart Computing (SMARTCOMP)*, pages 203–210. IEEE, 2018.
- [308] Robert B Penfold and Fang Zhang. Use of interrupted time series analysis in evaluating health care quality improvements. *Academic pediatrics*, 13(6):S38–S44, 2013.
- [309] Hao Peng, Hongfei Wang, Bowen Du, Md Zakirul Alam Bhuiyan, Hongyuan Ma, Jianwei Liu, Lihong Wang, Zeyu Yang, Linfeng Du, Senzhang Wang, et al. Spatial temporal incidence dynamic graph neural networks for traffic flow forecasting. *Information Sciences*, 521:277–290, 2020.

- [310] Anna Petherick. Developing antibody tests for sars-cov-2. *The Lancet*, 395(10230):1101–1102, 2020.
- [311] Fotios Petropoulos and Spyros Makridakis. Forecasting the novel coronavirus covid-19. *PloS one*, 15(3):e0231236, 2020.
- [312] Pyae-Pyae Phy, Yung-Cheol Byun, and Namje Park. Short-term energy forecasting using machine-learning-based ensemble voting regression. *Symmetry*, 14(1):160, 2022.
- [313] Francesco Piccialli, Fabio Giampaolo, Edoardo Prezioso, Danilo Crisci, and Salvatore Cuomo. Predictive analytics for smart parking: A deep learning approach in forecasting of iot data. *ACM Transactions on Internet Technology (TOIT)*, 21(3):1–21, 2021.
- [314] Mariusz Podsiadlo and Henryk Rybinski. Financial time series forecasting using rough sets with time-weighted rule voting. *Expert Systems with Applications*, 66:219–233, 2016.
- [315] Andri Pranolo, Yingchi Mao, Aji Prasetya Wibawa, Agung Bella Putra Utama, and Felix Andika Dwiyanto. Robust lstm with tuned-pso and bifold-attention mechanism for analyzing multivariate time-series. *IEEE Access*, 10:78423–78434, 2022.
- [316] Wolfgang Preiser, Gert Van Zyl, and Angela Dramowski. Covid-19: Getting ahead of the epidemic curve by early implementation of social distancing. *South African Medical Journal*, 110(4):1, 2020.
- [317] Ondrej Pribyl, Miroslav Svitek, and Leon Rothkrantz. Intelligent mobility in smart cities, 2022.

- [318] Jesper C Provoost, Andreas Kamilaris, Luc JJ Wismans, Sander J Van Der Drift, and Maurice Van Keulen. Predicting parking occupancy via machine learning in the web of things. *Internet of Things*, 12:100301, 2020.
- [319] Saidur Rahman, Md Golam Rabiul Alam, and Md Mahbubur Rahman. Deep learning based ensemble method for household energy demand forecasting of smart home. In *2019 22nd International Conference on Computer and Information Technology (ICCIT)*, pages 1–6. IEEE, 2019.
- [320] Satyananda Champati Rai, Samaleswari Nayak, Biswaranjan Acharya, Vassilis Gerogiannis, Andreas Kanavos, and Theodor Panagiotakopoulos. Itss: An intelligent traffic signaling system based on an iot infrastructure. *electronics*, 12(5):1177, 2023.
- [321] Lavanya Rajamani. Ambition and differentiation in the 2015 paris agreement: Interpretative possibilities and underlying politics. *International & Comparative Law Quarterly*, 65(2):493–514, 2016.
- [322] Mauricio A Ramírez-Moreno, Sajjad Keshtkar, Diego A Padilla-Reyes, Edrick Ramos-López, Moisés García-Martínez, Mónica C Hernández-Luna, Antonio E Mogro, Jurgen Mahlknecht, José Ignacio Huertas, Rodrigo E Peimbert-García, et al. Sensors for sustainable smart cities: A review. *Applied Sciences*, 11(17):8198, 2021.
- [323] Syama Sundar Rangapuram, Matthias W Seeger, Jan Gasthaus, Lorenzo Stella, Yuyang Wang, and Tim Januschowski. Deep state space models for time series forecasting. *Advances in neural information processing systems*, 31:7785–7794, 2018.
- [324] Santosh Rani and Sandeep Kautish. Association clustering and time series based data mining in continuous data for diabetes prediction. In *2018*

- second international conference on intelligent computing and control systems (ICICCS)*, pages 1209–1214. IEEE, 2018.
- [325] Sebastian Raschka. Model evaluation, model selection, and algorithm selection in machine learning. *arXiv preprint arXiv:1811.12808*, 2018.
- [326] Yi Ren and Kunqing Xie. Transfer knowledge between sub-regions for traffic prediction using deep learning method. In *International Conference on Intelligent Data Engineering and Automated Learning*, pages 208–219. Springer, 2019.
- [327] Victor Henrique Alves Ribeiro and Gilberto Reynoso-Meza. Timestacking: An improved ensemble learning method for continuous time series classification. In *IFIP International Conference on Product Lifecycle Management*, pages 284–296. Springer, 2021.
- [328] Yuecheng Rong, Zhimian Xu, RuiBo Yan, and Xu Ma. Du-parking: Spatio-temporal big data tells you realtime parking availability. In *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pages 646–654, 2018.
- [329] K Roosa, Y Lee, R Luo, A Kirpich, R Rothenberg, JM Hyman, P Yan, and G Chowell. Real-time forecasts of the covid-19 epidemic in china from february 5th to february 24th, 2020. *Infectious Disease Modelling*, 5:256–263, 2020.
- [330] Max Roser, Hannah Ritchie, and Esteban Ortiz-Ospina. Coronavirus disease (covid-19)—statistics and research. *Our World in Data*, 2020.
- [331] Pranab K Roy Chowdhury, Jeanette E Weaver, Eric M Weber, Dalton Lunga, St Thomas M LeDoux, Amy N Rose, and Budhendra L Bhaduri. Electricity consumption patterns within cities: application of a data-driven settlement

- characterization method. *International Journal of Digital Earth*, 13(1):119–135, 2020.
- [332] Ralf R  ther, Andreas Klos, Marius Rosenbaum, and Wolfram Schiffmann. Traffic flow forecast of road networks with recurrent neural networks. In *2021 International Symposium on Computer Science and Intelligent Controls (ISCSIC)*, pages 31–38. IEEE, 2021.
- [333] Majid Safaei-Farouji, Hung Vo Thanh, Zhenxue Dai, Abolfazl Mehbodniya, Mohammad Rahimi, Umar Ashraf, and Ahmed E Radwan. Exploring the power of machine learning to predict carbon dioxide trapping efficiency in saline aquifers for carbon geological storage project. *Journal of Cleaner Production*, 372:133778, 2022.
- [334] TD Sajanraj, Jaison Mulerikkal, S Raghavendra, R Vinith, and V Fabera. Passenger flow prediction from afc data using station memorizing lstm for metro rail systems. *Neural Network World*, 31(3):173, 2021.
- [335] Muhammad Sajjad, Zulfiqar Ahmad Khan, Amin Ullah, Tanveer Hussain, Waseem Ullah, Mi Young Lee, and Sung Wook Baik. A novel cnn-gru-based hybrid approach for short-term residential load forecasting. *Ieee Access*, 8:143759–143768, 2020.
- [336] David Salinas, Valentin Flunkert, Jan Gasthaus, and Tim Januschowski. Deepar: Probabilistic forecasting with autoregressive recurrent networks. *International Journal of Forecasting*, 36(3):1181–1191, 2020.
- [337] K Samal, Korra Babu, and Santos Das. Spatio-temporal prediction of air quality using distance based interpolation and deep learning techniques. *EAI Endorsed Transactions on Smart Cities*, 5(14), 2021.
- [338] K Krishna Rani Samal, Korra Sathya Babu, Abhirup Acharya, and Santos Kumar Das. Long term forecasting of ambient air quality using deep

- learning approach. In *2020 IEEE 17th India Council International Conference (INDICON)*, pages 1–6. IEEE, 2020.
- [339] Aidos Satan, Ayagoz Khamzina, Damir Toktarbayev, Zhuldyz Sotsial, Ideyat Bapiyev, and Nurkhat Zhakiyev. Comparative lstm and svm machine learning approaches for energy consumption prediction: Case study in akmola. In *2022 International Conference on Smart Information Systems and Technologies (SIST)*, pages 1–7. IEEE, 2022.
- [340] Mike Schuster and Kuldip K Paliwal. Bidirectional recurrent neural networks. *IEEE transactions on Signal Processing*, 45(11):2673–2681, 1997.
- [341] Omer Berat Sezer, Mehmet Ugur Gudelek, and Ahmet Murat Ozbayoglu. Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*, 11:106181, 2020.
- [342] Elham Shabani, Babollah Hayati, Esmaeil Pishbahar, Mohammad Ali Ghorbani, and Mohammad Ghahremanzadeh. A novel approach to predict co2 emission in the agriculture sector of iran based on inclusive multiple model. *Journal of Cleaner Production*, 279:123708, 2021.
- [343] K Shailaja, Banoth Seetharamulu, and MA Jabbar. Machine learning in healthcare: A review. In *2018 Second international conference on electronics, communication and aerospace technology (ICECA)*, pages 910–914. IEEE, 2018.
- [344] Wei Shao, Yu Zhang, Bin Guo, Kai Qin, Jeffrey Chan, and Flora D Salim. Parking availability prediction with long short term memory model. In *International conference on green, pervasive, and cloud computing*, pages 124–137. Springer, 2018.
- [345] Dehua Shen, Andrew Urquhart, and Pengfei Wang. Does twitter predict bitcoin? *Economics Letters*, 174:118–122, 2019.

- [346] David Balderas Silva, Pedro Ponce Cruz, and Arturo Molina Molina. Are the long short term memory and convolution neural networks really based on biological systems? *ICT Express*, 2018.
- [347] Mukul Singh and Rahul Dubey. Deep learning model based co2 emissions prediction using vehicle telematics sensors data. *IEEE Transactions on Intelligent Vehicles*, 2021.
- [348] Pawan Kumar Singh, Alok Kumar Pandey, Sahil Ahuja, and Ravi Kiran. Multiple forecasting approach: a prediction of co2 emission from the paddy crop in india. *Environmental Science and Pollution Research*, pages 1–12, 2021.
- [349] Suryabhan Singh and V Ananthanarayanan. Air quality monitoring system with effective traffic control model for open smart cities of india. In *Advances in Electrical and Computer Technologies*, pages 405–419. Springer, 2021.
- [350] Slawek Smyl. A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*, 36(1):75–85, 2020.
- [351] Radina P Soebiyanto, Farida Adimi, and Richard K Kiang. Modeling and predicting seasonal influenza transmission in warm regions using climatological parameters. *PloS one*, 5(3), 2010.
- [352] Nivethitha Somu, Gauthama Raman MR, and Krithi Ramamritham. A deep learning framework for building energy consumption forecast. *Renewable and Sustainable Energy Reviews*, 137:110591, 2021.
- [353] Namrye Son. Comparison of the deep learning performance for short-term power load forecasting. *Sustainability*, 13(22):12493, 2021.

- [354] Chao Song, Youfang Lin, Shengnan Guo, and Huaiyu Wan. Spatial-temporal synchronous graph convolutional networks: A new framework for spatial-temporal network data forecasting. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 34, pages 914–921, 2020.
- [355] Xin Song, Jun Xiao, Jiang Deng, Qiong Kang, Yanyu Zhang, and Jinbo Xu. Time series analysis of influenza incidence in chinese provinces from 2004 to 2011. *Medicine*, 95(26), 2016.
- [356] Dionisios N Sotiropoulos and George A Tsihrintzis. Artificial immune system-based music recommendation. *Intelligent Decision Technologies*, 12(2):213–229, 2018.
- [357] Jovani Taveira de Souza, Antonio Carlos de Francisco, Cassiano Moro Piekarski, and Guilherme Francisco do Prado. Data mining and machine learning to promote smart cities: A systematic review from 2000 to 2018. *Sustainability*, 11(4):1077, 2019.
- [358] Evita Stenqvist and Jacob Lönnö. Predicting bitcoin price fluctuation with twitter sentiment analysis, 2017. MSc thesis, KTH ROYAL INSTITUTE OF TECHNOLOGY, SCHOOL OF COMPUTER SCIENCE AND COMMUNICATION, STOCKHOLM, SWEDEN.
- [359] Jack Stilgoe. Machine learning, social learning and the governance of self-driving cars. *Social studies of science*, 48(1):25–56, 2018.
- [360] Devika Subramanian, Venkataraman Subramanian, Anita Deswal, and Douglas L Mann. New predictive models of heart failure mortality using time-series measurements and ensemble models. *Circulation: Heart Failure*, 4(4):456–462, 2011.
- [361] Wei Sun, Caifei Wang, and Chongchong Zhang. Factor analysis and forecasting of co2 emissions in hebei, using extreme learning machine based

- on particle swarm optimization. *Journal of cleaner production*, 162:1095–1101, 2017.
- [362] Ilya Sutskever, Oriol Vinyals, and Quoc V Le. Sequence to sequence learning with neural networks. *Advances in neural information processing systems*, 27, 2014.
- [363] Pruethsan Sutthichaimethee and Danupon Ariyasajakorn. Forecast of carbon dioxide emissions from energy consumption in industry sectors in thailand. *Environmental and Climate Technologies*, 22(1):107–117, 2018.
- [364] Pejman Tahmasebi, Serveh Kamrava, Tao Bai, and Muhammad Sahimi. Machine learning in geo-and environmental sciences: From small to large scale. *Advances in Water Resources*, 142:103619, 2020.
- [365] Ke Tan, Jitong Chen, and DeLiang Wang. Gated residual networks with dilated convolutions for monaural speech enhancement. *IEEE/ACM transactions on audio, speech, and language processing*, 27(1):189–198, 2018.
- [366] Vartika Tanania, Shipra Shukla, and Shambhavi Singh. Time series data analysis and prediction of co2 emissions. In *2020 10th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, pages 665–669. IEEE, 2020.
- [367] Qing Tao, Fang Liu, Yong Li, and Denis Sidorov. Air pollution forecasting using a deep learning model based on 1d convnets and bidirectional gru. *IEEE access*, 7:76690–76698, 2019.
- [368] Sean J Taylor and Benjamin Letham. Forecasting at scale. *The American Statistician*, 72(1):37–45, 2018.
- [369] Kankamon Thaweephol and Nuwee Wiwatwattana. Long short-term memory deep neural network model for pm2. 5 forecasting in the bangkok

- urban area. In *2019 17th International Conference on ICT and Knowledge Engineering (ICT&KE)*, pages 1–6. IEEE, 2019.
- [370] Florian Toqué, Etienne Côme, Latifa Oukhellou, and Martin Trépanier. Short-term multi-step ahead forecasting of railway passenger flows during special events with machine learning methods. In *CASPT 2018, Conference on Advanced Systems in Public Transport and TransitData 2018*, page 15p, 2018.
- [371] José F Torres, Dalil Hadjout, Abderrazak Sebaa, Francisco Martínez-Álvarez, and Alicia Troncoso. Deep learning for time series forecasting: a survey. *Big Data*, 9(1):3–21, 2021.
- [372] Evelin Priscila Trindade, Marcus Phoebe Farias Hinnig, Eduardo Moreira da Costa, Jamile Sabatini Marques, Rogério Cid Bastos, and Tan Yigitcanlar. Sustainable development of smart cities: A systematic review of the literature. *Journal of Open Innovation: Technology, Market, and Complexity*, 3(3):1–14, 2017.
- [373] Meng-Ju Tsai, Hsiu-Yuan Chen, Zhiyong Cui, and Yinhai Wang. Multivariate long and short term lstm-based network for traffic forecasting under interference: Experiments during covid-19. In *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*, pages 2169–2174. IEEE, 2021.
- [374] Cristiana Tudor. Predicting the evolution of co2 emissions in bahrain with automated forecasting methods. *Sustainability*, 8(9):923, 2016.
- [375] Andrei M Tudose, Dorian O Sidea, Irina I Picioroaga, Valentin A Boicea, and Constatin Bulac. A cnn based model for short-term load forecasting: a real case study on the romanian power system. In *2020 55th International Universities Power Engineering Conference (UPEC)*, pages 1–6. IEEE, 2020.

- [376] Fath U Min Ullah, Amin Ullah, Ijaz Ul Haq, Seungmin Rho, and Sung Wook Baik. Short-term prediction of residential power energy consumption via cnn and multi-layer bi-directional lstm networks. *IEEE Access*, 8:123369–123380, 2019.
- [377] Fatih Ünal, Abdulaziz Almalaq, and Sami Ekici. A novel load forecasting approach based on smart meter data using advance preprocessing and hybrid deep learning. *Applied Sciences*, 11(6):2742, 2021.
- [378] Jan Vanus, Radek Martinek, Petr Bilik, Jan Zidek, Pavel Dohnalek, and Petr Gajdos. New method for accurate prediction of co2 in the smart home. In *2016 IEEE international instrumentation and measurement technology conference proceedings*, pages 1–5. IEEE, 2016.
- [379] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. In *Advances in neural information processing systems*, pages 5998–6008, 2017.
- [380] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. *Advances in neural information processing systems*, 30, 2017.
- [381] Petar Veličković, Guillem Cucurull, Arantxa Casanova, Adriana Romero, Pietro Liò, and Yoshua Bengio. Graph attention networks. In *International Conference on Learning Representations*.
- [382] Balachandran Vijayalakshmi, Kadarkarayandi Ramar, NZ Jhanjhi, Sahil Verma, Madasamy Kaliappan, Kandasamy Vijayalakshmi, Shanmuganathan Vimal, and Uttam Ghosh. An attention-based deep learning model for traffic flow prediction using spatiotemporal features towards sustainable smart city. *International Journal of Communication Systems*, 34(3):e4609, 2021.

- [383] Gretchen Vogel. New blood tests for antibodies could show true scale of coronavirus pandemic. *Science*, March 2020.
- [384] Gerasimos Vonitsanos, Theodor Panagiotakopoulos, Andreas Kanavos, and Achilles Tsakalidis. Forecasting air flight delays and enabling smart airport services in apache spark. In *Artificial Intelligence Applications and Innovations. AIAI 2021 IFIP WG 12.5 International Workshops*, pages 407–417, 2021.
- [385] Leye Wang, Bin Guo, and Qiang Yang. Smart city development with urban transfer learning. *Computer*, 51(12):32–41, 2018.
- [386] Qiang Wang, Shuyu Li, and Zhanna Pisarenko. Modeling carbon emission trajectory of china, us and india. *Journal of cleaner production*, 258:120723, 2020.
- [387] Yuyang Wang, Alex Smola, Danielle Maddix, Jan Gasthaus, Dean Foster, and Tim Januschowski. Deep factors for forecasting. In *International conference on machine learning*, pages 6607–6617. PMLR, 2019.
- [388] Nan Wei, Changjun Li, Xiaolong Peng, Yang Li, and Fanhua Zeng. Daily natural gas consumption forecasting via the application of a novel hybrid model. *Applied Energy*, 250:358–368, 2019.
- [389] Sun Wei, Wang Yuwei, and Zhang Chongchong. Forecasting co2 emissions in hebei, china, through moth-flame optimization based on the random forest and extreme learning machine. *Environmental Science and Pollution Research*, 25(29):28985–28997, 2018.
- [390] Wangyang Wei, Honghai Wu, and Huadong Ma. An autoencoder and lstm-based traffic flow prediction method. *Sensors*, 19(13):2946, 2019.

- [391] Xiaohui Wei, Yuanyuan Liu, Shang Gao, Xingwang Wang, and Hengshan Yue. An rnn-based delay-guaranteed monitoring framework in underwater wireless sensor networks. *IEEE access*, 7:25959–25971, 2019.
- [392] Lei Wen and Xiaoyu Yuan. Forecasting co2 emissions in chinas commercial department, through bp neural network based on random forest and pso. *Science of The Total Environment*, 718:137194, 2020.
- [393] Qingsong Wen, Tian Zhou, Chaoli Zhang, Weiqi Chen, Ziqing Ma, Junchi Yan, and Liang Sun. Transformers in time series: A survey. *arXiv preprint arXiv:2202.07125*, 2022.
- [394] Ruofeng Wen and Kari Torkkola. Deep generative quantile-copula models for probabilistic forecasting. *arXiv preprint arXiv:1907.10697*, 2019.
- [395] Ari Wibisono, Hanif Arief Wisesa, Novian Habibie, Aulia Arshad, Aditya Murdha, Wisnu Jatmiko, Ahmad Gamal, Indra Hermawan, and Siti Aminah. Dataset of short-term prediction of co2 concentration based on a wireless sensor network. *Data in Brief*, 31:105924, 2020.
- [396] David H Wolpert. Stacked generalization. *Neural networks*, 5(2):241–259, 1992.
- [397] World Health Organization and others. Naming the coronavirus disease (covid-19) and the virus that causes it. *World Health Organization*. [https://www.who.int/emergencies/diseases/novel-coronavirus-2019/technical-guidance/naming-the-coronavirus-disease-\(covid-2019\)-and-the-virus-that-causes-it](https://www.who.int/emergencies/diseases/novel-coronavirus-2019/technical-guidance/naming-the-coronavirus-disease-(covid-2019)-and-the-virus-that-causes-it), 2020. Accessed: 2020-05-02.
- [398] Binrong Wu, Lin Wang, Rui Tao, and Yu-Rong Zeng. Interpretable tourism volume forecasting with multivariate time series under the impact of covid-19. *Neural Computing and Applications*, 35(7):5437–5463, 2023.

- [399] Binrong Wu, Lin Wang, and Yu-Rong Zeng. Interpretable wind speed prediction with multivariate time series and temporal fusion transformers. *Energy*, 252:123990, 2022.
- [400] Joseph T Wu, Kathy Leung, and Gabriel M Leung. Nowcasting and forecasting the potential domestic and international spread of the 2019-ncov outbreak originating in wuhan, china: a modelling study. *The Lancet*, 395(10225):689–697, 2020.
- [401] Zonghan Wu, Shirui Pan, Fengwen Chen, Guodong Long, Chengqi Zhang, and S Yu Philip. A comprehensive survey on graph neural networks. *IEEE transactions on neural networks and learning systems*, 32(1):4–24, 2020.
- [402] Zonghan Wu, Shirui Pan, Guodong Long, Jing Jiang, Xiaojun Chang, and Chengqi Zhang. Connecting the dots: Multivariate time series forecasting with graph neural networks. In *Proceedings of the 26th ACM SIGKDD international conference on knowledge discovery & data mining*, pages 753–763, 2020.
- [403] Zonghan Wu, Shirui Pan, Guodong Long, Jing Jiang, and Chengqi Zhang. Graph wavenet for deep spatial-temporal graph modeling. In *Proceedings of the 28th International Joint Conference on Artificial Intelligence*, pages 1907–1913, 2019.
- [404] Dawen Xia, Maoting Zhang, Xiaobo Yan, Yu Bai, Yongling Zheng, Yantao Li, and Huaqing Li. A distributed wnd-lstm model on mapreduce for short-term traffic flow prediction. *Neural Computing and Applications*, 33(7):2393–2410, 2021.
- [405] Xiao Xiao, Zhiling Jin, Yilong Hui, Yueshen Xu, and Wei Shao. Hybrid spatial-temporal graph convolutional networks for on-street parking availability prediction. *Remote Sensing*, 13(16):3338, 2021.

- [406] Guangyue Xu, Peter Schwarz, and Hualiu Yang. Determining china's co2 emissions peak with a dynamic nonlinear artificial neural network approach and scenario analysis. *Energy Policy*, 128:752–762, 2019.
- [407] Wenjia Xu, Lixin Miao, and Jinjiang Xing. Short-term passenger flow forecasting of the airport based on deep learning spatial-temporal network. In *2022 The 9th International Conference on Industrial Engineering and Applications (Europe)*, pages 77–83, 2022.
- [408] Yingying Xu and Kezhong Jin. An lstm approach for predicting the short-time passenger flow of urban bus. In *2021 2nd International Conference on Artificial Intelligence in Electronics Engineering*, pages 35–40, 2021.
- [409] Bailin Yang, Shulin Sun, Jianyuan Li, Xianxuan Lin, and Yan Tian. Traffic flow prediction using lstm with feature enhancement. *Neurocomputing*, 332:320–327, 2019.
- [410] Li Yang and Abdallah Shami. On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, 415:295–316, 2020.
- [411] Shuguan Yang, Wei Ma, Xidong Pi, and Sean Qian. A deep learning approach to real-time parking occupancy prediction in transportation networks incorporating multiple spatio-temporal data sources. *Transportation Research Part C: Emerging Technologies*, 107:248–265, 2019.
- [412] Yurong Yang, Qingyu Xiong, Chao Wu, Qinghong Zou, Yang Yu, Hualing Yi, and Min Gao. A study on water quality prediction by a hybrid cnn-lstm model with attention mechanism. *Environmental Science and Pollution Research*, 28(39):55129–55139, 2021.
- [413] Zifeng Yang, Zhiqi Zeng, Ke Wang, Sook-San Wong, Wenhua Liang, Mark Zanin, Peng Liu, Xudong Cao, Zhongqiang Gao, Zhitong Mai, et al. Modified

- seir and ai prediction of the epidemics trend of covid-19 in china under public health interventions. *Journal of Thoracic Disease*, 12(3):165, 2020.
- [414] Ibrahim Yazici, Omer Faruk Beyca, and Dursun Delen. Deep-learning-based short-term electricity load forecasting: A real case application. *Engineering Applications of Artificial Intelligence*, 109:104645, 2022.
- [415] Rui Yin, Emil Luusua, Jan Dabrowski, Yu Zhang, and Chee Keong Kwoh. Tempel: time-series mutation prediction of influenza a viruses via attention-based recurrent neural networks. *Bioinformatics*, 2020.
- [416] Xueyan Yin, Genze Wu, Jinze Wei, Yanming Shen, Heng Qi, and Baocai Yin. Multi-stage attention spatial-temporal graph networks for traffic prediction. *Neurocomputing*, 428:42–53, 2021.
- [417] Bing Yu, Haoteng Yin, and Zhanxing Zhu. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting. In *Proceedings of the 27th International Joint Conference on Artificial Intelligence*, pages 3634–3640, 2018.
- [418] G Udny Yule. Why do we sometimes get nonsense-correlations between time-series?—a study in sampling and the nature of time-series. *Journal of the royal statistical society*, 89(1):1–63, 1926.
- [419] Noureen Zafar, Irfan Ul Haq, Jawad-ur-Rehman Chughtai, and Omair Shafiq. Applying hybrid lstm-gru model based on heterogeneous data sources for traffic speed prediction in urban areas. *Sensors*, 22(9):3348, 2022.
- [420] Nur’atiah Zaini, Lee Woen Ean, Ali Najah Ahmed, and Marlinda Abdul Malek. A systematic literature review of deep learning neural network for time series air quality forecasting. *Environmental Science and Pollution Research*, pages 1–33, 2021.

- [421] Wojciech Zaremba, Ilya Sutskever, and Oriol Vinyals. Recurrent neural network regularization. *arXiv preprint arXiv:1409.2329*, 2014.
- [422] Chao Zeng, Changxi Ma, Ke Wang, and Zihao Cui. Parking occupancy prediction method based on multi factors and stacked gru-lstm. *IEEE Access*, 10:47361–47370, 2022.
- [423] Cha Zhang and Yunqian Ma. *Ensemble machine learning: methods and applications*. Springer, 2012.
- [424] Da Zhang and Mansur R Kabuka. Combining weather condition data to predict traffic flow: a gru-based deep learning approach. *IET Intelligent Transport Systems*, 12(7):578–585, 2018.
- [425] G Peter Zhang. Time series forecasting using a hybrid arima and neural network model. *Neurocomputing*, 50:159–175, 2003.
- [426] G Peter Zhang. Time series forecasting using a hybrid arima and neural network model. *Neurocomputing*, 50:159–175, 2003.
- [427] Guoqiang Peter Zhang. Neural networks for classification: a survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 30(4):451–462, 2000.
- [428] Jinlei Zhang, Feng Chen, Yinan Guo, and Xiaohong Li. Multi-graph convolutional network for short-term passenger flow forecasting in urban rail transit. *IET Intelligent Transport Systems*, 14(10):1210–1217, 2020.
- [429] Qiang Zhang, Ruiqi Wang, Ying Qi, and Fei Wen. A watershed water quality prediction model based on attention mechanism and bi-lstm. *Environmental Science and Pollution Research*, 29(50):75664–75680, 2022.

- [430] Quan-shi Zhang and Song-Chun Zhu. Visual interpretability for deep learning: a survey. *Frontiers of Information Technology & Electronic Engineering*, 19(1):27–39, 2018.
- [431] Sheng Zhang, MengYuan Diao, Wenbo Yu, Lei Pei, Zhaofen Lin, and Dechang Chen. Estimation of the reproductive number of novel coronavirus (covid-19) and the probable outbreak size on the diamond princess cruise ship: A data-driven analysis. *International Journal of Infectious Diseases*, 93:201–204, 2020.
- [432] Yuzhou Zhang, Laith Yakob, Michael B Bonsall, and Wenbiao Hu. Predicting seasonal influenza epidemics using cross-hemisphere influenza surveillance data and local internet query data. *Scientific reports*, 9(1):1–7, 2019.
- [433] Bendong Zhao, Huanzhang Lu, Shangfeng Chen, Junliang Liu, and Dongya Wu. Convolutional neural networks for time series classification. *Journal of Systems Engineering and Electronics*, 28(1):162–169, 2017.
- [434] Huimin Zhao and Sudha Ram. Constrained cascade generalization of decision trees. *IEEE Transactions on Knowledge and Data Engineering*, 16(6):727–739, 2004.
- [435] Huimin Zhao and Sudha Ram. Entity matching across heterogeneous data sources: An approach based on constrained cascade generalization. *Data & Knowledge Engineering*, 66(3):368–381, 2008.
- [436] Ling Zhao, Yujiao Song, Chao Zhang, Yu Liu, Pu Wang, Tao Lin, Min Deng, and Haifeng Li. T-gcn: A temporal graph convolutional network for traffic prediction. *IEEE transactions on intelligent transportation systems*, 21(9):3848–3858, 2019.

- [437] Ge Zheng, Wei Koong Chai, and Vasilis Katos. An ensemble model for short-term traffic prediction in smart city transportation system. In *2019 IEEE Global Communications Conference (GLOBECOM)*, pages 1–6. IEEE, 2019.
- [438] Lin Zheng, Chaowei Qi, and Shibo Zhao. Multivariate passenger flow forecast based on acfb model. In *INTERNATIONAL CONFERENCE ON WIRELESS COMMUNICATIONS, NETWORKING AND APPLICATIONS*, pages 104–113. Springer, 2022.
- [439] Long Zhou, Jiajun Zhang, and Chengqing Zong. Synchronous bidirectional neural machine translation. *Transactions of the Association for Computational Linguistics*, 7:91–105, 2019.
- [440] Weiguo Zhu, Yongqi Sun, Xintong Yi, and Yan Wang. A correlation information-based spatiotemporal network for traffic flow forecasting. *arXiv preprint arXiv:2205.10365*, 2022.
- [441] Xiangyu Zou, Jinjin Zhao, Duan Zhao, Bin Sun, Yongxin He, and Stelios Fuentes. Air quality prediction based on a spatiotemporal attention mechanism. *Mobile Information Systems*, 2021, 2021.
- [442] Zhili Zuo, Haixiang Guo, and Jinhua Cheng. An lstm-stripat model analysis of china’s 2030 co2 emissions peak. *Carbon Management*, 11(6):577–592, 2020.