



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ  
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ  
ΥΠΟΛΟΓΙΣΤΩΝ  
ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ  
ΕΡΓΑΣΤΗΡΙΟ ΣΥΣΤΗΜΑΤΩΝ ΤΕΧΝΗΤΗΣ ΝΟΗΜΟΣΥΝΗΣ ΚΑΙ ΜΑΘΗΣΗΣ

Ανάλυση χρονοσειρών με χρήση νευρωνικών  
δικτύων μετασχηματιστών

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

του

ΚΟΝΤΑΡΑ ΜΑΡΙΝΟΥ

**Επιβλέπων:** Αθανάσιος Βουλόδημος  
Επίκουρος Καθηγητής Ε.Μ.Π.  
**Συνεπιβλέπων:** Γεώργιος Αλεξανδρίδης  
Εργαστηριακό και Διδακτικό Προσωπικό Ε.Μ.Π.

Αθήνα, Απρίλιος 2023





ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ  
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ  
ΥΠΟΛΟΓΙΣΤΩΝ  
ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ  
ΕΡΓΑΣΤΗΡΙΟ ΣΥΣΤΗΜΑΤΩΝ ΤΕΧΝΗΤΗΣ ΝΟΗΜΟΣΤΝΗΣ ΚΑΙ  
ΜΑΘΗΣΗΣ

Ανάλυση χρονοσειρών με χρήση νευρωνικών  
δικτύων μετασχηματιστών

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

ΚΟΝΤΑΡΑ ΜΑΡΙΝΟΥ

Επιβλέπων: Αθανάσιος Βουλόδημος  
Επίκουρος Καθηγητής Ε.Μ.Π.  
Συνεπιβλέπων: Γεώργιος Αλεξανδρίδης  
Εργαστηριακό και Διδακτικό Προσωπικό Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 24 Απριλίου 2023.

(Υπογραφή)

(Υπογραφή)

(Υπογραφή)

.....  
Αθανάσιος Βουλόδημος  
Επίκουρος Καθηγητής Ε.Μ.Π.

.....  
Στάμου Γεώργιος  
Καθηγητής Ε.Μ.Π.

.....  
Κόλλιας Στέφανος  
Καθηγητής Ε.Μ.Π.

Αθήνα, Απρίλιος 2023





ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ  
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ  
ΥΠΟΛΟΓΙΣΤΩΝ  
ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ  
ΕΡΓΑΣΤΗΡΙΟ ΣΥΣΤΗΜΑΤΩΝ ΤΕΧΝΗΤΗΣ ΝΟΗΜΟΣΤΝΗΣ ΚΑΙ  
ΜΑΘΗΣΗΣ

Copyright ©–All rights reserved Μαρίνος Κονταράς, 2023.

Με την επιφύλαξη παντός δικαιώματος.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα.

Το περιεχόμενο αυτής της εργασίας δεν απηχεί απαραίτητα τις απόψεις του Τμήματος, του Επιβλέποντα, ή της επιτροπής που την ενέκρινε.

### Υπεύθυνη Δήλωση

Βεβαιώνω ότι είμαι συγγραφέας αυτής της πτυχιακής εργασίας, και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην πτυχιακή εργασία. Επίσης έχω αναφέρει τις όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε αυτές αναφέρονται ακριβώς είτε παραφρασμένες. Επίσης, βεβαιώνω ότι αυτή η πτυχιακή εργασία προετοιμάστηκε από εμένα προσωπικά ειδικά για τις απαιτήσεις του προγράμματος σπουδών του τμήματος Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου.

(Υπογραφή)

Μαρίνος Κονταράς



# Περίληψη

Η πρόβλεψη χρονοσειρών αποτελεί μία κρίσιμη εργασία για ποικίλους τομείς, με τα παραδοσιακά στατιστικά μοντέλα να αποτυγχάνουν συχνά να συλλάβουν πολύπλοκες χρονικές και μακροπρόθεσμες εξαρτήσεις. Για την αντιμετώπιση αυτού του ζητήματος, τα μοντέλα βαθιάς μάθησης έχουν αναδειχθεί ως ένα ισχυρό εναλλακτικό εργαλείο. Πιο συγκεκριμένα, τα νευρωνικά δίκτυα μετασχηματιστών, τα οποία έχουν επιδείξει εντυπωσιακές επιδόσεις σε τομείς με χρονική αλληλεξάρτηση όπως είναι η επεξεργασία φυσικής γλώσσας, έχουν πρόσφατα επεκταθεί στην πρόβλεψη χρονοσειρών.

Η παρούσα διπλωματική εργασία στοχεύει στην βελτίωση ενός ήδη υπάρχοντος ευφυούς συστήματος μεταφορών που χρησιμοποιείται για αποτελεσματικές στρατηγικές ελέγχου και διαχείρισης της κυκλοφορίας, αλλά και βελτιστοποιημένες ταξιδιωτικές αποφάσεις και προγραμματισμό για τους ενδιαφερόμενους χρήστες. Αυτό το σύστημα ενσωματώνει διάφορες βάσεις δεδομένων και εργαλεία για την εκπαίδευση και αξιολόγηση μοντέλων μηχανικής & βαθιάς μάθησης, με έμφαση στα μοντέλα μετασχηματιστών για δεδομένα χρονοσειρών. Επιπλέον, η συγκεκριμένη έρευνα παρέχει μια ολοκληρωμένη μελέτη της ανάλυσης χρονοσειρών με τη χρήση μετασχηματιστών, καλύπτοντας τόσο τις θεωρητικές βάσεις όσο και τις πρακτικές υλοποιήσεις.

Επιπλέον, προτείνονται νέες επεκτάσεις υφιστάμενων μοντέλων μετασχηματιστών για την βελτίωση της πρόβλεψης δεδομένων χρονοσειρών, μέσω της ορθής αξιοποίησης και ενσωμάτωσης εξωτερικών μεταβλητών στις υπό μελέτη αρχιτεκτονικές. Η αποτελεσματικότητα αυτών των προτεινόμενων μεθόδων επαληθεύεται σε ένα πραγματικό σύνολο κυκλοφοριακών δεδομένων, από σταθμούς διοδίων της Ολυμπίας Οδού, ενός από τους σημαντικότερους και μεγαλύτερους αυτοκινητόδρομους στην Ελλάδα.

Συνολικά, η παρούσα διπλωματική εργασία παρέχει πολύτιμες γνώσεις σχετικά με την εφαρμογή μοντέλων που βασίζονται σε μετασχηματιστές για την πρόβλεψη χρονοσειρών σε συστήματα ευφυών μεταφορών. Το σύστημα που σχεδιάστηκε και υλοποιήθηκε σε αυτή τη εργασία μπορεί να αποτελέσει την αφετηρία για μελλοντική έρευνα σε αντίστοιχες εφαρμογές πραγματικού κόσμου.

## Λέξεις Κλειδιά

Ανάλυση χρονοσειρών, Μονομεταβλητή πρόβλεψη χρονοσειρών, Πρόβλεψη κυκλοφορίας, Ευφυές Σύστημα Μεταφορών, Νευρωνικά Δίκτυα, Βαθιά Μάθηση, Δίκτυα Μετασχηματιστών





# Abstract

Time-series forecasting has become a critical task for many applications across a variety of fields, with traditional statistical models often failing to capture complex temporal and long-term dependencies. To address this issues, deep learning models have emerged as a powerful alternative tool in this field. More specifically, transformer-based neural networks, which have shown impressive performance in tasks with temporal dependencies such as natural language processing, have recently been extended to time-series forecasting.

This diploma thesis aims to the improvement of an existing intelligent transportation system that is utilized for efficient traffic control and management strategies, as well as optimized travel decisions and scheduling for commuters. This system incorporates various databases and tools for training and evaluating machine & deep learning models, with a focus on transformer architectures for time-series data. Moreover, this thesis provides a comprehensive study of time-series analysis using transformers, covering both the theoretical foundations and practical implementations.

In addition, novel extensions to the existing transformer-based models are proposed for time-series analysis, including the incorporation of external variables and leveraging multi-horizon forecasting. The effectiveness of the proposed methods are demonstrated on a real-world traffic dataset, originating from toll stations at Olympia Odos, a modern highway in Greece.

Overall, this thesis provides valuable insight into the application of transformer-based models for time-series forecasting. The framework designed and implemented in this thesis can serve as a starting point for future research and real-world applications in intelligent transportation systems.

## Keywords

Time-series Analysis, Univariate Forecasting, Traffic Forecasting, Intelligent Transportation System, Neural Networks, Deep Learning, Transformers



*στους γονείς μου*



# Ευχαριστίες

Πρώτα απ' όλα, θα ήθελα να εκφράσω την εγκάρδια ευγνωμοσύνη μου στον Επίκουρο Καθηγητή Ε.Μ.Π. κ. Βουλόδημο Αθανάσιο για την ευκαιρία που μου έδωσε να εκπονήσω τη διπλωματική μου εργασία στο Εργαστήριο Τεχνητής Νοημοσύνης της Σχολής Ηλεκτρολόγων Μηχανικών & Μηχανικών Η/Υ του ΕΜΠ, αλλά και που με βοήθησε να διευρύνω τις γνώσεις μου στον περίπλοκο κόσμο της Τεχνητής Νοημοσύνης και των Νευρωνικών Δικτύων. Επιπλέον, θα ήθελα να εκφράσω τη βαθύτατη εκτίμησή μου στο μέλος Εργαστηριακού και Διδακτικού Προσωπικού Ε.Μ.Π., κ. Γεώργιο Αλεξανδρίδη, του οποίου η ανεκτίμητη βοήθεια και επίβλεψη ήταν καθοριστική για την επιτυχία της εργασίας μου. Δεν θα μπορούσα να είχα ολοκληρώσει αυτή την εργασία χωρίς τη συνεχή υποστήριξη και ενθάρρυνσή του και είμαι ευγνώμων για την εξαιρετική συνεργασία που είχαμε.

Θα ήθελα επίσης να ευχαριστήσω όλους τους εξωτερικούς συνεργάτες αυτής της εργασίας, τους υπεύθυνους της Ολυμπίας Οδού Α.Ε., κ. Fabrice Breton και κα. Καλλιόπη Τζιβανάκη, που μας έδωσαν την ευκαιρία να εργαστούμε πάνω στα κυκλοφοριακά δεδομένα της Ολυμπίας Οδού και μας παρείχαν χρήσιμες πληροφορίες για την επιτυχία αυτού του απαιτητικού έργου, καθώς και τον κ. Πέτρο Αλεξανδρίδη από την Extrabit E.E, για την πολύτιμη συμβολή και τις παρατηρήσεις του καθ' όλη τη διάρκεια της έρευνας.

Στο σημείο αυτό θα ήθελα να ευχαριστήσω προσωπικά όλους τους ανθρώπους που με βοήθησαν καθ' όλη τη διάρκεια των φοιτητικών μου χρόνων. Στους φίλους μου, τους συμφοιτητές μου και τους συναδέλφους μου· σας ευχαριστώ για την υποστήριξη και την ενθάρρυνση σας. Τέλος, θα ήθελα να εκφράσω την ευγνωμοσύνη μου στους γονείς μου. Η αγάπη και η υποστήριξή τους ήταν το θεμέλιο πάνω στο οποίο έχτισα την ακαδημαϊκή μου σταδιοδρομία. Πάντα με ενθάρρυναν να κυνηγάω τα όνειρά μου και μου παρείχαν τα εργαλεία και τους πόρους που χρειαζόμουν για να επιτύχω. Είμαι ευγνώμων για την αγάπη, την καθοδήγηση και την πίστη τους σε μένα και τους αφιερώνω αυτή την εργασία με όλη μου την καρδιά.

Απρίλιος 2023  
Κοντάρας Μαρίνος



# Περιεχόμενα

Περίληψη	i
Abstract	iii
Ευχαριστίες	vii
Περιεχόμενα	xi
Κατάλογος Σχημάτων	xv
Κατάλογος Πινάκων	xvii
<b>1 Εισαγωγή</b>	<b>1</b>
1.1 Κίνητρο . . . . .	2
1.2 Στόχοι και συνεισφορές της εργασίας . . . . .	7
1.3 Διάρθρωση της Διπλωματικής Εργασίας . . . . .	9
<b>2 Πρόβλεψη χρονοσειρών</b>	<b>11</b>
2.1 Χρονοσειρές . . . . .	11
2.2 Πρόβλεψη χρονοσειρών . . . . .	15
2.2.1 Στατιστικά Μοντέλα . . . . .	15
2.2.2 Μοντέλα μηχανικής & βαθιάς μάθησης . . . . .	17
2.3 Μοντέλα μετασχηματιστών για χρονοσειρές . . . . .	19
<b>3 Βαθιά Μάθηση και Μοντέλα Ακολουθίας-σε-Ακολουθία</b>	<b>23</b>
3.1 Νευρωνικά Δίκτυα Πρόσθιας Τροφοδότησης . . . . .	24
3.1.1 Συνελικτικά Νευρωνικά Δίκτυα . . . . .	25
3.1.2 Συνέλιξη . . . . .	26
3.1.3 Αιτιώδης Συνέλιξη . . . . .	26
3.1.4 Διευρυμένη Συνέλιξη . . . . .	27
3.2 Μοντέλα Ακολουθίας-προς-Ακολουθία . . . . .	27
3.2.1 Μοντέλα Μετασχηματιστών . . . . .	28
3.2.2 Αυτο-προσοχή . . . . .	29

3.2.3	Τεχνική Μάσκας . . . . .	31
3.2.4	Αυτοπροσοχή με πολλαπλές κεφαλές . . . . .	31
3.2.5	Κωδικοποίηση θέσης . . . . .	33
<b>4</b>	<b>Δεδομένα και Αρχιτεκτονική Συστήματος</b>	<b>35</b>
4.1	Σύνολο δεδομένων . . . . .	35
4.2	Διαδικασία ETL . . . . .	36
4.3	Προεπεξεργασία δεδομένων . . . . .	37
4.4	Διαχωρισμός δεδομένων . . . . .	38
4.5	Ανάλυση δεδομένων . . . . .	38
4.6	Ευφυές Σύστημα Μεταφορών . . . . .	40
4.6.1	Στοιχεία συστήματος . . . . .	46
<b>5</b>	<b>Μοντέλα Μετασχηματιστών</b>	<b>49</b>
5.1	Vanilla Transformer . . . . .	49
5.2	Informer . . . . .	50
5.3	FEDFormer . . . . .	53
5.4	ETSFormer . . . . .	54
5.5	Επιλογή μοντέλου . . . . .	56
<b>6</b>	<b>Πειράματα</b>	<b>59</b>
6.1	Τροποποιημένος ETSFormer . . . . .	59
6.2	Πληροφορίες υλοποίησης . . . . .	59
6.2.1	Υπερπαράμετροι . . . . .	59
6.2.2	Βελτιστοποίηση, συνάρτηση απώλειας και μετρικές αξιολόγησης . . . . .	60
6.2.3	Τεχνικές κανονικοποίησης . . . . .	63
6.3	Μοντέλα βάσης . . . . .	63
6.4	Συνδυαστικό Μοντέλο . . . . .	65
<b>7</b>	<b>Αποτελέσματα</b>	<b>67</b>
7.1	Επιλογή μοντέλου . . . . .	67
7.2	Αποτελέσματα αξιολόγησης . . . . .	68
7.2.1	Απώλεια εκπαίδευσης και επικύρωσης . . . . .	74
7.3	Προβλέψεις κυκλοφορίας . . . . .	75
7.3.1	Τελικό συνδυαστικό μοντέλο . . . . .	77
7.4	Πολυμεταβλητή πρόβλεψη κυκλοφορίας . . . . .	79
<b>8</b>	<b>Συμπεράσματα και μελλοντική έρευνα</b>	<b>85</b>
<b>A'</b>	<b>Παράρτημα</b>	<b>89</b>
A'.1	Απώλεια εκπαίδευσης και επικύρωσης . . . . .	89
A'.2	Προβλέψεις κυκλοφορίας . . . . .	89



---

Συντομεύσεις - Αρχικόλεξα

109



# Κατάλογος Σχημάτων

1.1	Βασικά χαρακτηριστικά της υποδομής και των υπηρεσιών των Ευφυών Συστημάτων Μεταφορών (Πηγή: [48]) . . . . .	4
1.2	Υποδομή και βασικά στοιχεία ενός Ευφυούς Συστήματος Διαχείρισης Αυτοκινητόδρομων σε σταθμούς διοδίων (Πηγή: [48]) . . . . .	6
2.1	Ένα παράδειγμα διακριτής μονομεταβλητής χρονοσειράς που δείχνει τον όγκο κυκλοφορίας στα διόδια ενός αυτοκινητοδρόμου στην Ελλάδα. . . . .	12
2.2	Πολλαπλασιαστική αποσύνθεση των χρονοσειρών Bitcoin και Microsoft (Πηγή: [87]) . . . . .	13
2.3	Η αρχιτεκτονική του κωδικοποιητή-αποκωδικοποιητή . . . . .	19
3.1	Στρώμα από $S$ Perceptrons με $R$ εισόδους [81] . . . . .	24
3.2	Πολυστρωματικό Perceptron με ένα στρώμα εισόδου, ένα στρώμα εξόδου (στρώμα 3) και δύο κρυφά στρώματα (στρώματα 1 και 2) [81] . . . . .	25
3.3	Διαφορά μεταξύ ρηχών και βαθιών δικτύων ΠΤ . . . . .	25
3.4	Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου . . . . .	26
3.5	Διαφορές μεταξύ (α) του τυπικού, (β) του αιτιώδους και (γ) του διευρυμένου ΣΝΔ. . . . .	28
3.6	Γενική αρχιτεκτονική του μοντέλου ακολουθίας-προς-ακολουθία . . . . .	28
3.7	Μηχανισμός Αυτο-προσοχής . . . . .	30
3.8	Απλή προβολή της εισόδου $\mathbf{X}$ με πολλαπλασιασμό πινάκων για την κατασκευή των πινάκων $\mathbf{Q}$ , $\mathbf{K}$ και $\mathbf{V}$ . . . . .	31
3.9	Τεχνική μάσκας . . . . .	32
3.10	Αυτοπροσοχή με πολλαπλές κεφαλές: πολλαπλά επίπεδα προσοχής που λειτουργούν παράλληλα . . . . .	32
3.11	Γραφική απεικόνιση της ημιτονοειδούς κωδικοποίησης θέσης . . . . .	33
4.1	Όγκος κυκλοφορίας ανά έτος για όλους τους σταθμούς διοδίων . . . . .	40
4.2	Όγκος κυκλοφορίας ανά μήνα για την κατεύθυνση ELEE για τα έτη 2022, 2020, 2019, 2018 και 2017. . . . .	41
4.3	Όγκος κυκλοφορίας ανά μήνα για την κατεύθυνση ELET για τα έτη 2022, 2020, 2019, 2018 και 2017. . . . .	42

4.4	Όγκος κυκλοφορίας ανά μήνα για την κατεύθυνση ISTE για τα έτη 2022, 2020, 2019, 2018 και 2017. . . . .	43
4.5	Όγκος κυκλοφορίας ανά μήνα για την κατεύθυνση ISTT για τα έτη 2022, 2020, 2019, 2018 και 2017. . . . .	44
4.6	Ποσοστό Αληθών τιμών των δυαδικών μεταβλητών τα έτη 2022, 2020, 2019, 2018 και 2017. . . . .	45
4.7	Αρχιτεκτονική του ευφυούς συστήματος κυκλοφορίας για εφαρμογές πραγματικού χρόνου . . . . .	47
5.1	Αρχιτεκτονική του Informer (Πηγή: [104]) . . . . .	51
5.2	Η αναπαράσταση εισόδου του Informer [104] . . . . .	52
5.3	Αρχιτεκτονική του κωδικοποιητή του Informer [104] . . . . .	52
5.4	Αρχιτεκτονική του FEDFormer (Πηγή: [105]) . . . . .	53
5.5	Αρχιτεκτονική του ETSFormer (Πηγή: [96]) . . . . .	55
6.1	Βασική αρχιτεκτονική ενός συνδυαστικού μοντέλου . . . . .	66
7.1	Απώλειες εκπαίδευσης και επικύρωσης για τους σταθμούς διοδίων ELEE και ELET, για κάθε μοντέλο του Πίνακα 7.6 . . . . .	75
7.2	Προβλέψεις των συνδυαστικών μοντέλων για τον σταθμό διοδίων ELEE και ELET. Το παράθυρο αναδρομής είναι από 20/02/2023 00:00 έως 22/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 23/02/2023 00:00 έως 25/02/2023 00:00. . . . .	76
7.3	Προβλέψεις του προτεινόμενου συνδυαστικού μοντέλου για τους σταθμούς διοδίων ELEE και ELET. Το παράθυρο αναδρομής είναι από 20/02/2023 00:00 έως 22/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 23/02/2023 00:00 έως 25/02/2023 00:00. . . . .	79
7.4	Προβλέψεις του προτεινόμενου συνδυαστικού μοντέλου για τους σταθμούς διοδίων ELEE και ELET. Το παράθυρο αναδρομής είναι από 21/02/2023 00:00 έως 23/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 24/02/2023 00:00 έως 26/02/2023 00:00. . . . .	80
7.5	Προβλέψεις του προτεινόμενου συνδυαστικού μοντέλου για τους σταθμούς διοδίων ELEE και ELET. Το παράθυρο αναδρομής είναι από 22/02/2023 00:00 έως 24/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 25/02/2023 00:00 έως 27/02/2023 00:00. . . . .	81
7.6	Προβλέψεις του προτεινόμενου συνδυαστικού μοντέλου για τους σταθμούς διοδίων ELEE και ELET. Το παράθυρο αναδρομής είναι από 23/02/2023 00:00 έως 25/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 26/02/2023 00:00 έως 28/02/2023 00:00. . . . .	82

7.7	Προβλέψεις του προτεινόμενου συνδυαστικού μοντέλου για τους σταθμούς διοδίων ELEE και ELET. Το παράθυρο αναδρομής είναι από 24/02/2023 00:00 έως 26/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 27/02/2023 00:00 έως 29/02/2023 00:00. . . . .	83
A.1	Απώλειες εκπαίδευσης και επικύρωσης για τους σταθμούς διοδίων ΙΣΤΕ και ΙΣΤΤ για κάθε μοντέλο του Πίνακα 7.6 . . . . .	89
A'2	Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 20/02/2023 00:00 έως 22/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 23/02/2023 00:00 έως 25/02/2023 00:00. . .	90
A'3	Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 21/02/2023 00:00 έως 23/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 24/02/2023 00:00 έως 26/02/2023 00:00. . .	91
A'4	Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 22/02/2023 00:00 έως 24/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 25/02/2023 00:00 έως 27/02/2023 00:00. . .	92
A'5	Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 23/02/2023 00:00 έως 25/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 26/02/2023 00:00 έως 28/02/2023 00:00. . .	93
A'6	Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 24/02/2023 00:00 έως 26/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 27/02/2023 00:00 έως 29/02/2023 00:00. . .	94
A'7	Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 19/03/2023 00:00 έως 21/03/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 22/03/2023 00:00 έως 24/03/2023 00:00. . .	95
A'8	Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 20/03/2023 00:00 έως 22/03/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 23/03/2023 00:00 έως 25/03/2023 00:00. . .	96
A'9	Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 21/03/2023 00:00 έως 23/03/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 24/03/2023 00:00 έως 26/03/2023 00:00. . .	97
A'10	Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 22/03/2023 00:00 έως 24/03/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 25/03/2023 00:00 έως 27/03/2023 00:00. . .	98
A'11	Προβλέψεις των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 23/02/2023 00:00 έως 25/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 26/03/2023 00:00 έως 28/03/2023 00:00.	99



# Κατάλογος Πινάκων

4.1	Σταθμοί διοδίων στο σύνολο δεδομένων . . . . .	36
4.2	Χρησιμοποιούμενες στήλες από τη βάση δεδομένων με τους τύπους και την περιγραφή τους . . . . .	36
5.1	Ανάλυση πολυπλοκότητας διαφορετικών μοντέλων πρόβλεψης (Πηγή: [105]) . . . . .	57
6.1	Υπερπαραμέτροι που χρησιμοποιήθηκαν στο ETSFormer . . . . .	60
6.2	Βασικές τιμές υπερπαραμέτρων του vanilla Transformer . . . . .	64
6.3	Βασικές τιμές υπερπαραμέτρων του Informer . . . . .	64
6.4	Βασικές τιμές υπερπαραμέτρων του FEDFormer . . . . .	65
7.1	Βέλτιστες τιμές υπερπαραμέτρων του ETSFormer για τους σταθμούς διοδίων <b>ELEE</b> και <b>ISTE</b> . . . . .	67
7.2	Βέλτιστες τιμές υπερπαραμέτρων του ETSFormer για τους σταθμούς διοδίων <b>ELET</b> και <b>ISTT</b> . . . . .	68
7.3	Παραλλαγές του Modified ETSFormer για κάθε σταθμό διοδίων . . . . .	68
7.4	Συνδυαστικά μοντέλα για κάθε σταθμό διοδίων . . . . .	69
7.5	Αποτελέσματα μονομεταβλητής πρόβλεψης μακράς ακολουθίας για παραλλαγές του METSFormer. Τα καλύτερα αποτελέσματα επισημαίνονται με <b>bold</b> . . . . .	69
7.6	Αποτελέσματα μονομεταβλητής πρόβλεψης μακράς ακολουθίας για διαφορετικές αρχιτεκτονικές Μετασχηματιστή στο σύνολο δεδομένων. Τα καλύτερα αποτελέσματα επισημαίνονται με <b>έντονη γραφή</b> και τα δεύτερα καλύτερα αποτελέσματα με <u>υπογράμμιση</u> . . . . .	72





# Κεφάλαιο 1

## Εισαγωγή

Η ανάλυση χρονοσειρών αποτελεί σημαντικό πεδίο μελέτης εδώ και αρκετές δεκαετίες. Παρέχει στους ερευνητές μια πληθώρα αναλυτικών εργαλείων που απαιτούνται για την ανάδειξη και την κατανόηση προτύπων και τάσεων. Πιο συγκεκριμένα, μια χρονοσειρά ορίζεται ως μια διατεταγμένη ακολουθία παρατηρήσεων κάποιας διαδικασίας που λαμβάνονται διαδοχικά στο χρόνο [95]. Κατά την τελευταία δεκαετία, η ανάλυση και η μοντελοποίηση της χρονικής εξάρτησης και δυναμικής των δεδομένων έχει αποκτήσει σημαντική προβολή ως ερευνητικό πεδίο και έχει καταστεί κρίσιμο συστατικό σε διάφορους τομείς, όπως στη χρηματοοικονομική και την οικονομετρία [54, 16], τη μετεωρολογία [2] το περιβάλλον [94] και το κλίμα [59], τα δίκτυα υπολογιστών και επικοινωνιών [83, 101], την υγεία και την ιατρική επιστήμη [78, 85], την παραγωγή [58] και τη διαφήμιση [30]. Τα παραδοσιακά στατιστικά μοντέλα χρονοσειρών, όπως τα μοντέλα αυτοπαλινδρόμησης (autoregression), κινητού μέσου όρου (moving average), εκθετικής εξομάλυνσης (exponential smoothing) και οι παραλλαγές τους [95, 91, 77, 94, 16, 32], χρησιμοποιούνται ευρέως για αυτού του είδους τις εργασίες εδώ και αρκετά χρόνια. Σήμερα, με τόσους πολλούς τομείς εφαρμογής σε συνδυασμό με την τεράστια πρόοδο της υπολογιστικής ισχύος και την ταχεία αύξηση του όγκου και της διαθεσιμότητας των δεδομένων, οι τεχνικές και οι αλγόριθμοι μηχανικής και βαθιάς μάθησης αναδύονται ως πιθανές λύσεις που αντιμετωπίζουν τους περιορισμούς των αμιγώς παραμετρικών μοντέλων με βάση τα εκάστοτε δεδομένα [3].

Τα βαθιά νευρωνικά δίκτυα (BND - deep neural networks) είναι μερικές από τις πιο πρόσφατα εισαχθείσες τεχνικές μηχανικής μάθησης που έχουν επιτύχει πολλά υποσχόμενα αποτελέσματα και αξιοσημείωτες επιδόσεις σε διάφορα προβλήματα σχετικά με την ανάλυση χρονοσειρών [40, 23, 36, 71, 76]. Οι πρόσφατες προόδους στη μοντελοποίηση πρόβλεψης με βάση την προσοχή (attention-based predictive modeling), με έμφαση στην καινοτομία του μοντέλου μετασχηματιστή (transformer) [88], έχουν δείξει μεγάλες δυνατότητες στη βελτίωση της αποτελεσματικότητας της ανάλυσης χρονοσειρών. Τα μοντέλα Μετασχηματιστών στη βαθιά μάθηση έχουν οδηγήσει σε τεράστιες βελτιώσεις στην *όραση υπολογιστών* [46] (μερικά παραδείγματα είναι τα DETR [14], Vision Transformer [28] και Image GPT [19]), στην *αναγνώριση ομιλίας* [49] και την *επεξεργασία φυσικής γλώσσας* [51] (μερικά παραδείγματα είναι τα BERT [26], Transformer-XL [25] και GPT-3 [12]), λόγω της ικανότητάς τους να μοντελο-

ποιούν εξαρτήσεις μεγάλης εμβέλειας σε διαδοχικά δεδομένα και συνεπώς είναι ελκυστικά στη μοντελοποίηση χρονοσειρών. Πράγματι, τα τελευταία χρόνια, έχουν προταθεί πολυάριθμα μοντέλα που βασίζονται σε μετασχηματιστές για τη βελτίωση της απόδοσης διαφόρων εργασιών και πρόσφατα άρχισε η έρευνα για την εφαρμογή τους σε εργασίες χρονοσειρών, όπως η πρόβλεψη, η ανίχνευση ανωμαλιών και η ταξινόμηση [92].

## 1.1 Κίνητρο

Στις μέρες μας, η έννοια της «έξυπνης» πόλης σημειώνει ανοδική πορεία εξαιτίας της αστικοποίησης και της αύξησης του παγκόσμιου πληθυσμού [10]. Στις έξυπνες πόλεις ενσωματώνονται διάφορες σύγχρονες τεχνολογίες πληροφορικής και επικοινωνιών για τη συλλογή, ανάλυση και αξιοποίηση βασικών πληροφοριών προκειμένου να βελτιωθεί η λειτουργία των πόλεων, συμπεριλαμβανομένης της ενίσχυσης της δημόσιας ασφάλειας, της προώθησης της βιώσιμης ανάπτυξης και της αποτελεσματικής διαχείρισης των πόρων [103].

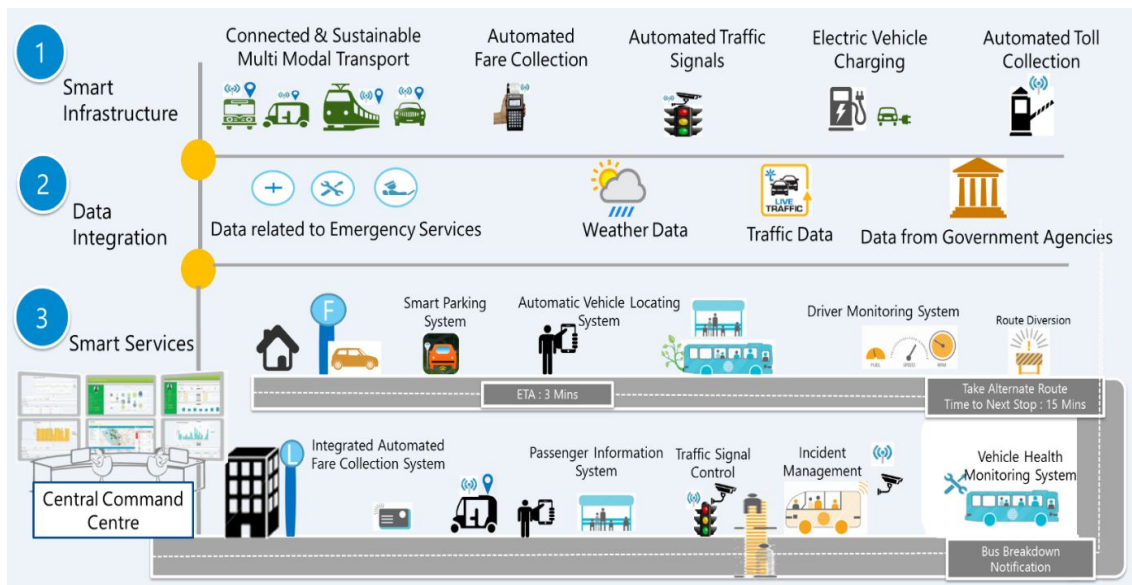
Οι υπηρεσίες της έξυπνης πόλης έχουν σχεδιαστεί για να παρέχουν ευφυείς απαντήσεις σε ποικίλες ανάγκες που σχετίζονται με το αστικό περιβάλλον. Με την ταχεία ανάπτυξη του διαδικτύου των πραγμάτων (Internet of Things - IoT) περισσότερα δεδομένα σχετικά με το οικοσύστημα των πόλεων γίνονται μετρήσιμα [55]. Μεταξύ των διαφόρων στόχων των έξυπνων πόλεων, η ανάπτυξη έξυπνων συστημάτων κυκλοφορίας και αστικής διαχείρισης είναι δύο βασικοί άξονες που θα μπορούσαν να επηρεάσουν σημαντικά τη ζωή των κατοίκων των μελλοντικών πόλεων. Το σύστημα μεταφορών και οδικής κυκλοφορίας είναι ζωτικής σημασίας για τη λειτουργία και την ανάπτυξη των πόλεων και η πρόσφατη τάση προς την αστικοποίηση έχει επιφέρει πολλές προκλήσεις στον τομέα αυτό. Με περισσότερο από τον μισό παγκόσμιο πληθυσμό να ζει σε αστικές περιοχές [62], η κυκλοφοριακή συμφόρηση έχει καταστεί μείζον πρόβλημα, με αποτέλεσμα την αύξηση των χρόνων ταξιδιού, αλλά και των κυκλοφοριακών παραβάσεων, της κατανάλωσης καυσίμων και των εκπομπών αέριων ρύπων [55].

Σύμφωνα με τον Rosenbloom [1], η κυκλοφοριακή συμφόρηση εμφανίζεται όταν η ταξιδιωτική ζήτηση υπερβαίνει την υπάρχουσα χωρητικότητα του οδικού συστήματος. Παρά τις σημαντικές επενδύσεις και τα μέτρα στις υποδομές μεταφορών και διαχείρισης της κυκλοφορίας, η κυκλοφοριακή συμφόρηση των δρόμων παραμένει ένα κρίσιμο κοινωνικό, οικονομικό και περιβαλλοντικό πρόβλημα [73]. Για παράδειγμα, το Υπουργείο Μεταφορών των ΗΠΑ θεωρεί την κυκλοφοριακή συμφόρηση ως μία από τις σημαντικότερες απειλές για την οικονομική επιτυχία, ενώ κοστίζει περίπου \$869 σε χαμένο χρόνο ετησίως ανά άτομο και ένα συνολικό ποσό ύψους 81 δισεκατομμυρίων δολαρίων σε χαμένο χρόνο και καύσιμα στις Ηνωμένες Πολιτείες το 2022 [64]. Η κατάσταση είναι πανομοιότυπη και σε άλλες χώρες, με την κυκλοφοριακή συμφόρηση να οδηγεί σε απώλεια παραγωγικότητας, αυξημένη ατμοσφαιρική ρύπανση και μειωμένη ποιότητα ζωής για τους κατοίκους. Η έλλειψη ακριβούς και έγκαιρης πληροφόρησης σχετικά με τις συνθήκες κυκλοφορίας είναι μία από τις κύριες αιτίες της κυκλοφοριακής συμφόρησης [98]. Οι οδηγοί μπορεί να μην γνωρίζουν για κυκλοφοριακά συμβάντα, κατασκευές ή κλείσιμο δρόμων, οδηγώντας σε καθυστερήσεις, απογοήτευση, ακόμη και ατυχήματα. Επιπλέον, οι οργανισμοί διαχείρισης της κυκλοφορίας συχνά βασίζονται σε ξεπερασμένα κυκλοφοριακά δεδομένα ή εκτιμήσεις, γεγονός που μπορεί να οδηγήσει σε αναποτελεσματικές στρατηγικές διαχείρισης της κυκλοφορίας.

Τα ευφυή συστήματα μεταφορών (ΕΣΜ - intelligent transportation systems) ή αλλιώς τα ευφυή συστήματα κυκλοφορίας αναδύονται ως πιθανές λύσεις για την αντιμετώπιση των προκλήσεων που αντιμετωπίζουν οι αστικές περιοχές, όπως οι μετακινήσεις, η ασφάλεια και η κυκλοφοριακή συμφόρηση [18]. Σε αντίθεση με τις παραδοσιακές μεθόδους κατασκευής νέων υποδομών, τα ΕΣΜ χρησιμοποιούν μια σειρά τεχνολογιών, συμπεριλαμβανομένων ηλεκτρονικών αισθητήρων, επαγωγικών βρόχων, δικτύων επικοινωνίας, εργαλείων ανάλυσης και μετάδοσης, για την ενσωμάτωση και επεξεργασία ποικίλων δεδομένων [55]. Το IoT είναι ένας ταχέως αναπτυσσόμενος τομέας εντός των ΕΣΜ, ο οποίος περιλαμβάνει τη διασύνδεση έξυπνων συσκευών και αισθητήρων μέσω του διαδικτύου. Οι συσκευές IoT χρησιμοποιούν μια σειρά από μέσα επικοινωνίας για την ανταλλαγή δεδομένων [80], ενώ η διασυνδεσιμότητα σε πραγματικό χρόνο που προσφέρει το IoT, σε συνδυασμό με την αξιοπιστία και τη διαλειτουργικότητά του, το καθιστά ιδιαίτερα χρήσιμο για εφαρμογές έξυπνου δικτύου. Καθώς ο αριθμός των συνδεδεμένων συσκευών συνεχίζει να αυξάνεται, αυξάνεται και ο όγκος των δεδομένων που παράγονται από αυτές. Αυτός ο συνεχώς αυξανόμενος όγκος δεδομένων, σε συνδυασμό με τις πρόσφατες τεχνολογικές εξελίξεις, όπως η μηχανική και βαθιά μάθηση, το υπολογιστικό νέφος και η δικτύωση 5G, παρουσιάζει σημαντικές ευκαιρίες για την ανάπτυξη έξυπνων αλγορίθμων και εφαρμογών στο πλαίσιο των ΕΣΜ [99].

Διάφοροι τομείς που σχετίζονται με τις μεταφορές μπορούν να επωφεληθούν από την ανάπτυξη ευφυών συστημάτων κυκλοφορίας, συμπεριλαμβανομένων των συστημάτων διαχείρισης αρτηριών και δρόμων ταχείας κυκλοφορίας, των συστημάτων διαχείρισης διαμετακόμισης (ΣΔΔ - transit management systems), των συστημάτων διαχείρισης συμβάντων και έκτακτης ανάγκης, των συστημάτων διαχείρισης αυτοκινητόδρομων (ΣΔΑ - Motorway or Advance Traffic Management system) και των συστημάτων διαχείρισης πληροφοριών (ΣΔΠ - Information Management Systems), που ονομάζονται επίσης συστήματα πληροφόρησης

ταξιδιωτών [65]. Η παρούσα εργασία επικεντρώνεται στην ανάπτυξη των ΕΣΜ στον τομέα των ΣΔΑ και ΣΔΠ και διερευνά τη δυνητική χρήση τεχνικών μηχανικής και βαθιάς μάθησης σε τέτοια συστήματα. Γενικά, το ΣΔΠ είναι σχεδιασμένο για να καλύπτει όλους τους τύπους αυτοκινητοδρόμων και αρτηριών, τα μέσα μεταφοράς και όλες τις περιοχές, συμπεριλαμβανομένων γειτονικών πόλεων και χωρών. Με τη βελτίωση της συνολικής ποιότητας της συλλογής δεδομένων σε πραγματικό χρόνο και της προσβασιμότητας σε πληροφορίες, το σύστημα διευκολύνει τους μετακινούμενους ώστε να σχεδιάζουν αποτελεσματικά τις μετακινήσεις τους, να έχουν πρόσβαση σε πληροφορίες για τη διαμετακόμιση σε πραγματικό χρόνο και να λαμβάνουν δρομολόγια κυκλοφορίας και τυχών πληροφορίες για τη στάθμευση [102]. Η ενσωμάτωση των ασύρματων και διαδικτυακών τεχνολογιών στο ΣΔΠ καθιστά επίσης πιο αποτελεσματική την ανάκτηση πληροφοριών κυκλοφορίας σε πραγματικό χρόνο από τους μετακινούμενους [65]. Εκτός από αυτό, τα ΣΔΠ παρέχουν χρήσιμες πληροφορίες που βοηθούν τους υπεύθυνους λήψης αποφάσεων στον έγκαιρο σχεδιασμό και έλεγχο των λειτουργικών και των πόρων. Ομοίως με το ΣΔΠ, το ΣΔΑ είναι μια ολοκληρωμένη λύση για τη διαχείριση της κυκλοφορίας στους αυτοκινητοδρόμους με τη συλλογή, ανάλυση και επεξεργασία δεδομένων. Ο κύριος στόχος ενός ΣΔΑ είναι να ενημερώνει με ακρίβεια και σε πραγματικό χρόνο τους χρήστες, τις υπηρεσίες και τους ενδιαφερόμενους φορείς σχετικά με τις κυκλοφοριακές καταστάσεις, τα συμβάντα, τις οδικές και καιρικές συνθήκες, εξασφαλίζοντας με αυτόν τον τρόπο την ασφάλεια και την αποτελεσματικότητα της κυκλοφορίας. Με τη διαθεσιμότητα των ΕΣΜ, οι μεμονωμένοι μετακινούμενοι, οι τοπικές αρχές και οι οργανισμοί μπορούν να επωφεληθούν από βελτιστοποιημένες ταξιδιωτικές αποφάσεις και αποτελεσματική διαχείριση της κυκλοφορίας [73].



Σχήμα 1.1: Βασικά χαρακτηριστικά της υποδομής και των υπηρεσιών των Ευφυών Συστημάτων Μεταφορών (Πηγή: [48])


Μεταξύ των διαφόρων εφαρμογών των ΕΣΜ (Σχήμα 1.1), η εκτίμηση και η πρόβλεψη της κυκλοφορίας είναι δύο από τις πιο κρίσιμες εργασίες [42]. Παρά τη διαθεσιμότητα μιας

ποικιλίας σχετικών δεδομένων, πληροφορίες για την κυκλοφορία, όπως ο όγκος, η ταχύτητα και ο χρόνος ταξιδιού, μπορεί να μην είναι πάντα άμεσα διαθέσιμες και να απαιτούν πρώτα την επεξεργασία των δεδομένων. Αυτή ακριβώς η επεξεργασία αναφέρεται ως το πρόβλημα της εκτίμησης της κυκλοφορίας, με απώτερο στόχο την εξαγωγή ακριβών πληροφοριών κίνησης από τα ακατέργαστα δεδομένα. Παρόλο που η εκτίμηση παρέχει μόνο πληροφόρηση σχετικά με τις ιστορικές καταστάσεις της κυκλοφορίας, η πρόβλεψη της κυκλοφορίας περιλαμβάνει την εκτίμηση μελλοντικών συνθηκών με βάση τα ιστορικά δεδομένα και την εφαρμογή κατάλληλων μέτρων, όπως είναι ο έλεγχος της κυκλοφορίας, για την αποτροπή κυκλοφοριακής συμφόρησης ή οδικών ανωμαλιών.

Όπως αναφέρθηκε προηγουμένως, οι προβλέψεις κυκλοφορίας μπορούν να χρησιμοποιηθούν στα ΕΣΜ για την υποστήριξη των κέντρων ελέγχου κυκλοφορίας στην αποτελεσματική διαχείριση των οδικών δικτύων, με την κατανομή πόρων με συστηματικό τρόπο, όπως το άνοιγμα και το κλείσιμο λωρίδων και διοδίων, την εκτέλεση συντήρησης και ανακατασκευής δρόμων, την εφαρμογή δυναμικής τιμολόγησης στάθμευσης και τη χρήση προσαρμοστικών φωτεινών σηματοδοτών. Η πρόβλεψη της κυκλοφορίας μπορεί να βοηθήσει στον υπολογισμό αποδοτικότερων διαδρομών, στη μείωση του χρόνου ταξιδιού και στη διευκόλυνση της αναζήτησης χώρων στάθμευσης. Επίσης, η πρόβλεψη της κυκλοφοριακής ροής μπορεί να φανεί χρήσιμη ακόμα και στους εμπόρους για τον εντοπισμό δυνητικών πελατών με την ανάλυση της συμπεριφοράς των πελατών και των προτύπων ταξιδιού κατά τη διάρκεια των περιόδων αιχμής των διακοπών [60].

Μια από τις πιο συχνά χρησιμοποιούμενες προσεγγίσεις για την εκτίμηση της κυκλοφορίας είναι τα δεδομένα εισιτηρίων διοδίων (toll ticket data) που συλλέγονται από συστήματα ηλεκτρονικής συλλογής διοδίων (ΗΣΔ - electronic toll collection) [65] και χειροκίνητης συλλογής διοδίων (ΧΣΔ - manual toll collection), τα οποία χρησιμοποιούνται εκτενώς σε αυτοκινητοδρόμους, οδούς ταχείας κυκλοφορίας και γέφυρες μεταξύ διαφορετικών περιοχών (Σχήμα 1.2). Τα συστήματα ΗΣΔ αποτελούν από μόνα τους μια πολύ γνωστή εφαρμογή των ΕΣΜ, καθώς εξαλείφουν την καθυστέρηση και ενισχύουν την αποτελεσματικότητα της είσπραξης διοδίων. Η χρήση των δεδομένων των εισιτηρίων διοδίων διευκολύνει την οικονομικά αποδοτική και ευρέως διαδεδομένη εκτίμηση της κυκλοφορίας. Συμπληρωματικά δεδομένα, όπως πληροφορίες καιρού και ημερολογιακών στοιχείων μπορούν επίσης να χρησιμοποιηθούν για την εκτίμηση και πρόβλεψη της κυκλοφορίας [42].

Στη βιβλιογραφία έχουν μελετηθεί τόσο βραχυπρόθεσμα όσο και μακροπρόθεσμα προβλήματα πρόβλεψης της κυκλοφορίας για διάφορα μέσα μεταφοράς. Η παρούσα διπλωματική εργασία ασχολείται συγκεκριμένα με το πρόβλημα της μακροπρόθεσμης πρόβλεψης της κυκλοφορίας με τεχνικές βαθιάς μάθησης. Λόγω του μεγάλου όγκου δεδομένων που παρουσιάζει υψηλή διαστατικότητα, καθώς και των πολλαπλών δυναμικών που σχετίζονται με τη συγκεκριμένη εργασία, όπως τα τροχαία ατυχήματα, το πρόβλημα της πρόβλεψης της κυκλοφορίας θεωρείται ένα ιδιαίτερα απαιτητικό πρόβλημα πρόβλεψης χρονοσειρών. Αυτό οφείλεται επίσης στο γεγονός ότι η κατάσταση της κυκλοφορίας σε μια συγκεκριμένη τοποθεσία έχει τόσο χωρικές όσο και χρονικές εξαρτήσεις, οι οποίες μπορεί να επηρεάζονται από κοντινές περιοχές και εποχιακές αλλαγές, αντίστοιχα.



Σχήμα 1.2: Υποδομή και βασικά στοιχεία ενός Ευφυούς Συστήματος Διαχείρισης Αυτοκινητόδρομων σε σταθμούς διοδίων (Πηγή: [48])

Διάφορες μέθοδοι έχουν προταθεί για την πρόβλεψη της κυκλοφορίας, συμπεριλαμβανομένων στατιστικών μοντέλων, μοντέλων μηχανικής μάθησης και υβριδικών μοντέλων που συνδυάζουν και τις δύο προσεγγίσεις. Τα στατιστικά μοντέλα βασίζονται σε ιστορικά δεδομένα κυκλοφορίας και χρησιμοποιούν παραμετρικές τεχνικές ανάλυσης χρονοσειρών για να κάνουν προβλέψεις [95, 91, 77, 94, 16, 31]. Αυτά τα μοντέλα έχουν χρησιμοποιηθεί ευρέως στην έρευνα για τις μεταφορές και τη διαχείριση της κυκλοφορίας [37] και έχουν αποδειχθεί αποτελεσματικά στη βραχυπρόθεσμη πρόβλεψη της κυκλοφορίας [73]. Ωστόσο, ενδέχεται να μην αποτυπώνουν τις πολύπλοκες σχέσεις μεταξύ των διαφόρων μεταβλητών και να μην είναι κατάλληλα για μακροπρόθεσμη πρόβλεψη. Ειδικότερα, τα γραμμικά στατιστικά μοντέλα χρονοσειρών, όπως λ.χ. τα μοντέλα αυτόματης παλινδρόμησης και ολοκληρωμένου κινητού μέσου όρου (ARIMA), δεν μπορούν να χειριστούν τέτοιες χωροχρονικές εξαρτήσεις σε προβλήματα πρόβλεψης χρονοσειρών [42]. Προς την κατεύθυνση αυτή έχουν εισαχθεί ποικίλλες τεχνικές μηχανικής μάθησης (ML) και βαθιάς μάθησης με σκοπό τη βελτίωση της ακρίβειας πρόβλεψης, όπως τα μοντέλα μηχανών διανυσμάτων υποστήριξης [20, 84], αναδρομικών νευρωνικών δικτύων [6] και συνελκτικών νευρωνικών δικτύων [43]. Τα τελευταία χρόνια, η χρήση των μοντέλων βαθιάς μάθησης, ιδίως των μοντέλων μετασχηματιστών, έχει δώσει ικανοποιητικά δείγματα γραφής για τη βελτίωση της ακρίβειας της πρόβλεψης χρονοσειρών. Ωστόσο, λόγω της έλλειψης συνόλων δεδομένων κυκλοφοριακής ροής, δεν είναι ακόμη προφανές εάν τα μοντέλα μετασχηματιστών θα μπορούσαν δυνητικά να ξεπεράσουν τα υπάρχοντα μοντέλα κυκλοφοριακής ροής και λίγη έρευνα έχει γίνει σχετικά με την εφαρμοσιμότητα των μετασχηματιστών στην πρόβλεψη της κυκλοφορίας σε πραγματικές εφαρμογές. Ακόμα και αν ένα

μοντέλο έχει καλές επιδόσεις όσον αφορά τις μετρικές αξιολόγησης, σε πραγματικές εφαρμογές οι συνθήκες είναι διαφορετικές και το ίδιο μοντέλο μπορεί να αδυνατεί να ανταποκριθεί στις απαιτήσεις των ενδιαφερομένων φορέων. Οι μετρικές αξιολόγησης είναι καλές για την εύρεση μιας καλής αρχιτεκτονικής μοντέλου, αλλά η αξιολόγηση με συγκρίσεις και γραφικά αποτελέσματα σε προβλήματα του πραγματικού κόσμου μπορεί να βοηθήσει να διαπιστωθεί αν το μοντέλο είναι όντως κατάλληλο για την εργασία για την οποία έχει σχεδιαστεί

Υπό το πρίσμα των ανωτέρω, ο πρωταρχικός στόχος της παρούσας διατριβής είναι η ανάπτυξη και αξιολόγηση ενός μοντέλου μετασχηματιστή για την πρόβλεψη του κυκλοφοριακού φόρτου, που να μπορεί να αποτελέσει μέρος ενός ΕΣΜ και να παρέχει ακριβείς και συγκεκριμένες προβλέψεις στους εθνικούς αυτοκινητόδρομους της Ελλάδας. Συγκεκριμένα, για την παρούσα διπλωματική εργασία συλλέχθηκαν και αξιοποιήθηκαν δεδομένα από τα συστήματα ΗΣΔ και ΧΣΔ του αυτοκινητόδρομου της Ολυμπίας Οδού στην Ελλάδα για την εκτίμηση και πρόβλεψη της κυκλοφορίας. Το συγκοινωνιακό δίκτυο της Ολυμπίας Οδού στην Ελλάδα αποτελεί κρίσιμο τμήμα της υποδομής της χώρας, καθώς λειτουργεί ως σημαντικός κόμβος μεταφορών για εργαζόμενους και επαγγελματίες οδηγούς, μετακινούμενους και τουρίστες. Η ακριβής πρόβλεψη του όγκου της κυκλοφορίας στα διόδια αυτού του δικτύου είναι απαραίτητη για την αποτελεσματική διαχείριση της κυκλοφορίας και την ανάπτυξη των υποδομών για την Ολυμπία Οδό, τον προγραμματισμό των διαδρομών και την αποφυγή της κυκλοφοριακής συμφόρησης.

## 1.2 Στόχοι και συνεισφορές της εργασίας

Στην ενότητα αυτή περιγράφονται οι κύριες συνεισφορές και στόχοι της παρούσας εργασίας. Καταρχήν παρέχεται μια εμπεριστατωμένη παρουσίαση των βασικών εννοιών της ανάλυσης και της πρόβλεψης χρονοσειρών, παράλληλα με μια λεπτομερή περιγραφή των χρονοσειρών με έμφαση στην αρχιτεκτονική των μοντέλων μετασχηματιστή. Στη συνέχεια αξιολογείται η αποτελεσματικότητα και η ακρίβεια των μοντέλων μετασχηματιστή για την πρόβλεψη της κυκλοφορίας σε πραγματικά δεδομένα στους σταθμούς διοδίων της Ολυμπίας Οδού στην Ελλάδα, ειδικά κατά τις περιόδους αιχμής και τις μαζικές αναχωρήσεις των εορτών, όπως τα Χριστούγεννα, η Καθαρά Δευτέρα, το Πάσχα και οι εθνικές εορτές. Η αξιολόγηση περιλαμβάνει τη σύγκριση διαφορετικών αρχιτεκτονικών μετασχηματιστών για να καταδειχθούν τα πιθανά πλεονεκτήματα και οι περιορισμοί τους. Επίσης, παρουσιάζεται ένα ΕΣΜ που ενσωματώνει μοντέλα μετασχηματιστών και δεδομένα κυκλοφορίας σε πραγματικό χρόνο για τη βελτίωση της διαχείρισης της κυκλοφορίας και την ανάπτυξη των υποδομών στο δίκτυο διοδίων της Ολυμπίας Οδού.

Αναλυτικότερα στην παρούσα διατριβή αναπτύσσεται ένα τμήμα της αρχιτεκτονικής ενός ΕΣΜ, το οποίο αποτελείται από μια βάση δεδομένων MySQL [93] στην οποία αποθηκεύονται δεδομένα από τα διόδια της Ολυμπίας Οδού μέσω μιας διαδικασίας Extract-Transform-Load και μια βάση δεδομένων χρονοσειρών InfluxDB [72], η οποία χρησιμοποιείται για την αποθήκευση των χρήσιμων δεδομένων και αποτελεσμάτων σε «κάδους» ώστε στη συνέχεια να είναι εφικτή και εύκολη η οπτικοποίηση τους στο Grafana [15], το οποίο είναι ένα εργαλείο

οπτικοποίησης χρονοσειρών σε γραφήματα. Το ΕΣΜ περιλαμβάνει επίσης μια προγραμματιστική διεπαφή που επιστρέφει προβλέψεις από τα εκπαιδευμένα μοντέλα βαθιάς μάθησης, στη συγκεκριμένη περίπτωση από μοντέλα μετασχηματιστών. Η εκπαίδευση, η αξιολόγηση και η δοκιμή των μοντέλων πραγματοποιούνται σε έναν διακομιστή, στον οποίο εκτελείται και η εν λόγω προγραμματιστική διεπαφή. Η παρούσα εργασία θα διερευνήσει τα πλεονεκτήματα και τους περιορισμούς των μετασχηματιστών στην πρόβλεψη της κυκλοφορίας σε αυτό το κρίσιμο συγκοινωνιακό δίκτυο της Ελλάδας και θα αξιολογήσει την ικανότητά τους να χειρίζονται ελλιπή και ακανόνιστα δεδομένα, να καταγράφουν μακροπρόθεσμες εξαρτήσεις και να βελτιώνουν την ακρίβεια των προβλέψεων. Η προτεινόμενη έρευνα θα έχει μεγάλο ενδιαφέρον για τους σχεδιαστές μεταφορών, τους μηχανικούς και τους υπεύθυνους χάραξης πολιτικής, καθώς και για τους μετακινούμενους και άλλους χρήστες του δικτύου της Ολυμπίας Οδού. Με τη βελτίωση της ακρίβειας και της αποτελεσματικότητας της πρόβλεψης της κυκλοφορίας σε αυτό το δίκτυο, η έρευνα θα μπορούσε τελικά να οδηγήσει σε βελτιωμένη ασφάλεια, μείωση των χρόνων ταξιδιού, αποτελεσματικότερη διαχείριση της κυκλοφορίας και ανάπτυξη νέων υποδομών.

Οι κύριες συνεισφορές της συγκεκριμένης έρευνας συνοψίζονται στα παρακάτω σημεία

- Ολοκληρωμένη ανάλυση δεδομένων για το σύνολο δεδομένων των διοδίων, που παρέχει βασικές γνώσεις οι οποίες μπορούν να τροφοδοτήσουν τη μελλοντική έρευνα στον τομέα της ανάλυσης και της πρόβλεψης της κυκλοφορίας.
- Σχεδιασμός και υλοποίηση μιας προγραμματιστικής διεπαφής τόσο για την παροχή προβλέψεων από εκπαιδευμένα μοντέλα, όσο και για την εκπαίδευση, την προσαρμογή, την αξιολόγηση και τη τελική δοκιμή τους.
- Ανάπτυξη ενός ΕΣΜ το οποίο μπορεί να χρησιμοποιηθεί για την υποστήριξη των κέντρων ελέγχου κυκλοφορίας στην αποτελεσματική διαχείριση των οδικών δικτύων με συστηματική κατανομή των πόρων.
- Αξιολόγηση της επίδρασης διαφόρων παραγόντων στον κυκλοφοριακό φόρτο, όπως η ημέρα της εβδομάδας, η ώρα της ημέρας, οι αργίες και η θέση των διοδίων και διερεύνηση της πιθανής χρήσης τους για τη βελτίωση της ακρίβειας της πρόβλεψης της κυκλοφορίας.
- Προσαρμογή και αξιολόγηση της επίδρασης διαφορετικών υπερπαραμέτρων στην απόδοση του μοντέλου μετασχηματιστή, συμπεριλαμβανομένου του αριθμού των στρωμάτων, των κεφαλών προσοχής, των διαστάσεων, των επιπέδων τροφοδότησης και άλλων.
- Δημιουργία μιας προσαρμοσμένης συνάρτησης κόστους με σκοπό την ικανοποίηση των απαιτήσεων της συγκεκριμένης εφαρμογής.
- Συμβολή στον τομέα της ανάλυσης χρονοσειρών με την παροχή λεπτομερούς μελέτης των μοντέλων μετασχηματιστή και της αρχιτεκτονικής τους, προκειμένου να κατανοηθούν τα κίνητρα και η σύνδεση με τα παραδοσιακά μοντέλα χρονοσειρών.
- Λεπτομερής περιγραφή μελλοντικής έρευνας στον τομέα της πρόβλεψης χρονοσειρών με βάση τους μετασχηματιστές.



## 1.3 Διάρθρωση της Διπλωματικής Εργασίας

Η διατριβή οργανώνεται ως εξής:

- **Κεφάλαιο 1: Εισαγωγή** - Σύντομη επισκόπηση του ερευνητικού προβλήματος, των κινήτρων, των στόχων και της συνεισφοράς της διατριβής.
- **Κεφάλαιο 2: Πρόβλεψη χρονοσειρών** - Επισκόπηση της σχετικής βιβλιογραφίας σχετικά με τα μοντέλα στατιστικής και βαθιάς μάθησης για την πρόβλεψη χρονοσειρών, συμπεριλαμβανομένης μιας εμπειριστατωμένης μελέτης για τα μοντέλα μετασχηματιστών και την αρχιτεκτονική τους.
- **Κεφάλαιο 3: Δίκτυα Μετασχηματιστών** - Θεωρητική παρουσίαση και επεξήγηση της αρχιτεκτονικής των μετασχηματιστών και των μηχανισμών τους, με ιδιαίτερη έμφαση στο μηχανισμό προσοχής.
- **Κεφάλαιο 4: Δεδομένα και Αρχιτεκτονική Συστήματος** - Λεπτομερείς πληροφορίες σχετικά με το σύνολο δεδομένων που χρησιμοποιήθηκε στα πειράματα, την προεπεξεργασία και την ανάλυση των δεδομένων και την περιγραφή της αρχιτεκτονικής του συστήματος που σχεδιάστηκε και υλοποιήθηκε στην παρούσα διατριβή.
- **Κεφάλαιο 5: Μοντέλα Μετασχηματιστών** - Μια ολοκληρωμένη ανασκόπηση των μοντέλων που βασίζονται σε μετασχηματιστές για την πρόβλεψη χρονοσειρών, συμπεριλαμβανομένων των Transformer, Informer, FEDFormer και ETSFormer.
- **Κεφάλαιο 6: Πειράματα και λεπτομέρειες εφαρμογής** - Λεπτομέρειες της πειραματικής διάταξης, των τροποποιήσεων που έγιναν στις αρχιτεκτονικές μετασχηματιστών και λεπτομέρειες υλοποίησης του προτεινόμενου πλαισίου.
- **Κεφάλαιο 7: Αποτελέσματα** - Λεπτομερής ανάλυση και σύγκριση των αποτελεσμάτων που προέκυψαν από τα πειράματα που πραγματοποιήθηκαν στο Κεφάλαιο 6.
- **Κεφάλαιο 8: Συμπεράσματα** - Μια σύνοψη των συνεισφορών της διατριβής, των περιορισμών και των συστάσεων για μελλοντική εργασία.



## Κεφάλαιο 2


# Πρόβλεψη χρονοσειρών

### 2.1 Χρονοσειρές

Μια χρονοσειρά  $X$  ορίζεται ως ένα σύνολο σημείων δεδομένων  $X_{t_1}, X_{t_2}, \dots, X_{t_n}$  που παρατηρούνται διαδοχικά στο χρόνο, δηλαδή  $t_1 < t_2 < \dots < t_n$  [11]. Κάθε παρατηρούμενο σημείο  $X_t$  εμφανίζεται σε κάποια χρονική στιγμή  $t$ , η οποία ανήκει στο σύνολο των επιτρεπόμενων χρονικών σημείων,  $T$ . Οι χρονοσειρές μπορεί να είναι είτε διακριτές, όπως απεικονίζεται στο Σχήμα 2.1, στην περίπτωση που το  $T$  είναι ένα διακριτό σύνολο, είτε συνεχείς, όταν οι παρατηρήσεις καταγράφονται συνεχώς σε ένα κλειστό χρονικό διάστημα, π.χ. όταν  $T = [0, 1]$ . Οι διακριτές χρονοσειρές μπορούν να προκύψουν με δεδομένη μια συνεχή χρονοσειρά με την ψηφιοποίηση των τιμών της σε ίσα χρονικά διαστήματα. Αυτός ο τύπος διακριτής χρονοσειράς ονομάζεται *δειγματοληπτική σειρά*. Γενικά, οι χρονοσειρές μπορεί να είναι *μονομεταβλητές*, όπου υπάρχει μόνο μία μεταβλητή ενδιαφέροντος (μεταβλητή-στόχος), ή *πολυμεταβλητές*, όπου υπάρχουν πολλές μεταβλητές [17].

Μια χρονοσειρά μπορεί να αναλυθεί σε τέσσερις κύριες συνιστώσες [44, 58, 24], καθεμία από τις οποίες συμβάλλει στη συνολική συμπεριφορά της:

- **Τάση ( $T_t$ ):** η μακροπρόθεσμη τάση, αύξηση (*ανοδική τάση*) ή μείωση (*καθοδική τάση*) στις τιμές των παρατηρούμενων δεδομένων.
- **Εποχικότητα ( $S_t$ ):** οι τακτικές, περιοδικές διακυμάνσεις που συμβαίνουν σε ένα γνωστό και σταθερό χρονικό διάστημα, συνήθως εντός ενός έτους, δηλ. μοτίβα που επαναλαμβάνονται μηνιαία, εβδομαδιαία, ημερήσια κ.λπ.
- **Κυκλικότητα ( $C_t$ ):** τα επαναλαμβανόμενα μοτίβα που ΔΕΝ είναι σταθερής χρονικής περιόδου.
- **Αντικανονικότητα ( $I_t$ ):** οι υπολειμματικές μεταβολές των παρατηρούμενων τιμών που δεν μπορούν να αποδοθούν σε καμία από τις παραπάνω συνιστώσες, δηλαδή οι τυχαίες διακυμάνσεις ή ο θόρυβος.



Σχήμα 2.1: Ένα παράδειγμα διακριτής μονομεταβλητής χρονοσειράς που δείχνει τον όγκο κυκλοφορίας στα διόδια ενός αυτοκινητοδρόμου στην Ελλάδα.

Η χρονοσειρά μπορεί στη συνέχεια να εκφραστεί ως σύνθεση συνιστωσών<sup>1</sup>, ανάλογα με τη μέθοδο αποσύνθεσης που χρησιμοποιείται. Υπάρχουν τρεις, συνήθως χρησιμοποιούμενοι, τύποι μεθόδων αποσύνθεσης [24]:

1. **Αθροιστική μέθοδος**, η οποία ορίζεται ως εξής:

$$X_t = T_t + S_t + C_t + I_t \quad (2.1)$$

όπου  $X_t$  αντιπροσωπεύει την πραγματική τιμή του σημείου στο  $t$  και  $T_t, S_t, C_t, I_t$  αναφέρονται στις τέσσερις κύριες συνιστώσες που παρουσιάστηκαν προηγουμένως.

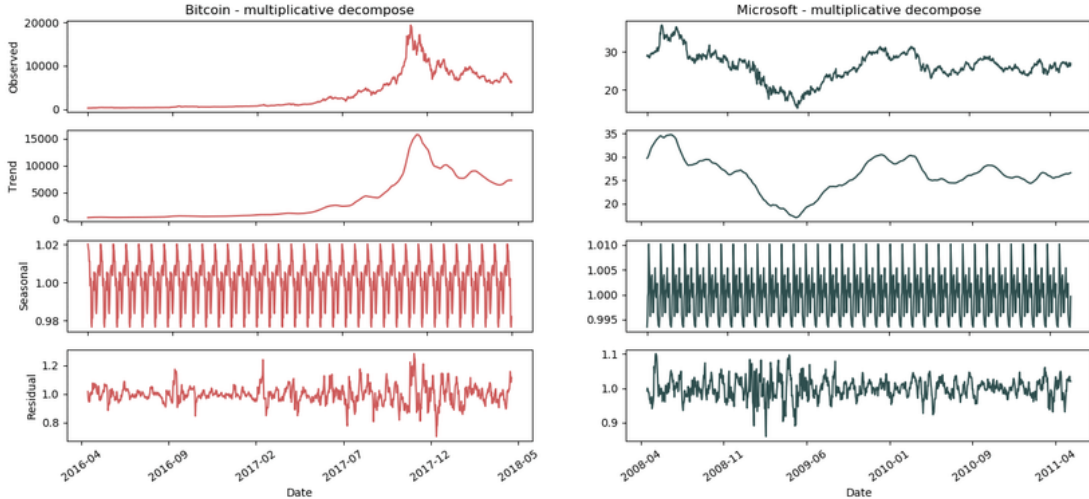
2. **Πολλαπλασιαστική μέθοδος**, η οποία ορίζεται ως εξής:

$$Y_t = T_t \times S_t \times C_t \times I_t \quad (2.2)$$

όπου  $Y_t$  αντιπροσωπεύει την πραγματική τιμή του σημείου στο  $t$  και  $T_t, S_t, C_t, I_t$  αναφέρονται στις τέσσερις κύριες συνιστώσες που παρουσιάστηκαν προηγουμένως. Ένα παράδειγμα της πολλαπλασιαστικής μεθόδου απεικονίζεται στο Σχήμα 2.2.

3. **Υβριδική μέθοδος**, δηλαδή συνδυασμός των δύο προηγούμενων μεθόδων.

<sup>1</sup>Όταν εφαρμόζεται μια μέθοδος αποσύνθεσης, οι συνιστώσες της τάσης και της κυκλικότητας συνήθως συνδυάζονται σε μια ενιαία συνιστώσα, η οποία μερικές φορές ονομάζεται απλώς τάση για λόγους απλότητας.



Σχήμα 2.2: Πολλαπλασιαστική αποσύνθεση των χρονοσειρών Bitcoin και Microsoft (Πηγή: [87])

Η πρόβλεψη χρονοσειράς είναι η πρόβλεψη των μελλοντικών τιμών μιας χρονοσειριακής μεταβλητής-στόχου  $y_t$ , τη χρονική στιγμή  $t$ , με βάση τις ιστορικές παρατηρήσεις της [50]. Χωρίς βλάβη της γενικότητας, στην παρούσα διατριβή εστιάζουμε στη μονομεταβλητή πρόβλεψη (δηλαδή σε μονοδιάστατες μεταβλητές-στόχους), αλλά οι ίδιες μέθοδοι μπορούν να επεκταθούν σε πολυμεταβλητά μοντέλα. Στη γενική περίπτωση της πρόβλεψης πολλαπλών βημάτων, τα μοντέλα έχουν τη μορφή της Εξίσωσης 2.3

$$\hat{y}_{t+1:t+f} = f(y_{t-h:t}, x_{t-h:t}, s) \quad (2.3)$$

όπου:

- $\hat{y}_{t+1:t+f} = \{\hat{y}_{t-h}, \dots, \hat{y}_t\}$ : οι προβλεπόμενες τιμές για τον ορίζοντα πρόβλεψης  $f$
- $y_{t-h:t} = \{y_{t-h}, \dots, y_t\}$ : παρατηρήσεις της μεταβλητής-στόχου σε ένα παράθυρο αναδρομής  $h$
- $x_{t-h:t} = \{x_{t-h}, \dots, x_t\}$ : εξωγενής εισροή σε ένα παράθυρο αναδρομής  $h$
- $s$ : στατικά μεταδεδομένα, π.χ. θέση αισθητήρα
- $f(\cdot)$ : η συνάρτηση πρόβλεψης που μαθαίνει το μοντέλο

Όπως εκφράζεται με την παραπάνω μορφή, το παράθυρο αναδρομής  $h$  είναι ο αριθμός των παρελθοντικών παρατηρήσεων που χρησιμοποιούνται για την εκπαίδευση του μοντέλου, που συνήθως αναπαρίσταται ως υποσύνολο της πλήρους χρονοσειράς. Από την άλλη πλευρά, ο ορίζοντας πρόβλεψης  $f$  είναι ο αριθμός των μελλοντικών παρατηρήσεων που πρέπει να προβλεφθούν, ξεκινώντας από το τέλος του παραθύρου αναδρομής [17], δηλαδή,  $y_{h+1:h+f} = y_{h+1}, \dots, y_{h+f}$ . Το πρόβλημα πρόβλεψης χρονοσειρών μπορεί επομένως να οριστεί ως η εύρεση μιας συνάρτησης  $f$  που αντιστοιχίζει τις τιμές εντός του παραθύρου αναδρομής  $y_{t-h:t}$  στον ορίζοντα πρόβλεψης  $y_{t+1:t+f}$ .

Η πρόβλεψη *πολλαπλών οριζόντων* αναφέρεται στην πρόβλεψη μελλοντικών τιμών για πολλαπλά μελλοντικά χρονικά βήματα. Στο πλαίσιο της πρόβλεψης χρονοσειρών, τα μοντέλα *πολλαπλών οριζόντων* μπορούν να ταξινομηθούν γενικά σε δύο κατηγορίες [104, 50, 82]:

1. **Επαναληπτικές μέθοδοι:** Στις επαναληπτικές μεθόδους, το μοντέλο πρόβλεψης προβλέπει ένα χρονικό βήμα προς τα εμπρός κάθε φορά και στη συνέχεια χρησιμοποιεί τις δικές του προβλέψεις ως είσοδο για να δημιουργήσει την επόμενη πρόβλεψη. Η διαδικασία αυτή επαναλαμβάνεται μέχρι να επιτευχθεί ο επιθυμητός ορίζοντας. Οι επαναληπτικές μέθοδοι είναι υπολογιστικά αποδοτικές και εύκολες στην εφαρμογή τους, αλλά μπορεί να υποφέρουν από σύνθετα σφάλματα που συσσωρεύονται με την πάροδο του χρόνου.
2. **Άμεσες μέθοδοι:** Στις άμεσες μεθόδους, το μοντέλο πρόβλεψης προβλέπει άμεσα όλα τα μελλοντικά χρονικά βήματα ταυτόχρονα, δεδομένων των διαθέσιμων πληροφοριών εισόδου. Οι άμεσες μέθοδοι είναι πιο ακριβείς από τις επαναληπτικές μεθόδους, καθώς λαμβάνουν υπόψη τις εξαρτήσεις μεταξύ των διαφόρων μελλοντικών χρονικών βημάτων. Ωστόσο, οι άμεσες μέθοδοι μπορεί να είναι υπολογιστικά κοστοβόρες και απαιτούν περισσότερα δεδομένα εκπαίδευσης σε σύγκριση με τις επαναληπτικές μεθόδους.

Η ανάλυση χρονοσειρών περιλαμβάνει δύο κύριες μεθόδους: την ανάλυση στο πεδίο του χρόνου και την ανάλυση στο πεδίο της *συχνότητας* [94]. Η πρώτη χαρακτηρίζει τις χρονοσειρές δεδομένων χρησιμοποιώντας τους ίδιους όρους με τους οποίους παρατηρούνται, και ως εκ τούτου λειτουργεί στον ίδιο χώρο με τα δεδομένα. Η ανάλυση στο πεδίο του χρόνου μπορεί να περιλαμβάνει τη χρήση μαθηματικών μεθόδων, όπως οι κινητοί μέσοι όροι και οι μέθοδοι εκτίμησης απλών και βηματικών τάσεων. Επιπλέον, μπορεί να γίνει χρήση γραφημάτων, όπως το γράφημα χρονοσειρών ή γραφήματα που απεικονίζουν την αυτοσυσχέτιση των δεδομένων.

Από την άλλη πλευρά, η ανάλυση στο πεδίο της συχνότητας αναφέρεται στη μελέτη της συμπεριφοράς μιας χρονοσειράς με μεθόδους μετασχηματισμού, όπως ο μετασχηματισμός Fourier. Ειδικότερα, ο μετασχηματισμός Fourier αναλύει μια χρονοσειρά σε συνιστώσες συχνότητας που αντιπροσωπεύονται από συναρτήσεις ημιτόνου και συνημιτόνου, οι οποίες αναπαριστούν το ποσοστό της συνολικής διακύμανσης της χρονοσειράς που εξηγείται από κάθε συχνότητα. Οι υψηλές συχνότητες αντιστοιχούν σε ταχείες αλλαγές στη χρονοσειρά, ενώ οι χαμηλές συχνότητες αντιστοιχούν σε βραδείες.

Με την ανάλυση στο πεδίο της συχνότητας, δύναται να εντοπιστούν επαναλαμβανόμενα μοτίβα ή τάσεις που σχετίζονται με συγκεκριμένες συχνότητες στη χρονοσειρά. Η ανάλυση στο πεδίο της συχνότητας μπορεί επίσης να βοηθήσει στην απομάκρυνση του παρεμβατικού θορύβου στη χρονοσειρά, καθώς μπορεί να αποκλείσει συχνότητες που είναι ασυνήθιστες για το συγκεκριμένο σήμα. Αν και αυτή η προσέγγιση μπορεί να φαίνεται αντισυμβατική, χρησιμοποιείται συχνά για την ανάλυση χρονοσειρών και αρκετά μοντέλα χρονοσειρών μετασχηματιστή έχουν ήδη χρησιμοποιήσει αυτή την προσέγγιση ανάλυσης [97, 105, 96].

## 2.2 Πρόβλεψη χρονοσειρών

Η ανάλυση και η πρόβλεψη χρονοσειρών έχουν ήδη τύχει ευρείας εφαρμογής στην κάλυψη τόσο επιχειρηματικών όσο και βιομηχανικών αποφάσεων. Τα μοντέλα που χρησιμοποιούνται για τη σύλληψη των χρονολογικών σειρών μπορούν να χωριστούν σε δύο βασικές κατηγορίες: τα στατιστικά μοντέλα και τα μοντέλα μηχανικής & βαθιάς μάθησης. Στο παρελθόν, η πλειονότητα της βιβλιογραφίας για την πρόβλεψη χρονοσειρών στηριζόταν σε μεγάλο βαθμό στα πρώτα. Τα τελευταία χρόνια, έχουν προταθεί βαθιά νευρωνικά δίκτυα, ιδίως αναδρομικά νευρωνικά δίκτυα και νευρωνικά δίκτυα μετασχηματιστών, ικανά να χειρίζονται δεδομένα χρονοσειρών, για την πραγματοποίηση προβλέψεων οδηγούμενων από τα δεδομένα.

### 2.2.1 Στατιστικά Μοντέλα

Τα παραδοσιακά στατιστικά μοντέλα [95, 91, 77, 94, 16, 32] έχουν χρησιμοποιηθεί ευρέως για εργασίες πρόβλεψης χρονοσειρών λόγω της απλότητας και της αποτελεσματικότητάς τους σε σύγκριση με τα μοντέλα μηχανικής & βαθιάς μάθησης. Τα μοντέλα αυτά βασίζονται σε καθιερωμένες στατιστικές μεθοδολογίες, οι οποίες διακρίνονται για την εύκολη εφαρμογή και ερμηνεία τους. Τα στατιστικά μοντέλα μπορούν να διακριθούν σε γραμμικά και μη γραμμικά<sup>2</sup>.

Δύο βασικά γραμμικά μοντέλα είναι τα μοντέλα αυτοπαλινδρόμησης (AutoRegressive - AR) και ο κινητός μέσος όρος (Moving Average - MA). Όσον αφορά τα μοντέλα AR, ο όρος αυτοπαλινδρόμηση υποδηλώνει ότι πρόκειται για παλινδρόμηση της μεταβλητής έναντι του εαυτού της. Έτσι, σε ένα μοντέλο αυτοπαλινδρόμησης, η τιμή πρόβλεψης  $\hat{y}_t$  με τάξη  $p$  είναι ο γραμμικός συνδυασμός των  $p$  παρελθοντικών τιμών της μεταβλητής ενδιαφέροντος  $y_t$ , δηλαδή  $y_{t-p:t}$ . Στην Εξίσωση 2.4, ο όρος  $\epsilon_t \sim N(0, \sigma^2)$  δηλώνει κάποιο λευκό θόρυβο τη χρονική στιγμή  $t$ ,  $\phi_i \in \mathbb{R}$ , για  $i = 1, \dots, p$ , είναι οι παράμετροι του μοντέλου (ή αλλιώς, βάρη) και  $c \in \mathbb{R}$  είναι μια σταθερά.

$$\hat{y}_{t+1} = \sum_{i=1}^p \phi_i y_{t-i} + \epsilon_t + c \quad (2.4)$$

Σε αντίθεση με το μοντέλο AR του οποίου οι προβλέψεις βασίζονται σε παρελθοντικές τιμές το μοντέλο κινητού μέσου όρου δημιουργεί προβλέψεις με βάση τα παρελθοντικά σφάλματα πρόβλεψης. Έστω  $\epsilon_t \sim N(0, \sigma^2)$  τα σφάλματα πρόβλεψης, που σημαίνει ότι τα  $\epsilon_t$  είναι πανομοιότυπα, ανεξάρτητα κατανομημένα, το καθένα με κανονική κατανομή που έχει μηδενική μέση τιμή και ίδια διακύμανση. Συνεπώς, ένα μοντέλο MA με τάξη  $q$  ορίζεται ως ο γραμμικός συνδυασμός των προηγούμενων  $q$  σφαλμάτων πρόβλεψης (Εξίσωση 2.5):

$$\hat{y}_{t+1} = \mu + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \epsilon_t \quad (2.5)$$

όπου  $\theta_j \in \mathbb{R}$ , για  $j = 1, \dots, q$ , είναι οι παράμετροι του μοντέλου,  $\epsilon_t$  είναι τα σφάλματα πρόβλεψης που μοντελοποιούνται ως λευκός θόρυβος και  $\mu$  είναι η μέση τιμή της χρονοσειράς.

<sup>2</sup>Οι στατιστικές μέθοδοι συνήθως απαιτούν οι χρονοσειρές να είναι στάσιμες, δηλαδή οι ιδιότητες τους να μην μεταβάλλονται με την πάροδο του χρόνου. Άρα οι χρονοσειρές με τάσεις ή/και εποχικότητα θεωρούνται μη-στάσιμες. Με πιο απλά λόγια, μια χρονοσειρά είναι στάσιμη εάν ο μέσος όρος και η διακύμανσή της είναι σταθερές (ανεξάρτητες από το χρόνο- δεν υπάρχει διολίσθηση) για οποιαδήποτε περίοδο.

Πιο σύνθετα στατιστικά μοντέλα μπορούν να σχηματιστούν συνδυάζοντας κατάλληλα τα μοντέλα AR και MA. Ο αυτοπαλίνδρομος κινητός μέσος όρος (Autoregressive Moving Average - ARMA) [68] είναι ένα γνωστό γραμμικό μοντέλο που χρησιμοποιείται συνήθως όταν η χρονοσειρά παρουσιάζει στάσιμη συμπεριφορά. Ένα μοντέλο ARMA τάξης  $p, q$  που συμβολίζεται με  $ARMA(p, q)$ , μπορεί να προκύψει από την προσθήκη των μοντέλων  $MA(p)$  και  $AR(q)$ , όπως φαίνεται στην Εξίσωση 2.6. Ωστόσο, η γραμμικότητα μπορεί να μην είναι πάντα επαρκής για τη μοντελοποίηση μη γραμμικών προτύπων ή εξαρτήσεων στα δεδομένα. Για να αντιμετωπιστεί αυτός ο περιορισμός, έχουν αναπτυχθεί διάφορα μη γραμμικά στατιστικά μοντέλα που μπορούν να χειριστούν και μη στάσιμες χρονοσειρές. Ένα από τα σημαντικότερα μη γραμμικά μοντέλα είναι ο αυτοπαλίνδρομος ολοκληρωμένος κινητός μέσος όρος (Autoregressive Integrated Moving Average - ARIMA) [29], το οποίο είναι μια γενίκευση του ARMA και μια μορφή του μοντέλου Box-Jenkins [9], που περιλαμβάνει μια πρόσθετη ολοκληρωμένη συνιστώσα για να ληφθεί υπόψη η μη στάσιμη συμπεριφορά στη χρονοσειρά. Η ολοκληρωμένη συνιστώσα περιλαμβάνει τη διαφοροποίηση της χρονοσειράς για την εξάλειψη των τάσεων ή της εποχικότητας που μπορεί να υπάρχουν. Αν και οι επιμέρους συνιστώσες του μοντέλου ARIMA (AR, I και MA) περιλαμβάνουν γραμμικούς συνδυασμούς παρελθοντικών τιμών της χρονοσειράς ή παρελθοντικών σφαλμάτων, το μοντέλο στο σύνολό του θεωρείται μη γραμμικό λόγω της επαναληπτικής φύσης της διαδικασίας εκτίμησης των παραμέτρων και του μη γραμμικού μετασχηματισμού που σχετίζεται με τη συνιστώσα της διαφοροποίησης, όπως φαίνεται στην Εξίσωση 2.7.

$$\hat{y}_{t+1} = c + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^q \theta_j e_{t-j} + \epsilon_t \quad (2.6)$$

$$\hat{y}'_{t+1} = c + \sum_{i=1}^p \phi_i y'_{t-i} + \sum_{j=1}^q \theta_j e_{t-j} + \epsilon_t \quad (2.7)$$

Το μοντέλο ARIMA έχει διάφορες παραλλαγές που έχουν προταθεί για την αντιμετώπιση ορισμένων από τους περιορισμούς του, συμπεριλαμβανομένων των αυτοπαλίνδρομου κλασματικού ολοκληρωμένου κινητού μέσου όρου και του εποχικού αυτοπαλίνδρομου ολοκληρωμένου κινητού μέσου όρου [75]. Παρόμοια με τον ARIMA, ο δεύτερος μετασχηματίζει τη χρονοσειρά για να την καταστήσει στάσιμη, εξαλείφοντας την εποχιακή συνιστώσα. Μεταξύ των μη γραμμικών μοντέλων για την πρόβλεψη χρονοσειρών, αξιοσημείωτη είναι η αυτοπαλινδρομική υπό όρους ετεροσκεδαστικότητα (Autoregressive Conditional Heteroskedasticity - ARCH) και οι παραλλαγές της, όπως η γενικευμένη ARCH, η εκθετικά γενικευμένη ARCH, το αυτοπαλίνδρομο μοντέλο κατωφλίου, το μη-γραμμικό αυτοπαλίνδρομο και ο μη-γραμμικά κινούμενος μέσος όρος.

Μια άλλη μη γραμμική μέθοδος που έχει επικρατήσει για την πρόβλεψη χρονολογικών σειρών είναι η εκθετική εξομάλυνση (EE) [31, 41]. Εξομαλύνοντας (αφαιρώντας) τις βραχυπρόθεσμες διακυμάνσεις και εστιάζοντας στην υποκείμενη συνιστώσα τάσης, οι μέθοδοι EE είναι ιδιαίτερα αποτελεσματικές στην καταγραφή της εποχικότητας και των τάσεων στα δεδομένα. Όπως περιγράφεται στη βιβλιογραφία, τα μοντέλα EE χρησιμοποιούν ρητά εκθετικά φθίνοντα βάρη για την παραγωγή προβλέψεων, οι οποίες είναι σταθμισμένοι μέσοι όροι



προηγούμενων παρατηρήσεων. Με απλά λόγια, υψηλότερα βάρη αποδίδονται σε πιο πρόσφατες παρατηρήσεις. Για την πρόβλεψη χρονολογικών σειρών, οι τεχνικές εκθετικής εξομάλυνσης θα μπορούσαν να αποτελέσουν μια βιώσιμη εναλλακτική λύση στα γνωστά μοντέλα Box-Jenkins ARIMA, αλλά τα μοντέλα ΕΕ αναφέρονται συχνά ως μοντέλα ETS, επειδή μοντελοποιούν ρητά το σφάλμα, την τάση και την εποχικότητα (στα αγγλικά, Error, Trend, και Seasonality). Ένα από τα απλούστερα μοντέλα ΕΕ που υπάρχουν είναι το μοντέλο απλής εκθετικής εξομάλυνσης, το οποίο χρησιμοποιείται όταν μια χρονοσειρά δεν έχει σαφή τάση ή εποχικό πρότυπο. Η ταχύτητα εκθετικής αποσύνθεσης ελέγχεται από τη μοναδική υπερπαραμέτρο  $\alpha$ , με  $0 \leq \alpha \leq 1$ , η οποία μπορεί να βελτιστοποιηθεί μέσω ενός βήματος βελτιστοποίησης, όπως η κατάβαση κλίσης. Η απλή εκθετική εξομάλυνση περιγράφεται στις Εξισώσεις 2.8 και 2.9, με την τελευταία εξίσωση να προκύπτει με αναδρομή.

$$\hat{y}_{t+1} = \alpha y_t + (1 - \alpha) \hat{y}_t \quad (2.8)$$

$$\hat{y}_{t+1} = \sum_{i=0}^{\infty} \alpha(1 - \alpha)^i y_{t-i} \quad (2.9)$$

Γενικά, οι τεχνικές εξομάλυνσης χρησιμοποιούνται για την απομάκρυνση του θορύβου ή της αντικανονικότητας από μια χρονοσειρά, καθιστώντας ευκολότερο τον μετέπειτα εντοπισμό της υποκείμενης τάσης και εποχικότητας (ενδεχομένως με άλλο μοντέλο). Ωστόσο, υπάρχουν ορισμένοι πρωταρχικοί περιορισμοί των παραπάνω στατιστικών μοντέλων:

- **Περιορισμένο πεδίο εφαρμογής:** Τα στατιστικά μοντέλα χρησιμοποιούν συνήθως ένα σταθερό σύνολο παραγόντων που προέρχονται από τα πιο πρόσφατα ιστορικά δεδομένα για τη δημιουργία των προβλέψεων. Αυτό μπορεί να οδηγήσει σε δυνητικά ανακριβή αποτελέσματα εάν προκύψουν απρόβλεπτες μεταβλητές ή παράγοντες.
- **Ευαισθησία στην αρχικοποίηση:** Οι στατιστικές μέθοδοι είναι συχνά επαναληπτικές, και τα αποτελέσματα μπορεί να είναι ευαίσθητα και να εξαρτώνται σε μεγάλο βαθμό από την αρχικοποίηση ή τη διαδικασία εκκίνησης. Αυτό μπορεί να οδηγήσει σε ασταθείς ή ασυνεπείς προβλέψεις, ιδίως όταν εφαρμόζονται σε σύνθετα σύνολα δεδομένων.
- **Υπόθεση στασιμότητας:** Η στασιμότητα είναι μια αυστηρή απαίτηση που μπορεί να είναι δύσκολο να εκπληρωθεί, ιδίως για ευμετάβλητες χρονοσειρές. Παρά την αντιμετώπιση ζητημάτων όπως η ολίσθηση, η εποχικότητα, η αυτοσυσχέτιση και η ετεροσκεδαστικότητα, τα στατιστικά μοντέλα μπορεί να εξακολουθούν να δυσκολεύονται να επιτύχουν τη στασιμότητα.

## 2.2.2 Μοντέλα μηχανικής & βαθιάς μάθησης

Από τις αρχές της δεκαετίας του 2000, διάφορα μοντέλα μηχανικής μάθησης έχουν προταθεί για την πρόβλεψη χρονοσειρών, με τις μηχανές διανυσμάτων υποστήριξης (ΜΔΥ) να αποτελούν μία από τις πιο πρώιμες προσεγγίσεις [13, 20]. Υβριδικές προσεγγίσεις που συνδυάζουν ARIMA με ΜΔΥ [61] ή νευρωνικά δίκτυα [100] έχουν επίσης αναπτυχθεί για αυτού του


είδους τις εργασίες. Γενικά, έχει διαπιστωθεί ότι τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ) και τα ΒΝΔ υπερτερούν των παραδοσιακών στατιστικών μεθόδων στην πρόβλεψη χρονοσειρών [75]. Οι προσεγγίσεις βαθιάς μάθησης που είναι καταλληλότερες για αυτό το πρόβλημα περιλαμβάνουν τα αναδρομικά νευρωνικά δίκτυα (ΑΝΔ), τα δίκτυα μακράς βραχύχρονης μνήμης (Long Short-term Memory - LSTM), τις αναδρομικές μονάδες πυλών και τα συνελκτικτικά νευρωνικά δίκτυα (ΣΝΔ).

Οι ερευνητές έχουν συγκρίνει διάφορα μοντέλα σε διάφορες εργασίες για να καταδείξουν την ανώτερη απόδοση των μοντέλων βαθιάς μάθησης. Για παράδειγμα, ο Khedhiri [75] συνέκρινε τον επαχιακός αυτοπαλίνδρομος κλασματικά ολοκληρωμένο κινητό μέσο όρο και το LSTM σε μια εργασία πρόβλεψης θερμοκρασίας και κατέληξε στο συμπέρασμα ότι τα μοντέλα βαθιάς μάθησης είναι πιο κατάλληλα για αυτού του είδους τις εργασίες. Έχει επίσης προταθεί ένα μοντέλο με την ονομασία MTCAN [90], το οποίο ενσωματώνει ένα διευρυμένο ΣΝΔ ως βασική μονάδα, ασύμμετρα υπολειμματικά μπλοκ και ένα δίκτυο αυτο-προσοχής για την ενίσχυση της σύλληψης των σχέσεων χαρτογράφησης σε μη-περιοδικά σύνολα δεδομένων. Ένα άλλο μοντέλο μηχανικής μάθησης που χρησιμοποιεί στοιβαγμένα στρώματα LSTM είναι το DeepAR [70], το οποίο παράγει πιθανοτικές προβλέψεις και εκτιμά την αβεβαιότητα που σχετίζεται με αυτές, χρησιμοποιώντας ένα μοντέλο αυτοπαλινδρομικού αναδρομικού δικτύου. Τα ΑΝΔ έχουν επίσης χρησιμοποιηθεί στη βιβλιογραφία σε αρχιτεκτονικές κωδικοποιητή-αποκωδικοποιητή, σε συνδυασμό με μεταβλητούς αυτοκωδικοποιητές, σε βαθιά μοντέλα καταστάσεων-χώρου και με πολυεπίπεδα *perceptrons* στο μοντέλο multi-horizon quantile recurrent forecaster [34].

Όπως φαίνεται από την παραπάνω περιγραφική επισκόπηση, υπάρχουν πολυάριθμα μοντέλα μηχανικής μάθησης, συμπεριλαμβανομένων των ΜΔΥ, των ΤΝΔ και των αρχιτεκτονικών βαθιάς μάθησης, όπως τα ΑΝΔ, τα LSTM και τα ΣΝΔ. Για το λόγο αυτό, η παρούσα διατριβή δεν θα επικεντρωθεί σε αυτά τα μοντέλα για την πρόβλεψη χρονοσειρών, αλλά θα εξετάσει την υλοποίηση και την πρακτική εφαρμογή μιας νεοεισαχθείσας αρχιτεκτονικής βαθιάς μάθησης βασισμένης στην προσοχή, αυτή των μετασχηματιστών. Προκειμένου να ξεπεραστούν ορισμένοι περιορισμοί και να βελτιωθεί η αποτελεσματικότητα και η τοπικότητα της αρχιτεκτονικής των μετασχηματιστών, ιδίως η σημειακή αντιστοίχιση ερωτήσεων-κλειδιών στον μηχανισμό αυτοπροσοχής [74], πολλοί ερευνητές έχουν προτείνει μοντέλα που βασίζονται στο μοντέλο των μετασχηματιστών και ενσωματώνουν ΣΝΔ για να πραγματοποιήσουν διάφορες εργασίες, συμπεριλαμβανομένης της πρόβλεψης χρονοσειρών. Μια ολοκληρωμένη ανασκόπηση των μοντέλων πρόβλεψης χρονοσειρών που βασίζονται στην αρχιτεκτονική των μετασχηματιστών, εμπνευσμένα από την επιτυχία τους στην όραση υπολογιστών και την επεξεργασία φυσικής γλώσσας, θα παρουσιαστεί στο Κεφάλαιο 5, το οποίο αποτελεί και τον πυρήνα της παρούσας διατριβής.

Γενικά, τα ΒΝΔ αξιοποιούν μια ακολουθία μη γραμμικών επιπέδων προκειμένου να δημιουργήσουν ενδιάμεσες αναπαραστάσεις χαρακτηριστικών, οι οποίες τα βοηθούν να προβλέψουν με ακρίβεια το επιθυμητό αποτέλεσμα. Αυτή η τεχνική παρουσιάστηκε για πρώτη φορά από τους Nal Kalchbrenner και Phil Blunsom το 2013 [45] και είναι γενικά γνωστή ως αρχιτεκτονική κωδικοποιητή-αποκωδικοποιητή (Σχήμα 2.3). Αυτή η αρχιτεκτονική περιλαμ-

βάνει δύο κύρια στοιχεία: τον κωδικοποιητή, ο οποίος αντιστοιχίζει τα δεδομένα εισόδου σε μια λανθάνουσα αναπαράσταση χώρου, και τον αποκωδικοποιητή, ο οποίος χρησιμοποιεί τα κωδικοποιημένα δεδομένα για να παράγει μια έξοδο που αντιστοιχεί στην αρχική είσοδο.



Σχήμα 2.3: Η αρχιτεκτονική του κωδικοποιητή-αποκωδικοποιητή

Για εργασίες πρόβλεψης χρονοσειρών, ο κωδικοποιητής χαρτογραφεί τις σχετικές ιστορικές πληροφορίες σε μια λανθάνουσα μεταβλητή  $\mathbf{z}_t$ , η οποία στη συνέχεια χρησιμοποιείται από τον αποκωδικοποιητή προκειμένου να παραχθεί η τελική πρόβλεψη. Αυτή η γενική προσέγγιση εκφράζεται στις Εξισώσεις 2.10 και 2.11, όπου  $g_{enc}(\cdot)$ ,  $g_{dec}(\cdot)$  είναι οι συναρτήσεις κωδικοποιητή και αποκωδικοποιητή αντίστοιχα.

$$f(y_{t-h:t}, \mathbf{x}_{t-h:t}, \mathbf{s}) = g_{dec}(\mathbf{z}_t) \quad (2.10)$$

$$\mathbf{z}_t = g_{enc}(y_{t-h:t}, \mathbf{x}_{t-h:t}, \mathbf{s}) \quad (2.11)$$

Οι σχέσεις πρόβλεψης που μπορεί να μάθει το μοντέλο καθορίζονται από την αρχιτεκτονική του επιλεγμένου δικτύου. Ο κωδικοποιητής μπορεί να κατασκευαστεί με διάφορους τρόπους, όπως χρησιμοποιώντας *συνελικτικά* ή *αναδρομικά* στρώματα. Οι συνελικτικοί κωδικοποιητές είναι καταλληλότεροι για δεδομένα με μακροπρόθεσμες εξαρτήσεις, ενώ οι αναδρομικοί κωδικοποιητές είναι πιο αποτελεσματικοί για δεδομένα με βραχυπρόθεσμες εξαρτήσεις. Ο αποκωδικοποιητής, από την άλλη πλευρά, είναι υπεύθυνος για τη δημιουργία της τελικής πρόβλεψης από τις κωδικοποιημένες πληροφορίες και μπορεί να κατασκευαστεί χρησιμοποιώντας μόνο πλήρως συνδεδεμένα στρώματα ή σε συνδυασμό με άλλα στρώματα βαθιάς μάθησης για τη δημιουργία ενός πιο σύνθετου δικτύου.

Συνολικά, η αρχιτεκτονική κωδικοποιητή-αποκωδικοποιητή για την πρόβλεψη χρονοσειρών είναι μια ισχυρή προσέγγιση για την εκμάθηση εξαρτήσεων και σχέσεων σε πολύπλοκα χρονικά δεδομένα. Με την επιλογή του κατάλληλου σχεδιασμού και των απαιτούμενων συνιστωσών του δικτύου, τα BND μπορούν να συλλάβουν αποτελεσματικά τα υποκείμενα πρότυπα και τις εξαρτήσεις που παρουσιάζονται στα δεδομένα, με ακριβή και αξιόπιστα αποτελέσματα πρόβλεψης.

## 2.3 Μοντέλα μετασχηματιστών για χρονοσειρές

Αν και αρχικά προτάθηκαν για εφαρμογές επεξεργασίας φυσικής γλώσσας, οι μετασχηματιστές έχουν χρησιμοποιηθεί με επιτυχία για την αντιμετώπιση ενός ευρέως φάσματος εργασιών μηχανικής μάθησης, όπως η ταξινόμηση εικόνων, η ανίχνευση αντικειμένων, η παραγωγή εικόνων και γλωσσών, η ανάλυση πολυτροπικών δεδομένων και η ανάλυση δεδομένων σε πίνακες και χρονοσειρές. Η παρούσα ενότητα παρέχει μια επισκόπηση της προηγούμενης έρευνας

σχετικά με τη χρήση των μετασχηματιστών για την πρόβλεψη χρονοσειρών, η οποία αποτελεί το κύριο ερευνητικό πεδίο αυτής της διατριβής.

Υπάρχουν δύο κύριες κατηγορίες μοντέλων που βασίζονται σε μετασχηματιστές για την πρόβλεψη χρονοσειρών: σε επίπεδο μονάδας και σε επίπεδο αρχιτεκτονικής [92]. Η παρούσα διατριβή θα εξετάσει μόνο την παραλλαγή σε επίπεδο μονάδας, καθώς αντιπροσωπεύει την πλειονότητα των πρόσφατων εργασιών. Σε γενικές γραμμές, αυτές οι παραλλαγές είναι παρόμοιες με την αρχιτεκτονική vanilla Transformer [88], αλλά με μικρές τροποποιήσεις σε ορισμένα μέρη της αρχιτεκτονικής, όπως η μονάδα προσοχής, η μονάδα κανονικοποίησης και η μονάδα ενσωμάτωσης εισόδου. Μεταξύ αυτών, το μεγαλύτερο μέρος της έρευνας έχει επικεντρωθεί στη μονάδα προσοχής, η οποία αποτελεί θεμελιώδες και ιδιαίτερο χαρακτηριστικό της αρχιτεκτονικής των μετασχηματιστών. Αν και έχει διεξαχθεί σχετική έρευνα και για τους άλλους δύο τύπους, δεν θα αναλυθούν περαιτέρω στην παρούσα διατριβή.

Μεταξύ αυτών των παραλλαγών της μονάδας προσοχής, μερικές από τις πιο καινοτόμες προσεγγίσεις περιλαμβάνουν το μοντέλο TimeSformer που προτάθηκε από τους Zhai et al. [7], το οποίο προσαρμόζει την αρχιτεκτονική του μετασχηματιστή για να χειριστεί τη χρονική διάσταση των δεδομένων χρονοσειρών με τη χρήση ενός  $1 - D$  χρονικού μηχανισμού αυτοπροσοχής. Μια άλλη αξιοσημείωτη προσέγγιση είναι το LogTrans [52], ένα μοντέλο μετασχηματιστή που εισάγει αιτιακές συνελίξεις για τη δημιουργία ερωτημάτων και κλειδιών στο επίπεδο προβολής τους και προτείνει την προσοχή LogSparse για τη μείωση της πολυπλοκότητας σε  $\mathcal{O}(L \log L)$ . Το μοντέλο Informer των Zhou et al. [104] επεκτείνει το Transformer εισάγοντας τον μηχανισμό προσοχής ProbSparse, ο οποίος επιλέγει τα κυρίαρχα ερωτήματα με βάση τις ομοιότητες ερωτημάτων και κλειδιών, με αποτέλεσμα η πολυπλοκότητα να είναι παρόμοια με αυτή του LogTrans. Ο Informer βασίζεται στη μέθοδο διάσπασης προσοχής και προς αυτό το σκοπό χρησιμοποιεί τη συνέλιξη για το σταδιακό φιλτράρισμα των στοιχείων που λαμβάνουν χαμηλές βαθμολογίες προσοχής. Η προσέγγιση αυτή βοηθά στο χειρισμό μεγάλων ακολουθιών, καθώς ο αριθμός των εξεταζόμενων στοιχείων μειώνεται σε κάθε επίπεδο του μοντέλου. Τέλος, χρησιμοποιεί έναν αποκωδικοποιητή γεννητικού τύπου για μακροπρόθεσμη πρόβλεψη και την αποφυγή συσσωρευτικών σφαλμάτων. Ο Autoformer [97] εισάγει τον μηχανισμό προσοχής αυτοσυσχέτισης, ο οποίος επικεντρώνεται στην ομοιότητα βάσει υποσειρών και είναι σε θέση να εξάγει περιοδικά μοτίβα. Ωστόσο, αποτυγχάνει να μοντελοποιήσει αποτελεσματικά τις χωρικές πληροφορίες (π.χ. η πρόβλεψη στο  $t + 1$  δεν εξαρτάται από το  $t, t - 1$ , κ.λπ.) και δεν διαχωρίζει τη συνιστώσα τάσης σε συνιστώσες επιπέδου και ανάπτυξης, οι οποίες είναι αμφότερες ζωτικής σημασίας για τη μοντελοποίηση μοτίβων τάσης. Επίσης, το εν λόγω μοντέλο υλοποιείται με βάση μια απλουστευμένη υπόθεση- εκτελεί αποσύνθεση σειράς μέσω ενός απλού κινητού μέσου όρου επί του σήματος εισόδου, ο οποίος δεν επαρκεί για την κατάλληλη μοντελοποίηση σύνθετων προτύπων τάσης. Πιο πρόσφατα, οι Liu et al. πρότειναν το Pyraformer [53], το οποίο χρησιμοποιεί μια ιεραρχική μονάδα πυραμιδικής προσοχής με ένα δυαδικό δέντρο για την καταγραφή των χρονικών εξαρτήσεων διαφορετικών σειρών με γραμμική πολυπλοκότητα χρόνου και μήμης. Οι Zhou et al. πρότειναν επίσης τον FEDformer [105], ο οποίος εφαρμόζει λειτουργίες προσοχής στο πεδίο της συχνότητας με μετασχηματισμούς Fourier και wavelet, επιτυγχάνοντας γραμμική πολυπλοκότητα με τυχαία επιλογή ενός

υποσυνόλου συχνότητας σταθερού μεγέθους. Μια άλλη σημαντική προσέγγιση είναι ο Quatformer [21], ο οποίος υλοποιεί ένα μηχανισμό προσοχής που μαθαίνει να περιστρέφεται με βάση τα quaternions για να επιτρέψει την αναπαράσταση σύνθετων περιοδικών μοτίβων, εισάγοντας πληροφορία σχετικά με τη φάση και την περίοδο της σειράς. Για την επίτευξη γραμμικής πολυπλοκότητας, ο Quatformer χρησιμοποιεί επίσης μια καθολική μνήμη για την αποσύζευξη της περιστρεφόμενης προσοχής. Τέλος, ο ETSformer [96], εμπνευσμένος από τις μεθόδους εκθετικής εξομάλυνσης, προσπαθεί να αντιμετωπίσει τη δυσχέρεια του Autoformer, αποσυνθέτοντας τις σειρές σε εποχικά μοτίβα. Ομοίως με τον FEDFormer, εφαρμόζει λειτουργίες προσοχής στο πεδίο της συχνότητας, εισάγοντας δύο νέες μονάδες προσοχής: την *προσοχή εκθετικής εξομάλυνσης* και την *προσοχή συχνότητας*. Ο ETSFormer διαφοροποιείται από άλλες προσεγγίσεις, καθώς είναι σε θέση να μαθαίνει και να εξάγει αυτόματα εποχικά μοτίβα χωρίς να βασίζεται σε χειροκίνητα σχεδιασμένες, δυναμικά χρονοεξαρτώμενες μεταβλητές.



## Κεφάλαιο 3

# Βαθιά Μάθηση και Μοντέλα Ακολουθίας-σε-Ακολουθία

Η μηχανική μάθηση είναι ένα γνωστικό πεδίο της τεχνητής νοημοσύνης που ασχολείται με την κατανόηση και την ανάπτυξη αλγορίθμων και μεθόδων που επιτρέπουν στα υπολογιστικά συστήματα να εκπαιδεύονται και να βελτιώνονται, βελτιστοποιώντας ένα κριτήριο απόδοσης, από δεδομένα παραδείγματος ή προηγούμενης εμπειρίας, αλλά χωρίς να προγραμματίζονται με ρητό τρόπο [4, 57]. Η συλλογή δεδομένων που χρησιμοποιείται στην εκπαίδευση αλγορίθμων μηχανικής μάθησης ονομάζεται δεδομένα εκπαίδευσης ή παραδείγματα εκπαίδευσης ή σημεία δεδομένων εκπαίδευσης. Το αποτέλεσμα της διαδικασίας εκπαίδευσης είναι συχνά ένα σύνολο δομημένων παραμέτρων, οι οποίες συνδυάζονται για την κατασκευή του μοντέλου της μηχανικής μάθησης. Με άλλα λόγια, ένα μοντέλο μηχανικής μάθησης μπορεί να θεωρηθεί ως μια μαθηματική αναπαράσταση ή μια συνάρτηση που αντιστοιχίζει δεδομένα εισόδου σε δεδομένα εξόδου, με βάση πρότυπα και σχέσεις που μαθαίνονται από τα δεδομένα εκπαίδευσης με την εκτέλεση ενός αλγορίθμου μάθησης. Τα μοντέλα μηχανικής μάθησης μπορούν να χρησιμοποιηθούν σε ένα ευρύ φάσμα εφαρμογών, αλλά η τελική επιλογή εξαρτάται από το συγκεκριμένο πρόβλημα που επιλύεται και τη φύση των δεδομένων που χρησιμοποιούνται [4].


Ένα πολύ ιδιαίτερο είδος μοντέλου μηχανικής μάθησης είναι τα νευρωνικά δίκτυα (ΤΝΔ), τα οποία αποτελούν υποσύνολο της μηχανικής μάθησης και βρίσκονται στην καρδιά των αλγορίθμων βαθιάς μάθησης [38]. Αρχικά εμπνευσμένα από την πολύπλοκη δομή και λειτουργία του ανθρώπινου εγκεφάλου, τα νευρωνικά δίκτυα σχηματίζονται από νευρικά κύτταρα (γνωστά και ως νευρώνες) που συνδέονται σε στρώματα και αλληλεπιδρούν με μη γραμμικές απεικονίσεις. Τα νευρωνικά δίκτυα είναι ικανά να εκτελούν βασικές εργασίες όπως ταξινόμηση, ομαδοποίηση, συγκέντρωση δεδομένων, νοηματοδότηση και πρόβλεψη, γεγονός που εξηγεί την ευελιξία τους και τις εκτεταμένες εφαρμογές τους σε τομείς όπως η αναγνώριση ομιλίας και εικόνας, η επεξεργασία φυσικής γλώσσας, οι χρονοσειρές και η ανάλυση πρόβλεψης.

Από την άλλη πλευρά, η βαθιά μάθηση είναι ένα υποσύνολο της μηχανικής μάθησης, με τον όρο 'βαθιά' να αναφέρεται στο πλήθος των επιπέδων του δικτύου [86], είτε αυτό είναι ένα πολυεπίπεδο perceptron, είτε ένα συνελικτικό νευρωνικό δίκτυο, είτε ένα αναδρομικό νευρωνικό δίκτυο, είτε ένα δίκτυο μακράς βραχυπρόθεσμης μνήμης. Στη σημερινή εποχή, με τη αυξημένη

διαθεσιμότητα και πρόσβαση σε μεγάλες ποσότητες δεδομένων και τα προηγμένα υπολογιστικά συστήματα, τα μοντέλα βαθιάς μάθησης εξελίσσονται με ραγδαίους ρυθμούς. Ωστόσο, η βαθιά μάθηση έχει έναν σημαντικό περιορισμό, την υπολογιστική ισχύ, η οποία περιορίζει τη χρήση της σε πολλές εργασίες. Η υπερπροσαρμογή και ο υπολογιστικός χρόνος είναι κοινές προκλήσεις κατά την εκπαίδευση βαθιών νευρωνικών δικτύων, αλλά έχουν αναπτυχθεί διάφορες τεχνικές κανονικοποίησης για την αντιμετώπιση αυτών των ζητημάτων. Μέθοδοι, όπως το 'κλάδεμα' (pruning), η αποσύνθεση βαρών (weight decay) και η αραιότητα (sparsity), έχουν βελτιώσει τις διαδικασίες βελτιστοποίησης και έχουν βοηθήσει τη βαθιά μάθηση να γίνει ένα πολύτιμο εργαλείο σε διάφορους τομείς.

### 3.1 Νευρωνικά Δίκτυα Πρόσθιας Τροφοδότησης

Ένα ΤΝΔ πρόσθιας τροφοδότησης (ΠΤ) είναι ένας τύπος δικτύου όπου η πληροφορία ρέει προς μία μόνο κατεύθυνση και δεν υπάρχουν επαναλαμβανόμενες συνδέσεις μεταξύ των κόμβων του (πρόσθια τροφοδότηση σημαίνει από την είσοδο προς την έξοδο). Το απλούστερο δίκτυο ΠΤ έχει μόνο έναν κόμβο και ονομάζεται perceptron. Για να σχηματιστεί μια πιο σύνθετη οντότητα, που ονομάζεται επίπεδο (*layer*), πολλά perceptrons στοιβάζονται το ένα πάνω στο άλλο, όπως φαίνεται στο Σχήμα 3.1. Πολλαπλά στρώματα perceptrons (Σχήμα 3.2) που συνδέονται μεταξύ τους σχηματίζουν το γνωστό πολυεπίπεδο Perceptron.

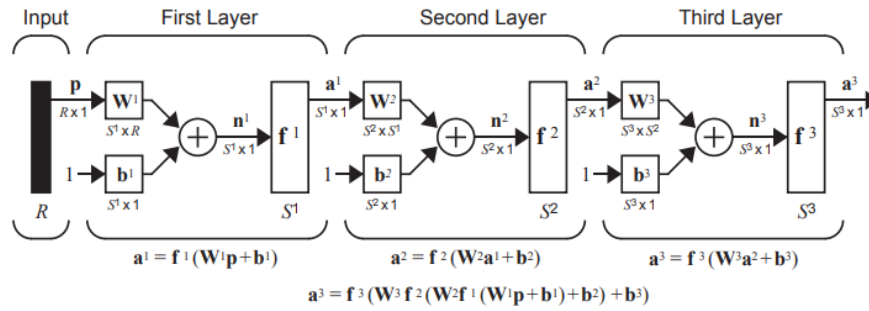


Σχήμα 3.1: Στρώμα από  $S$  Perceptrons με  $R$  εισόδους [81]

Σε ένα πολυστρωματικό perceptron πολλοί νευρώνες συνδυάζονται για να σχηματίσουν ένα στρώμα. Υπάρχουν τρία είδη στρωμάτων: (i) στρώμα εισόδου, (ii) κρυφό στρώμα και (iii) στρώμα εξόδου. Το **στρώμα εισόδου** λαμβάνει τα σήματα εισόδου και τα μεταδίδει στα ανώτερα στρώματα, χωρίς καμία επεξεργασία στις εισόδους. Το **στρώμα εξόδου** είναι το τελικό στρώμα στο δίκτυο, το οποίο παράγει την πρόβλεψη με βάση τα δεδομένα εισόδου. Τα στρώματα που δεν συνδέονται άμεσα με το περιβάλλον ονομάζονται **κρυφά**, και η χρησιμότητά τους είναι να δημιουργούν κρυφές αναπαραστάσεις της εισόδου εφαρμόζοντας μη γραμμικούς μετασχηματισμούς σε κάθε κρυφή μονάδα ακολουθώντας τον *αφινικό μετασχηματισμό*<sup>1</sup>. Οι συνδέσεις μεταξύ των νευρώνων κάθε επιπέδου ονομάζονται **βάρη**, οι οποίες είναι οι κύριες


<sup>1</sup>Ο αφινικός μετασχηματισμός αναφέρεται στον γραμμικό μετασχηματισμό των δεδομένων εισόδου.





Σχήμα 3.2: Πολυστρωματικό Perceptron με ένα στρώμα εισόδου, ένα στρώμα εξόδου (στρώμα 3) και δύο κρυφά στρώματα (στρώματα 1 και 2) [81]

παράμετροι που μαθαίνονται από τη διαδικασία εκπαίδευσης. Το βαθύ δίκτυο ΠΤ αποτελείται από πολλαπλά στρώματα που στοιβάζονται το ένα πάνω στο άλλο για να σχηματίσουν μια ‘βαθιά’ αλυσίδα κρυφών στρωμάτων, όπως φαίνεται στο Σχήμα 3.3β’.



Σχήμα 3.3: Διαφορά μεταξύ ρηχών και βαθιών δικτύων ΠΤ

Πολλαπλά στρώματα στοιβάζονται το ένα πάνω στο άλλο για να σχηματίσουν μια αλυσίδα κρυφών στρωμάτων με το βάθος να καθορίζεται από το πλήθος τους. Η ορολογία ‘βαθιά μάθηση’ προέκυψε από αυτή τη διαδικασία στοιβάγματος, οπότε τα δίκτυα ΠΤ με πολλά κρυφά στρώματα λέγεται ότι είναι βαθιά δίκτυα ΠΤ (Σχήμα 3.3). Ένας συγκεκριμένος τύπος πολυεπίπεδων Perceptron είναι τα πλήρως συνδεδεμένα νευρωνικά δίκτυα, γνωστά και ως πυκνά νευρωνικά δίκτυα, στα οποία κάθε νευρώνας σε ένα στρώμα συνδέεται με όλους τους νευρώνες του επόμενου στρώματος, καθώς και με όλους τους νευρώνες του προηγούμενου στρώματος.

### 3.1.1 Συνελικτικά Νευρωνικά Δίκτυα


Τα συνελικτικά νευρωνικά δίκτυα είναι ένας τύπος βαθιών δικτύων που κάνει χρήση συνελικτικών στρωμάτων, αντί για πλήρως συνδεδεμένων στρωμάτων, για την επεξεργασία δεδομένων που έχουν σχήμα πλέγματος, όπως οι εικόνες. Ως αρχιτεκτονική βαθιάς μάθησης, τα ΣΝΔ αποτελούνται από πολλά στρώματα που στοιβάζονται το ένα πάνω στο άλλο και

υπάρχουν συνήθως τρία είδη αυτών των στρωμάτων (ή δομικών στοιχείων): (i) στρώμα συνέλιξης, (ii) στρώμα υποδειγματοληψίας (iii) πλήρως διασυνδεδεμένο στρώμα. Τα δύο πρώτα είδη επιπέδων (συνέλιξης και υποδειγματοληψίας) χρησιμοποιούνται για την εξαγωγή χαρακτηριστικών, ενώ το τρίτο (πλήρως διασυνδεδεμένο), μαθαίνει τη συσχέτιση μεταξύ εξαγόμενων χαρακτηριστικών και εξόδου (λειτουργία ταξινόμησης).

### 3.1.2 Συνέλιξη

Τα ΣΝΔ, όπως υποδεικνύεται και από την ονομασία τους, χρησιμοποιούν μια διαδικασία που ονομάζεται *συνέλιξη*, η οποία περιλαμβάνει την αντικατάσταση ενός πλήρως συνδεδεμένου δικτύου με τοπικές μόνο συνδέσεις. Για να γίνει κατανοητό, ένας νευρώνας σε ένα ΣΝΔ δεν συνδέεται με όλους τους νευρώνες των προηγούμενων στρωμάτων (όπως σε ένα πλήρως διασυνδεδεμένο στρώμα), αλλά μόνο με ένα υποσύνολο αυτών. Αυτό πρακτικά επιτυγχάνεται με την εφαρμογή μιας συνάρτησης πυρήνα, που ονομάζεται επίσης φίλτρο, στα δεδομένα εισόδου μέσω της πράξης της συνέλιξης. Επιπλέον, τα βάρη του πυρήνα μοιράζονται από όλους τους νευρώνες σε ένα συγκεκριμένο στρώμα, κάτι που στη βιβλιογραφία αναφέρεται ως *διαμοιρασμός παραμέτρων*. Η συνέλιξη με συνάρτηση πυρήνα και ο διαμοιρασμός παραμέτρων έχουν ως αποτέλεσμα τη μείωση των παραμέτρων και επομένως την αποτελεσματική εκπαίδευση, σε σύγκριση με την αρχιτεκτονική ΠΤ. Η έξοδος ενός στρώματος συνέλιξης ονομάζεται *χάρτης χαρακτηριστικών*. Στο Σχήμα 3.4 απεικονίζεται μια πλήρης αρχιτεκτονική ΣΝΔ. Για μια μονομεταβλητή χρονοσειρά  $y(t)$  και έναν πυρήνα  $f \in \mathbb{R}^K$  με μέγεθος  $K$ , ο χάρτης χαρακτηριστικών ορίζεται σύμφωνα με την Εξίσωση 3.1

$$(y * f)(t) = \sum_{\tau=0}^{K-1} y[t - \tau]f[\tau] \quad (3.1)$$



Σχήμα 3.4: Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου

### 3.1.3 Αιτιώδης Συνέλιξη

Προκειμένου να προσαρμοστούν τα ΣΝΔ για την πρόβλεψη χρονοσειρών, απαιτείται η εισαγωγή ενός βασικού χαρακτηριστικού των δεδομένων χρονοσειρών, της αιτιότητας. Με λίγα λόγια, η αιτιότητα περιγράφει το γεγονός ότι τα αίτια πρέπει να προηγούνται των αποτελεσμάτων τους στο χρόνο [50]. Η *αιτιώδης συνέλιξη* αποτυπώνει τη χρονική προτεραιότητα με

τη χρήση πολλαπλών στρωμάτων συνελικτικών φίλτρων που διασφαλίζουν ότι για την πρόβλεψη χρησιμοποιούνται μόνο πληροφορίες του παρελθόντος. Με τον τρόπο αυτό διασφαλίζεται ότι δεν παραβιάζεται η χρονική σειρά των δεδομένων. Κάθε φίλτρο αιτιώδους συνέλιξης έχει τη μορφή των Εξισώσεων 3.2 και 3.3, όπου  $H$  είναι το μήκος του παραθύρου αναδρομής,  $\mathbf{h}_t^l \in \mathbb{R}^{H_{in}}$  είναι μια ενδιάμεση κατάσταση στο στρώμα  $l$  τη χρονική στιγμή  $t$ ,  $*$  είναι ο τελεστής συνέλιξης,  $\mathbf{W}(l, \tau) \in \mathbb{R}^{H_{out}} \times H_{in}$  είναι ένα σταθερό βάρος φίλτρου στο στρώμα  $l$ ,  $H_{in}$  και  $H_{out}$  αναφέρονται στο ύψος των χαρτών χαρακτηριστικών εισόδου και εξόδου, αντίστοιχα, μετά από ένα επίπεδο συνέλιξης και  $g(\cdot)$  είναι μια συνάρτηση ενεργοποίησης. Για ΣΝΔ με συνολικά  $L$  συνελικτικά στρώματα, η έξοδος του κωδικοποιητή είναι τότε  $\mathbf{z}_t = \mathbf{h}_t^L$ . Αξίζει να σημειωθεί ότι ένα μεμονωμένο αιτιατό στρώμα ΣΝΔ με γραμμική συνάρτηση ενεργοποίησης είναι ισοδύναμο με ένα μοντέλο (AR) (Ενότητα 2.2.1).

$$\mathbf{h}_t^{l+1} = g((\mathbf{W} * \mathbf{h})(l, t)) \quad (3.2)$$

$$(\mathbf{W} * \mathbf{h})(l, t) = \sum_{\tau=0}^H \mathbf{W}(l, \tau) \mathbf{h}_{t-\tau}^l \quad (3.3)$$

### 3.1.4 Διευρυμένη Συνέλιξη

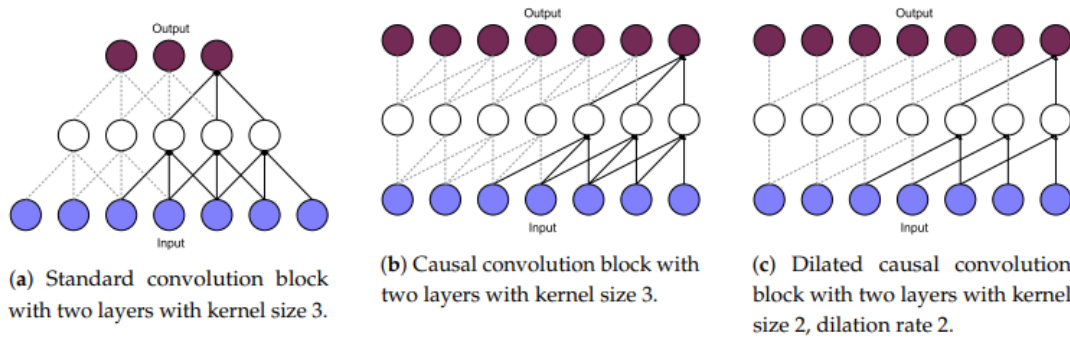
Μια άλλη τροποποιημένη εκδοχή ενός μοντέλου συνέλιξης είναι το μοντέλο *διευρυμένης ή διασταλμένης συνέλιξης* [8], το οποίο είναι ένα μοντέλο αρκετά υποσχόμενο για δεδομένα με χρονικές εξαρτήσεις μακράς εμβέλειας. Η διαστολή είναι ένας αποτελεσματικός τρόπος αύξησης του δεκτικού πεδίου του μοντέλου, επιτρέποντάς του να μαθαίνει για συσχετίσεις μεταξύ σημείων δεδομένων που βρίσκονται σε μεγάλη απόσταση. Μαθηματικά, το αποτέλεσμα μιας διασταλμένης συνέλιξης, όπως δίνεται από την Εξίσωση 3.4, μπορεί να θεωρηθεί ως αύξηση του πυρήνα με μηδενικά και περιοδική παράλειψη τιμών εισόδου με ένα ορισμένο μέγεθος βήματος, που ονομάζεται επίσης ρυθμός διαστολής,  $d$ .

$$(\mathbf{W} * \mathbf{h})(l, t, d_l) = \sum_{\tau=0}^{\lfloor H/d_l \rfloor} \mathbf{W}(l, \tau) \mathbf{h}_{t-d_l\tau}^l \quad (3.4)$$

Τέλος, το Σχήμα 3.5 συνοψίζει με συνοπτικό τρόπο τις διαφορές μεταξύ των τριών ειδών συνέλιξης που παρουσιάστηκαν παραπάνω.


## 3.2 Μοντέλα Ακολουθίας-προς-Ακολουθία

Ο περιορισμός επεξεργασίας των συνελικτικών νευρωνικών δικτύων για σταθερού μεγέθους είσοδο και έξοδο οδήγησε στη δεκαετία του 1980 στην πρόταση των αναδρομικών νευρωνικών δικτύων [69]. Τα ANΔ είναι ένα μοντέλο μάθησης που έχουν σχεδιαστεί για να αποτυπώνουν με σαφήνεια τη δυναμική των διατεταγμένων *ακολουθιών* μέσω της ιδέας των αναδρομικών (επαναλαμβανόμενων) συνδέσεων. Τα μοντέλα *ακολουθίας-προς-ακολουθία* είναι ένας τύπος αρχιτεκτονικής ANΔ που προτάθηκε για πρώτη φορά από τους Sutskever et al. [79] για εργασίες μηχανικής μετάφρασης, αλλά έκτοτε έχουν εφαρμοστεί σε διάφορες περιοχές, όπως η αναγνώριση ομιλίας και η αυτόματη παραγωγή λεζάντων για εικόνες. Η βασική ιδέα



Σχήμα 3.5: Διαφορές μεταξύ (α) του τυπικού, (β) του αιτιώδους και (γ) του διευρυμένου ΣΝΔ.

πίσω από αυτόν τον σχεδιασμό είναι ο διαχωρισμός μιας σύνθετης εργασίας, όπως η μηχανική μετάφραση, σε δύο επιμέρους εργασίες: την κωδικοποίηση και την αποκωδικοποίηση. Ο κωδικοποιητής επεξεργάζεται την ακολουθία εισόδου και παράγει μια συμπαγή σημασιολογική κρυφή αναπαράσταση (που συνήθως ονομάζεται *διάνυσμα πλαισίου*), η οποία αποτυπώνει τις βασικές πληροφορίες και τα χαρακτηριστικά της ακολουθίας εισόδου. Το διάνυσμα πλαισίου στη συνέχεια μεταβιβάζεται στον αποκωδικοποιητή, ο οποίος είναι υπεύθυνος για την παραγωγή της τελικής ακολουθίας εξόδου. Μια απλή απεικόνιση παρέχεται στο Σχήμα 3.6. Τα δύο κύρια πλεονεκτήματα του μοντέλου ακολουθίας-προς-ακολουθία είναι, πρώτον, ότι είναι ικανό να χειρίζεται ακολουθίες μεταβλητού μήκους, γεγονός που το καθιστά εφαρμόσιμο σε ένα ευρύ φάσμα εργασιών που σχετίζονται με ακολουθίες, και δεύτερον ότι μπορεί να εκπαιδευτεί από άκρο σε άκρο, πράγμα που σημαίνει ότι ολόκληρο το μοντέλο μπορεί να εκπαιδευτεί και να βελτιστοποιηθεί με τη χρήση αλγορίθμων, όπως αυτός της προς τα πίσω διάδοσης του σφάλματος.



Σχήμα 3.6: Γενική αρχιτεκτονική του μοντέλου ακολουθίας-προς-ακολουθία

### 3.2.1 Μοντέλα Μετασχηματιστών

Αρχικά, τα ΑΝΔ με αρχιτεκτονικές κωδικοποιητή-αποκωδικοποιητή αναπτύχθηκαν για την αντιμετώπιση των μακροχρόνιων εξαρτήσεων, αλλά παρά την εισαγωγή μηχανισμών πύλης πολλά προβλήματα, όπως ροή κλίσης και εξαφανιζόμενες/εξαρθρώμενες κλίσεις, εξακολουθούσαν να υφίστανται. Η εισαγωγή των μηχανισμών προσοχής έδωσε λύση σε αυτά τα ζητήματα,

αντικαθιστώντας πλήρως τις αρχιτεκτονικές που βασίζονται σε ΑΝΔ με την αρχιτεκτονική των μετασχηματιστών.

Ο μηχανισμός προσοχής προτάθηκε για πρώτη φορά στην εργασία Neural Machine Translation by Jointly Learning to Align and Translate των Bahdanau et al. το 2014 [5]. Οι συγγραφείς σημείωσαν ότι η παραδοσιακή αρχιτεκτονική κωδικοποιητή-αποκωδικοποιητή δεν μπορούσε να κωδικοποιήσει ολόκληρη την πρόταση εισόδου σε ένα ενιαίο διάνυσμα σταθερού μήκους. Για να αντιμετωπίσουν αυτόν τον περιορισμό, πρότειναν ένα αμφίδρομο LSTM με μηχανισμό προσοχής που κωδικοποιούσε την πρόταση εισόδου σε μια ακολουθία διανυσμάτων και επέλεγε ένα υποσύνολο αυτών των διανυσμάτων κατά την αποκωδικοποίηση της ακολουθίας εξόδου. Παρόλο που αυτή η τεχνική βελτίωσε την προσέγγιση κωδικοποιητή-αποκωδικοποιητή με βάση τα ΑΝΔ, ενσωματώνοντας την προσοχή στις προβλέψεις, η ευρύτερη αρχιτεκτονική εξακολουθούσε να είναι επιρρεπής στο ζήτημα της ροής της κλίσης μέσα στο χρόνο, το οποίο οδήγησε και πάλι σε μακροπρόθεσμες εξαρτήσεις.


Η επόμενη σημαντική συνεισφορά του μηχανισμού προσοχής που απαλλάχθηκε πλήρως από την αρχιτεκτονική των αναδρομικών δικτύων ήταν η αρχιτεκτονική του *μετασχηματιστή*, ευρέως γνωστή ως *transformer*, η οποία εισήχθη από τους Vaswani et al. το 2017 [88]. Το μοντέλο αυτό ενσωματώνει μια αρχιτεκτονική βασισμένη στην προσοχή, η οποία με την πάροδο των χρόνων κατάφερε να επιτύχει κορυφαίες επιδόσεις σε διάφορες εργασίες, ιδίως σε εργασίες επεξεργασίας φυσικής γλώσσας, όπως η μηχανική μετάφραση. Έκτοτε, τα μοντέλα μετασχηματιστών έχουν χρησιμοποιηθεί για διάφορες εφαρμογές, συμπεριλαμβανομένης και της πρόβλεψης χρονοσειρών. Το θεμελιώδες συστατικό της αρχιτεκτονικής των μετασχηματιστών είναι ένας *μηχανισμός αυτοπροσοχής*, όπου σε κάθε στοιχείο εισόδου αποδίδεται ένα βάρος ανάλογα με τη σημασία του σε σχέση με άλλα στοιχεία της ακολουθίας. Αυτό επιτρέπει στο μοντέλο να εστιάζει στα σημαντικά στοιχεία και να σταθμίζει επιλεκτικά τη συμβολή τους στην τελική έξοδο.

Οι μετασχηματιστές έχουν αρκετά πλεονεκτήματα σε σχέση με τις παραδοσιακές αρχιτεκτονικές νευρωνικών δικτύων. Πρώτον, μπορούν να χειριστούν ακολουθίες εισόδου και εξόδου *αυθαίρετου μήκους*, καθιστώντας τους κατάλληλους για ένα ευρύ φάσμα εργασιών πρόβλεψης χρονοσειρών. Δεύτερον, μπορούν να συλλάβουν *μακροπρόθεσμες εξαρτήσεις* στα δεδομένα πιο αποτελεσματικά από τις παραδοσιακές αρχιτεκτονικές που βασίζονται στα ΑΝΔ. Τέλος, μπορούν να εκπαιδευτούν με *παραλληλοποίηση* τρόπο, γεγονός που τους καθιστά υπολογιστικά αποδοτικούς και επεκτάσιμους σε μεγάλα σύνολα δεδομένων.

### 3.2.2 Αυτο-προσοχή

Ο *μηχανισμός προσοχής*, ή απλά *προσοχή*, επιτρέπει στον αποκωδικοποιητή να σταθμίζει τη σπουδαιότητα των διαφόρων τμημάτων του διάνυσματικού πλαισίου, ώστε να διευκολύνει την ροή της πληροφορίας και να καθιστά δυνατή την πλήρη παράκαμψη της κρυφής κατάστασης, εφόσον χρειάζεται.

Το μοντέλο του μετασχηματιστή βασίζεται σε έναν συγκεκριμένο μηχανισμό προσοχής, που ονομάζεται αυτο-προσοχή [88] και περιλαμβάνει τρεις κύριες συνιστώσες: (i) Ερώτηση-



Σχήμα 3.7: Μηχανισμός Αυτο-προσοχής

*Query*, (ii) Κλειδί – *Key* και (iii) Τιμή – *Value*, οι οποίες δημιουργούνται με γραμμικό μετασχηματισμό της αναπαράστασης εισόδου κάθε στοιχείου. Αυτά τα στοιχεία χρησιμοποιούνται για τον υπολογισμό των βαθμολογιών προσοχής μεταξύ διαφορετικών τμημάτων της ακολουθίας εισόδου. Το διάνυσμα ερώτησης συμβολίζεται με  $\mathbf{q}_i$  και αντιπροσωπεύει έναν γραμμικό μετασχηματισμό ενός συγκεκριμένου σημείου δεδομένων  $y_i$  στην ακολουθία εισόδου, π.χ.  $\mathbf{q}_c$  είναι ένας γραμμικός μετασχηματισμός της εισόδου  $y_c$  για μια συγκεκριμένη χρονική στιγμή  $t = c$  στην περίπτωση μονομεταβλητών χρονοσειρών  $y_t$ . Το διάνυσμα κλειδιού, που συμβολίζεται με  $\mathbf{k}_i$ , χρησιμοποιείται για τον υπολογισμό της ομοιότητας μεταξύ της εισόδου και κάθε άλλου σημείου δεδομένων. Τέλος, το διάνυσμα τιμών, που συμβολίζεται με  $\mathbf{v}_i$ , χρησιμοποιείται για τον υπολογισμό του σταθμισμένου αθροίσματος των τιμών προσοχής για κάθε σημείο δεδομένων εισόδου. Στην πράξη, η συνάρτηση προσοχής υπολογίζεται σε ένα σύνολο ερωτημάτων ταυτόχρονα, τα οποία συγκεντρώνονται στο τέλος σε έναν πίνακα  $\mathbf{Q}$ . Ομοίως, τα κλειδιά και οι τιμές συγκεντρώνονται επίσης σε πίνακες  $\mathbf{K}$  και  $\mathbf{V}$ , αντίστοιχα (Σχήμα 3.7).

Ο βαθμός προσοχής μεταξύ του σημείου δεδομένων  $y_i$  και κάθε άλλου σημείου δεδομένων  $y_j$  στην ακολουθία εισόδου, με  $i, j \in \{t_0 - t_h : t_0\}$  και  $i \neq j$ , υπολογίζεται ως το κλιμακωτό τετραγωνικό γινόμενο μεταξύ του διανύσματος ερωτήματος  $\mathbf{q}_i$  ( $i$ -οστή γραμμή του πίνακα  $\mathbf{Q}$ ) και του διανύσματος κλειδιού  $\mathbf{k}_j$  ( $j$ -οστή γραμμή του πίνακα  $\mathbf{K}$ ). Επομένως, ο πίνακας των αποτελεσμάτων προσοχής εξόδου υπολογίζεται σύμφωνα με την Εξίσωση 3.5)

$$Attention(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = softmax\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right) \quad (3.5)$$

όπου  $\mathbf{Q} \in \mathbb{R}^{n \times d_q}$ ,  $\mathbf{K} \in \mathbb{R}^{n \times d_k}$ ,  $\mathbf{V} \in \mathbb{R}^{n \times d_v}$ ,  $d_q, d_k, d_v$  είναι οι διαστάσεις των διανυσμάτων ερώτησης, κλειδιού και τιμής αντίστοιχα και  $n$  είναι ο αριθμός των ακολουθιών εισόδου. Η αυτοπροσοχή υπολογίζεται στη συνέχεια ως σταθμισμένο άθροισμα των διανυσμάτων τιμών στον πίνακα  $\mathbf{V}$ , όπου τα βάρη δίνονται από τους βαθμούς προσοχής που υπολογίστηκαν προηγουμένως (Εξίσωση 3.6)

$$Self\_Attention(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = Attention(\mathbf{Q}, \mathbf{K}, \mathbf{V})\mathbf{V} \quad (3.6)$$

Ο μηχανισμός της αυτο-προσοχής επιτυγχάνει τετραγωνική χρονική πολυπλοκότητα και  $O(d_q \cdot d_k)$  χωρική πολυπλοκότητα, τα οποία αποτελούν τα σημαντικότερα μειονεκτήματα του. Η

διάσταση των ερωτημάτων  $d_q$  και των κλειδιών  $d_k$  συνήθως τίθενται ίσες στην αυτοπροσοχή, καθώς απαιτείται ο υπολογισμός του εσωτερικού γινομένου του  $\mathbf{Q}$  και  $\mathbf{V}$ .


Για την εξαγωγή των αντίστοιχων πινάκων  $\mathbf{Q}$ ,  $\mathbf{K}$  και  $\mathbf{V}$ , οι εισόδοι  $\mathbf{X}$  προβάλλονται γραμμικά με διανυσματικό πολλαπλασιασμό πινάκων (ή με επίπεδα τροφοδότησης), όπως απεικονίζεται στο Σχήμα 3.8 και στις Εξισώσεις 3.7 - 3.9

$$\mathbf{Q} = \mathbf{X}\mathbf{W}^{\mathbf{Q}} \quad (3.7)$$

$$\mathbf{K} = \mathbf{X}\mathbf{W}^{\mathbf{K}} \quad (3.8)$$

$$\mathbf{V} = \mathbf{X}\mathbf{W}^{\mathbf{V}} \quad (3.9)$$

όπου  $\mathbf{X} \in \mathbb{R}^{n \times d_i}$ ,  $\mathbf{W}^{\mathbf{Q}} \in \mathbb{R}^{d_i \times d_q}$ ,  $\mathbf{W}^{\mathbf{K}} \in \mathbb{R}^{d_i \times d_k}$ ,  $\mathbf{W}^{\mathbf{V}} \in \mathbb{R}^{d_i \times d_v}$ ,  $n$  είναι ο αριθμός των ακολουθιών εισόδου και  $d_i$  είναι η διάσταση εισόδου. Οι  $\mathbf{W}^{\mathbf{Q}}$ ,  $\mathbf{W}^{\mathbf{K}}$ ,  $\mathbf{W}^{\mathbf{V}}$  αντιπροσωπεύουν τους πίνακες βαρών των γραμμικών προβολών.



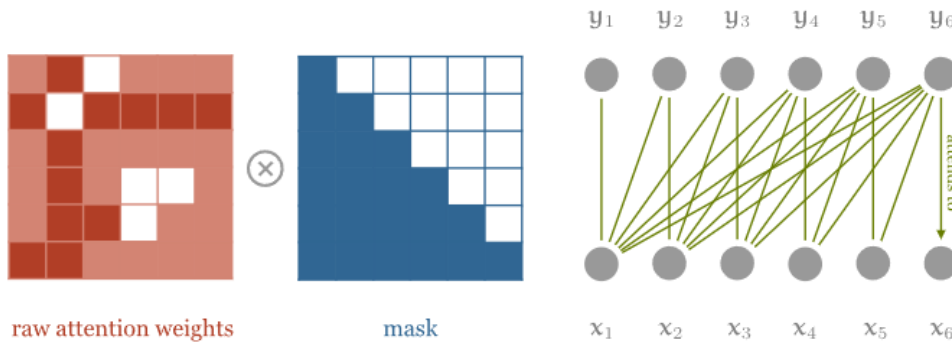
Σχήμα 3.8: Απλή προβολή της εισόδου  $\mathbf{X}$  με πολλαπλασιασμό πινάκων για την κατασκευή των πινάκων  $\mathbf{Q}$ ,  $\mathbf{K}$  και  $\mathbf{V}$

### 3.2.3 Τεχνική Μάσκα

Σε πολλές εφαρμογές, προκειμένου να διασφαλιστεί ότι ο μηχανισμός προσοχής ικανοποιεί την υπόθεση της αιτιότητας, εφαρμόζεται μια *τεχνική μάσκα* που περιλαμβάνει την τροποποίηση του μηχανισμού προσοχής με τον περιορισμό των βαρών προσοχής του, ώστε να αποκλείονται πληροφορίες από μελλοντικά σημεία της ακολουθίας. Στην πράξη, η απόκρυψη της αυτοπροσοχής σημαίνει την απόκρυψη των μελλοντικών σημείων θέτοντάς τα σε  $-\infty$ , πριν από το τελικό βήμα του υπολογισμού της αυτοπροσοχής, όπως απεικονίζεται στο Σχήμα 3.9.

### 3.2.4 Αυτοπροσοχή με πολλαπλές κεφαλές

Σε αντίθεση με την αυτοπροσοχή μιας κεφαλής, η οποία επιτρέπει στο μοντέλο να μάθει μόνο ένα σύνολο βαρών προσοχής, η αυτοπροσοχή πολλαπλών κεφαλών (που παρουσιάζεται




Σχήμα 3.9: Τεχνική μάσκας

στο Σχήμα 3.10) είναι μια επέκταση του μηχανισμού αυτοπροσοχής που επιτρέπει στο μοντέλο να μάθει παράλληλα πολλαπλά σύνολα βαρών προσοχής. Αυτή η προσέγγιση [88] περιλαμβάνει τη χρήση πολλαπλών κεφαλών προσοχής για τη γραμμική προβολή ερωτημάτων, κλειδιών και τιμών πολλές φορές, με διαφορετική προβολή κάθε φορά. Με τη χρήση της αυτοπροσοχής πολλαπλών κεφαλών, το μοντέλο μπορεί να επεξεργάζεται ταυτόχρονα διάφορες πτυχές της ακολουθίας εισόδου και, ως εκ τούτου, μπορεί να συλλάβει πιο περίπλοκες και πολύπλοκες σχέσεις μεταξύ των σημείων των ακολουθιών εισόδου, οδηγώντας σε βελτιωμένη γενίκευση και καλύτερη συνολική απόδοση (Εξισώσεις 3.10-3.2.4)

$$head_i = Self\_Attention(\mathbf{Q}W_i^Q, \mathbf{K}W_i^K, \mathbf{V}W_i^V), \text{ for } i \in 1 : n_h \quad (3.10)$$

$$MultiHead(\mathbf{Q}, \mathbf{K}, \mathbf{V}, n_h) = concat(head_1, head_2, \dots, head_{n_h}) \quad (3.11)$$

όπου  $n_h$  είναι ο αριθμός των κεφαλών και  $W_i^Q, W_i^K$  και  $W_i^V$  είναι οι πίνακες βαρών για την κεφαλή  $i$ .



Σχήμα 3.10: Αυτοπροσοχή με πολλαπλές κεφαλές: πολλαπλά επίπεδα προσοχής που λειτουργούν παράλληλα




### 3.2.5 Κωδικοποίηση θέσης

Ενώ οι αρχιτεκτονικές ANΔ εισάγουν εγγενώς την έννοια της χρονολογικής σειράς, καθώς κάθε χρονικό βήμα επεξεργάζεται διαδοχικά, το μοντέλο μετασχηματιστή βασίζεται στον μηχανισμό αυτοπροσοχής με πολλαπλές κεφαλές που χρησιμοποιεί παράλληλους υπολογισμούς και επομένως δεν λαμβάνει υπόψη τη σειρά των σημείων στις ακολουθίες. Για την ενσωμάτωση πληροφοριών θέσης στο μοντέλο μετασχηματιστή, είναι απαραίτητο να εισαχθεί η έννοια της κωδικοποίησης θέσης (positional encoding - PE). Διαισθητικά, η PE κωδικοποιεί τη σχετική ή απόλυτη πληροφορία θέσης των σημείων δεδομένων στην ακολουθία. Οι προκύπτουσες κωδικοποιήσεις θέσης προστίθενται στα διανύσματα εμφύτευσης κάθε σημείου δεδομένων πριν τροφοδοτηθούν στον μηχανισμό αυτοπροσοχής του μοντέλου. Η διαδικασία κωδικοποίησης παρουσιάζεται στην Εξίσωση 3.12

$$PE_{(t,i)} = \begin{cases} \sin\left(\frac{t}{10000^{2i/d_i}}\right), & \text{αν } i\%2 = 0 \\ \cos\left(\frac{t}{10000^{2(i-1)/d_i}}\right), & \text{αν } i\%2 = 1 \end{cases} \quad (3.12)$$

όπου  $i$  είναι ο δείκτης της διάστασης στο διάνυσμα εμφύτευσης και  $d_i$  είναι η διαστατικότητα του χώρου εμφύτευσης. Η κωδικοποίηση θέσης για κάθε σημείο δεδομένων  $y_t$  προκύπτει από τη συνένωση των τιμών των  $PE_{(t,2i)}$  και  $PE_{(t,2i+1)}$  για κάθε διάσταση  $i$  στο διάνυσμα εμφύτευσης.



Σχήμα 3.11: Γραφική απεικόνιση της ημιτονοειδούς κωδικοποίησης θέσης

Τα στοιχεία του κωδικοποιητή και του αποκωδικοποιητή περιέχουν από ένα πλήρως συνδεδεμένο δίκτυο προώθησης το οποίο λειτουργεί σε κάθε θέση της ακολουθίας εισόδου ανεξάρτητα και πανομοιότυπα. Το δίκτυο τροφοδότησης προς τα εμπρός αποτελείται από δύο γραμμικούς μετασχηματισμούς, με μια ημιγραμμική συνάρτηση ενεργοποίησης που εφαρμόζε-

ται μεταξύ τους, όπως απεικονίζεται στην Εξίσωση 3.13. Μια άλλη προσέγγιση είναι η χρήση δύο συνελίξεων με μέγεθος πυρήνα 1, αλλά το δίκτυο ΠΤ αποτελεί πιο άμεση λύση για το συγκεκριμένο πρόβλημα.

$$FFN(\mathbf{H}') = \text{ReLU}(\mathbf{H}'\mathbf{W}_1 + \mathbf{b}_1)\mathbf{W}_2 + \mathbf{b}_2 \quad (3.13)$$

όπου  $\mathbf{H}'$  είναι οι έξοδοι του προηγούμενου επιπέδου,  $\mathbf{W}_1 \in \mathbb{R}^{\mathbb{D}_m \times \mathbb{D}_f}$ ,  $\mathbf{W}_2 \in \mathbb{R}^{\mathbb{D}_f \times \mathbb{D}_m}$ ,  $\mathbf{b}_1 \in \mathbb{R}^{\mathbb{D}_f}$  και  $\mathbf{b}_2 \in \mathbb{R}^{\mathbb{D}_m}$  είναι εκπαιδευσιμες παράμετροι.

Η συγκεκριμένη αρχιτεκτονική επιτρέπει στο μοντέλο να μαθαίνει μη γραμμικές σχέσεις μεταξύ των ακολουθιών εισόδου και εξόδου, ενισχύοντας την ικανότητά του να συλλαμβάνει σύνθετα πρότυπα και εξαρτήσεις. Επιπλέον, η χρήση των ημιγραμμικών συναρτήσεων ενεργοποίησης έχει αποδειχθεί ότι παρέχει βελτιωμένη απόδοση σε διάφορα μοντέλα βαθιάς μάθησης λόγω της ικανότητάς τους να αποτρέπουν την εξαφάνιση των κλίσεων και να διευκολύνουν την ταχύτερη εκπαίδευση.

Για τη βελτιστοποίηση της απόδοσης ενός μοντέλου βαθιάς μάθησης, χρησιμοποιείται επιπλέον μια προηγμένη τεχνική γνωστή ως *κανονικοποίηση στρώματος* μαζί με μια *υπολειμματική μονάδα σύνδεσης* (residual connection module) γύρω από κάθε μονάδα (Εξισώσεις 3.14-ρεφεχ:τρανσφομερς:ρες)

$$\mathbf{H}' = \text{Layer\_Norm}(\text{Self\_Attention}(\mathbf{X}) + \mathbf{X}) \quad (3.14)$$

$$\mathbf{H} = \text{Layer\_Norm}(FFN(\mathbf{H}') + \mathbf{H}') \quad (3.15)$$

όπου  $\text{Self\_Attention}(\cdot)$  δηλώνει τη μονάδα αυτο-προσοχής και  $\text{Layer\_Norm}(\cdot)$  δηλώνει την πράξη κανονικοποίησης στρώματος. Αυτή η μεθοδολογία αντιμετωπίζει τις προκλήσεις που σχετίζονται με το πρόβλημα της εξαφανιζόμενης κλίσης, το οποίο ενδέχεται να δυσχεράνει την αποτελεσματικότητα των δικτύων βαθιάς μάθησης. Ο συνδυασμός αυτών των τεχνικών διευκολύνει την ομαλή ροή της πληροφορίας μέσω του δικτύου και βελτιώνει τη συνολική απόδοσή του.

## Κεφάλαιο 4

# Δεδομένα και Αρχιτεκτονική Συστήματος

### 4.1 Σύνολο δεδομένων

Το σύνολο δεδομένων που χρησιμοποιήθηκε στην παρούσα διπλωματική εργασία περιέχει χρονολογικά δεδομένα σχετικά με τον όγκο της κυκλοφορίας στα διόδια της Ολυμπίας Οδού. Η Ολυμπία Οδός είναι ένας σύγχρονος αυτοκινητόδρομος στην Ελλάδα που συνδέει τις πόλεις της Αθήνας και του Πύργου. Τα κυκλοφοριακά δεδομένα, που χρησιμοποιήθηκαν για τους σκοπούς της συγκεκριμένης έρευνας, συλλέγονται από τους σταθμούς διοδίων της Ελευσίνας και του Ισθμού της Κορίνθου. Αυτό επιτυγχάνεται μέσω μιας εφαρμογής συλλογής δεδομένων που ανακτά και μετασχηματίζει δεδομένα από το υφιστάμενο σύστημα διοδίων, συμπεριλαμβανομένων των συστημάτων χειροκίνητης και ηλεκτρονικής είσπραξης διοδίων, και το σύστημα διαχείρισης αυτοκινητοδρόμων σε περιοδική βάση (κάθε 15 λεπτά) και μεταφέρει τα δεδομένα αυτά σε μια σχεσιακή βάση δεδομένων που φιλοξενείται στις εγκαταστάσεις της «ΟΛΥΜΠΙΑΣ ΟΔΟΣ Α.Ε.», που είναι η εταιρία παραχώρησης του εν λόγω αυτοκινητοδρόμου.

Τα δεδομένα που χρησιμοποιήθηκαν χρονολογούνται από το έτος 2016 και ύστερα. Πιο συγκεκριμένα, τα δεδομένα του έτους 2019 χρησιμοποιήθηκαν ως σύνολο επικύρωσης και τα δεδομένα του 2017 χρησιμοποιήθηκαν για τη δοκιμή των μοντέλων, ενώ τα δεδομένα των ετών 2018 και 2022 χρησιμοποιήθηκαν για την εκπαίδευση. Τα δεδομένα από το 2020 έως και το 2021 δεν χρησιμοποιήθηκαν λόγω των επιπτώσεων της πανδημίας του COVID-19 και των κυβερνητικών κανονισμών που επηρέασαν με διάφορους τρόπους τη συλλογή δεδομένων και τον όγκο κίνησης στους σταθμούς διοδίων και ευρύτερα στο οδικό δίκτυο. Εκτός από τον όγκο κυκλοφορίας από συγκεκριμένους σταθμούς διοδίων, το σύνολο δεδομένων περιέχει επίσης στατιστικά στοιχεία κυκλοφορίας, ημερολογιακά δεδομένα (αργίες, Σαββατοκύριακα, εργάσιμες ημέρες κ.λπ.) και μετεωρολογικές προβλέψεις. Οι συγκεκριμένοι σταθμοί διοδίων που υπήρχαν στα δεδομένα συνοψίζονται στον Πίνακα 4.1

Όλο το σύνολο των δεδομένων είναι αποθηκευμένο σε σχεσιακή βάση δεδομένων, η οποία αποτελείται από διάφορους πίνακες και σχήματα. Για τους σκοπούς της παρούσας διατριβής, χρησιμοποιήθηκαν μόνο δεδομένα σχετικά με τον όγκο της κυκλοφορίας και ημερολογιακά

Κωδικός	Θέση	Κατεύθυνση
ELEE	Ελευσίνα	Αθήνα
ELET	Ελευσίνα	Πύργος
ISTE	Ισθμός	Αθήνα
ISTT	Ισθμός	Πύργος

Πίνακας 4.1: Σταθμοί διοδίων στο σύνολο δεδομένων

στοιχεία. Οι σχετικές στήλες από τους πίνακες της βάσης δεδομένων απεικονίζονται στον Πίνακα 4.2<sup>1</sup>.

Στήλη	Τύπος	Περιγραφή
Toll_Datetime	DATETIME	Η ώρα και ημερομηνία του συμβάντος σε ΥΤ <sup>2</sup> .
Node_name	CHAR(8)	Το όνομα της λωρίδας σε κείμενο (ELEE-LXX και ISTE-LXX για λωρίδες με κατεύθυνση προς Αθήνα, ELET-LXX και ISTT-LXX για λωρίδες με κατεύθυνση προς Πάτρα).
Is_Holiday	BIT	Η μεταβλητή είναι Αληθής αν η ημέρα είναι αργία και Ψευδής διαφορετικά.
Is_Holiday_Season	BIT	Η μεταβλητή είναι Αληθής αν η ημέρα βρίσκεται εντός περιόδου διακοπών, όπως η περίοδος των Χριστουγέννων και Ψευδής διαφορετικά.
Is_Weekday	BIT	Η μεταβλητή είναι Αληθής αν η ημέρα είναι καθημερινή (Δευτέρα έως Παρασκευή), διαφορετικά είναι Ψευδής.
Is_Business_Day	BIT	Η μεταβλητή είναι Αληθής αν η ημέρα είναι εργάσιμη, η οποία συνήθως ορίζεται ως μια καθημερινή ημέρα που δεν είναι αργία και Ψευδής διαφορετικά.

Πίνακας 4.2: Χρησιμοποιούμενες στήλες από τη βάση δεδομένων με τους τύπους και την περιγραφή τους

Αν και τα δεδομένα κίνησης είναι αποθηκευμένα στην βάση δεδομένων, ο όγκος κυκλοφορίας δεν είναι άμεσα διαθέσιμος και πρέπει να εξαχθεί. Αυτό οφείλεται στο γεγονός πως τα δεδομένα κυκλοφορίας αποθηκεύονται σε πραγματικό χρόνο, πράγμα που σημαίνει ότι μια νέα εγγραφή εισάγεται στη βάση δεδομένων κάθε φορά που ένα αυτοκίνητο περνά από έναν σταθμό διοδίων. Για το λόγο αυτό, προκειμένου να ληφθούν και να φορτωθούν τα δεδομένα από τη βάση δεδομένων, εκτελείται ένα ερώτημα SQL, το οποίο μετράει τις εγγραφές για κάθε σταθμό διοδίων κάθε 15 λεπτά, με δυνατότητα διαμόρφωσης με αύξοντα τρόπο.

## 4.2 Διαδικασία ETL

Η διαδικασία ETL (Extract, Transform and Load), είναι μια διαδικασία ολοκλήρωσης δεδομένων που συνδυάζει δεδομένα από πολλαπλές πηγές σε ένα ενιαίο, συνεπές αποθετήριο δεδομένων, το οποίο φορτώνεται σε μια αποθήκη δεδομένων ή σε άλλο σύστημα-στόχο για ανάλυση και αναφορά. Στο πλαίσιο του συστήματος διοδίων και του συστήματος διαχείρισης αυτοκινητοδρόμων στην Ολυμπία Οδό, η διαδικασία ETL πραγματοποιείται ως εξής:

- **Εξαγωγή (Extract):** Το πρώτο βήμα είναι η εξαγωγή δεδομένων από διάφορες πηγές, όπως τα συστήματα ΗΣΔ, ΧΣΔ και το σύστημα ανίχνευσης οχημάτων (ΣΑΟ), το οποίο

<sup>1</sup>Σημείωση: Ο τύπος δεδομένων BIT είναι μια ακέραια τιμή που δέχεται 0, 1 και NULL. Το BIT αντιπροσωπεύει έναν τύπο boolean με τιμές TRUE (1) και FALSE (0).

περιλαμβάνει αισθητήρες κυκλοφορίας, επαγωγικούς βρόχους και κάμερες. Τα δεδομένα αυτά μπορούν να περιλαμβάνουν πληροφορίες σχετικά με τις συναλλαγές διοδίων, τον όγκο κυκλοφορίας, τους τύπους οχημάτων και τις ταχύτητες.

- **Μετασχηματισμός (Transform):** Αφού εξαχθούν τα δεδομένα, πρέπει να μετασχηματιστούν σε μορφή κατάλληλη για ανάλυση. Αυτό μπορεί να περιλαμβάνει καθαρισμό, αφαίρεση αντιγράφων, φιλτράρισμα, ταξινόμηση και συγκέντρωση των δεδομένων. Τα δεδομένα μπορούν επίσης να εμπλουτιστούν με πρόσθετες πληροφορίες, όπως πρόγνωση καιρού, δεδομένα κυκλοφοριακών συμβάντων και ημερολογιακές πληροφορίες.
- **Φόρτωση (Load):** Το τελικό βήμα είναι η φόρτωση των μετασχηματισμένων δεδομένων στη βάση δεδομένων προορισμού ή στην αποθήκη δεδομένων, όπου μπορούν να χρησιμοποιηθούν για διάφορες εργασίες και αναλύσεις, μεταξύ αυτών και για την πρόβλεψη του όγκου της κυκλοφορίας. Αυτό περιλαμβάνει την αντιστοίχιση των δεδομένων στους κατάλληλους πίνακες και στήλες και τη διενέργεια τυχόν απαραίτητων ελέγχων επικύρωσης και ποιότητας των δεδομένων.

Συνολικά, με την εκτέλεση της διαδικασίας ETL στο Σύστημα Διοδίων και στο Σύστημα Διαχείρισης Αυτοκινητοδρόμων στην Ολυμπία Οδό, τα δεδομένα μπορούν να ενσωματωθούν και να αναλυθούν ώστε να παρέχουν πολύτιμες πληροφορίες για την πρόβλεψη της κυκλοφορίας, την τιμολόγηση των διοδίων και τη γενική απόδοση του συστήματος. Για παράδειγμα, τα δεδομένα μπορούν να χρησιμοποιηθούν για τον εντοπισμό προτύπων κυκλοφορίας, τη βελτιστοποίηση της τιμολόγησης των διοδίων και τον εντοπισμό ανωμαλιών, όπως ατυχήματα ή συμφόρηση.

### 4.3 Προεπεξεργασία δεδομένων

Η προεπεξεργασία δεδομένων είναι ένα ουσιαστικό βήμα στην πρόβλεψη με βάση τα νευρωνικά δίκτυα, προκειμένου να βελτιωθεί η ποιότητα των δεδομένων, να αφαιρεθούν οι ασυνέπειες και να μειωθεί ο θόρυβος. Μια συνήθης τεχνική στην προεπεξεργασία δεδομένων για τη βελτίωση της ακρίβειας της πρόβλεψης είναι η *κλιμάκωση* των δεδομένων για να εξασφαλιστεί *σταθερή σύγκλιση*. Οι μη κανονικοποιημένες είσοδοι μπορεί να προκαλέσουν αργή σύγκλιση, ενώ οι μη κανονικοποιημένες έξοδοι μπορεί να οδηγήσουν σε «*εκρηκτικές*» κλίσεις. Για να αντιμετωπιστεί αυτό το ζήτημα, η *τυποποίηση* είναι μια μέθοδος κανονικοποίησης των δεδομένων με τη χρήση του μέσου όρου και της τυπικής απόκλισης του συνόλου δεδομένων. Η τεχνική αυτή περιλαμβάνει την αφαίρεση του μέσου όρου από κάθε τιμή και στη συνέχεια τη διαίρεση με την τυπική απόκλιση. Αυτός ο μετασχηματισμός εξασφαλίζει ότι το σύνολο των δεδομένων παρουσιάζουν μέση τιμή μηδέν και τυπική απόκλιση ένα.

Για να εξασφαλιστεί η σωστή κλιμάκωση, τα δεδομένα εκπαίδευσης κλιμακώνονται πρώτα και στη συνέχεια η κλιμάκωση αυτή εφαρμόζεται στα δεδομένα δοκιμής και επικύρωσης. Η τυποποίηση είναι χρήσιμη για σύνολα δεδομένων με μεγάλο εύρος τιμών ή για σύνολα δεδομένων όπου η μέση τιμή και η τυπική απόκλιση είναι σημαντικά χαρακτηριστικά. Αυτή η

τεχνική μπορεί να βοηθήσει στη μείωση της επίδρασης των ακραίων τιμών και στη βελτίωση της απόδοσης των αλγορίθμων μηχανικής μάθησης που βασίζονται σε κανονικοποιημένα δεδομένα.

#### 4.4 Διαχωρισμός δεδομένων

Στην πράξη, η τυποποίηση συνδυάζεται συχνά με άλλες τεχνικές προεπεξεργασίας, όπως ο διαχωρισμός των δεδομένων σε υποσύνολα εκπαίδευσης, **επικύρωσης** και **δοκιμής**, προκειμένου να διασφαλιστεί ότι το μοντέλο εκπαιδεύεται και αξιολογείται σε διακριτά υποσύνολα δεδομένων. Όπως αναφέρθηκε προηγουμένως, τα δεδομένα των ετών 2018 και 2022 αποτέλεσαν το υποσύνολο εκπαίδευσης, τα δεδομένα του έτους 2019 το υποσύνολο δεδομένων επικύρωσης και τα δεδομένα του έτους 2017 για δοκιμή.

Πριν από την εκπαίδευση του μοντέλου, τα σύνολα δεδομένων χρονοσειρών πρέπει να μετατραπούν σε παραδείγματα εκπαίδευσης. Ο Informer [104] πρότεινε μια προσέγγιση που χρησιμοποιεί ένα κυλιόμενο παράθυρο για τη δημιουργία μιας ακολουθίας διαδοχικών τιμών της σειράς, ακολουθούμενη από τις αντίστοιχες τιμές που χρησιμεύουν ως ετικέτες. Παρόμοια μέθοδος εφαρμόστηκε και στο σύστημα που σχεδιάστηκε για τους σκοπούς της συγκεκριμένης διπλωματικής εργασίας.

Αξίζει να αναφερθεί ότι η τεχνική του κυλιόμενου παραθύρου χρησιμοποιείται συνήθως στην ανάλυση χρονολογικών σειρών για την κατάτμηση δεδομένων χρονολογικών σειρών σε μικρότερα τμήματα και συνεπώς επιτρέπει την ευκολότερη ανάλυση και μοντελοποίηση των δεδομένων. Η τεχνική αυτή περιλαμβάνει την επιλογή ενός μεγέθους παραθύρου και ενός διαστήματος, όπου το μέγεθος του παραθύρου καθορίζει το μήκος του τμήματος και το διάστημα καθορίζει το μέγεθος της επικάλυψης μεταξύ γειτονικών τμημάτων. Επιπλέον, η τεχνική του κυλιόμενου παραθύρου είναι ένα κρίσιμο βήμα για τη δημιουργία παραδειγμάτων εκπαίδευσης από δεδομένα χρονοσειρών, καθώς επιτρέπει τη δημιουργία ενός συνόλου ζευγών εισόδου-εξόδου που μπορούν να χρησιμοποιηθούν για την εκπαίδευση του μοντέλου.

#### 4.5 Ανάλυση δεδομένων

Στην παρούσα ενότητα παρουσιάζεται μια εκτενής ανάλυση του συνόλου δεδομένων, προκειμένου να αποκτηθεί μια εμπεριστατωμένη κατανόηση των θεμελιωδών χαρακτηριστικών και ιδιοτήτων του και να επιβεβαιωθεί η εγκυρότητα των πειραματικών αποφάσεων που ελήφθησαν. Τα διαγράμματα δημιουργήθηκαν προσθέτοντας αρχικά τυχαίο θόρυβο στα δεδομένα και στη συνέχεια κανονικοποιώντας τα με τη χρήση παραμέτρων κλιμάκωσης που υπολογίστηκαν με βάση το σύνολο δεδομένων του έτους 2022. Το Σχήμα 4.1 πιστοποιεί το γεγονός αυτό, δείχνοντας ότι ο μέσος όρος του θηγογράμματος για το 2022 είναι ίσος με το μηδέν. Είναι σημαντικό να σημειωθεί ότι για τη συμμόρφωση με τους κανονισμούς περί προστασίας των προσωπικών δεδομένων, οι πραγματικές τιμές των δεδομένων δεν θα αποκαλυφθούν στο πλαίσιο της παρούσας διατριβής.


Η κατανομή του όγκου κίνησης για κάθε μήνα των ετών 2022, 2020, 2019, 2018 και

2017 απεικονίζεται στα Σχήματα 4.2 έως 4.5. Αυτά τα σχήματα καταδεικνύουν την απόφαση να εξαιρεθούν τα δεδομένα των ετών 2020 και 2021 λόγω των επιπτώσεων της πανδημίας COVID-19, καθώς τα δεδομένα του έτους 2020 αποκλίνουν σημαντικά από τη γενική κατανομή και είναι ανόμοια με τα υπόλοιπα έτη, ιδίως κατά τον Απρίλιο, τον Μάιο, τον Νοέμβριο και τον Δεκέμβριο. Αξίζει να σημειωθεί ότι δεν υπάρχουν ακραίες τιμές τον Απρίλιο και τον Δεκέμβριο, ενώ οι ακραίες τιμές του 2020 έχουν μικρότερες τιμές σε σχέση με τα άλλα έτη, γεγονός που είναι αναμενόμενο λόγω των περιορισμών μετακίνησης που επιβλήθηκαν το 2020 και το 2021 στην Ελλάδα. Είναι σημαντικό να σημειωθεί ότι ο αποκλεισμός των δεδομένων του 2020 αποτελεί συνήθης πρακτική σε μελέτες κυκλοφοριακής ανάλυσης, καθώς η πανδημία είχε σημαντικό αντίκτυπο στα πρότυπα και τη συμπεριφορά της κυκλοφορίας.

Για παράδειγμα, κατά τις περιόδους διακοπών, όπως το καλοκαίρι και το Πάσχα και κατά τις εθνικές εορτές, όπως η 25<sup>η</sup> Μαρτίου και η 28<sup>η</sup> Οκτωβρίου, υπάρχουν συνήθως περισσότερες ακραίες τιμές και μεγαλύτερος όγκος κυκλοφορίας. Συγκεκριμένα, κατά τους καλοκαιρινούς μήνες Ιούλιο και Αύγουστο, παρατηρήθηκε ο υψηλότερος μέσος όγκος κυκλοφορίας σε όλους τους σταθμούς διοδίων και για όλα τα έτη. Αντίθετα, οι χειμερινοί μήνες παρουσιάζουν γενικά τον χαμηλότερο όγκο κυκλοφορίας, πιθανότατα λόγω δυσμενών καιρικών συνθηκών.

Το Σχήμα 4.1 απεικονίζει την κατανομή του όγκου κυκλοφορίας ανά έτος σε όλους τους σταθμούς. Αξίζει να σημειωθεί ότι το έτος 2020 ξεχωρίζει από τα υπόλοιπα, καθώς παρουσιάζει μια ξεχωριστή κατανομή. Η διαφοροποίηση αυτή μπορεί να αποδοθεί στον αντίκτυπο της πανδημίας COVID-19 στη ροή της κυκλοφορίας. Ως προληπτικό μέτρο για την αποτροπή της εξάπλωσης του ιού, οι κυβερνήσεις σε όλο τον κόσμο εφάρμοσαν αποκλεισμούς και ταξιδιωτικούς περιορισμούς, οι οποίοι προκάλεσαν σημαντική μείωση του όγκου της κυκλοφορίας, με αποτέλεσμα τη διαφορετική κατανομή του για το έτος 2020. Αντίθετα, η κατανομή του όγκου κυκλοφορίας για τα υπόλοιπα έτη φαίνεται να είναι παρόμοια μεταξύ τους.

Εκτός από τα δεδομένα κυκλοφορίας, χρησιμοποιήθηκε επιπλέον ο χαρακτηρισμός των ημερών, αν δηλαδή είναι η εκάστοτε ημέρα είναι εργάσιμη, αργία και ημέρα διακοπών, σύμφωνα με τις περιγραφές του Πίνακα 4.2. Για το λόγο αυτό, στο Σχήμα 4.6 απεικονίζεται το ποσοστό των Αληθών τιμών για κάθε μεταβλητή για κάθε έτος και σταθμό διοδίων. Είναι προφανές ότι οι μεταβλητές `Is_Weekday` και `Is_Business_Day` έχουν ποσοστό Αληθών τιμών πάνω από 65%, καθώς πάνω από 20 από τις 30 ημέρες ενός μήνα είναι καθημερινές και εργάσιμες. Επίσης, η μεταβλητή `Is_Holiday` παρουσιάζει το χαμηλότερο ποσοστό Αληθών τιμών, γεγονός που είναι λογικό καθώς υπάρχουν μόνο ελάχιστες, ή ακόμα και καθόλου (π.χ. Φεβρουάριος, Σεπτέμβριος και Νοέμβριος 2022), ημέρες σε κάθε μήνα που είναι αργίες. Ωστόσο, υπάρχουν περισσότερες ημέρες που περιλαμβάνονται σε περιόδους διακοπών, όπως φαίνεται από τη μεταβλητή `Is_Holiday_Season`. Μεταξύ των ετών, ο συνολικός αριθμός των αργιών και των ημερών σε περιόδους αργιών είναι ο ίδιος, αλλά η κατανομή τους μεταξύ των μηνών διαφέρει. Για παράδειγμα, το Πάσχα είναι μια κινητή γιορτή που παρατηρείται κυρίως τον Μάρτιο και τον Απρίλιο. Τα έτη 2022 και 2019 φαίνεται να έχουν ανάλογη κατανομή των αργιών, όπως ακριβώς και τα έτη 2020, 2018 και 2017.



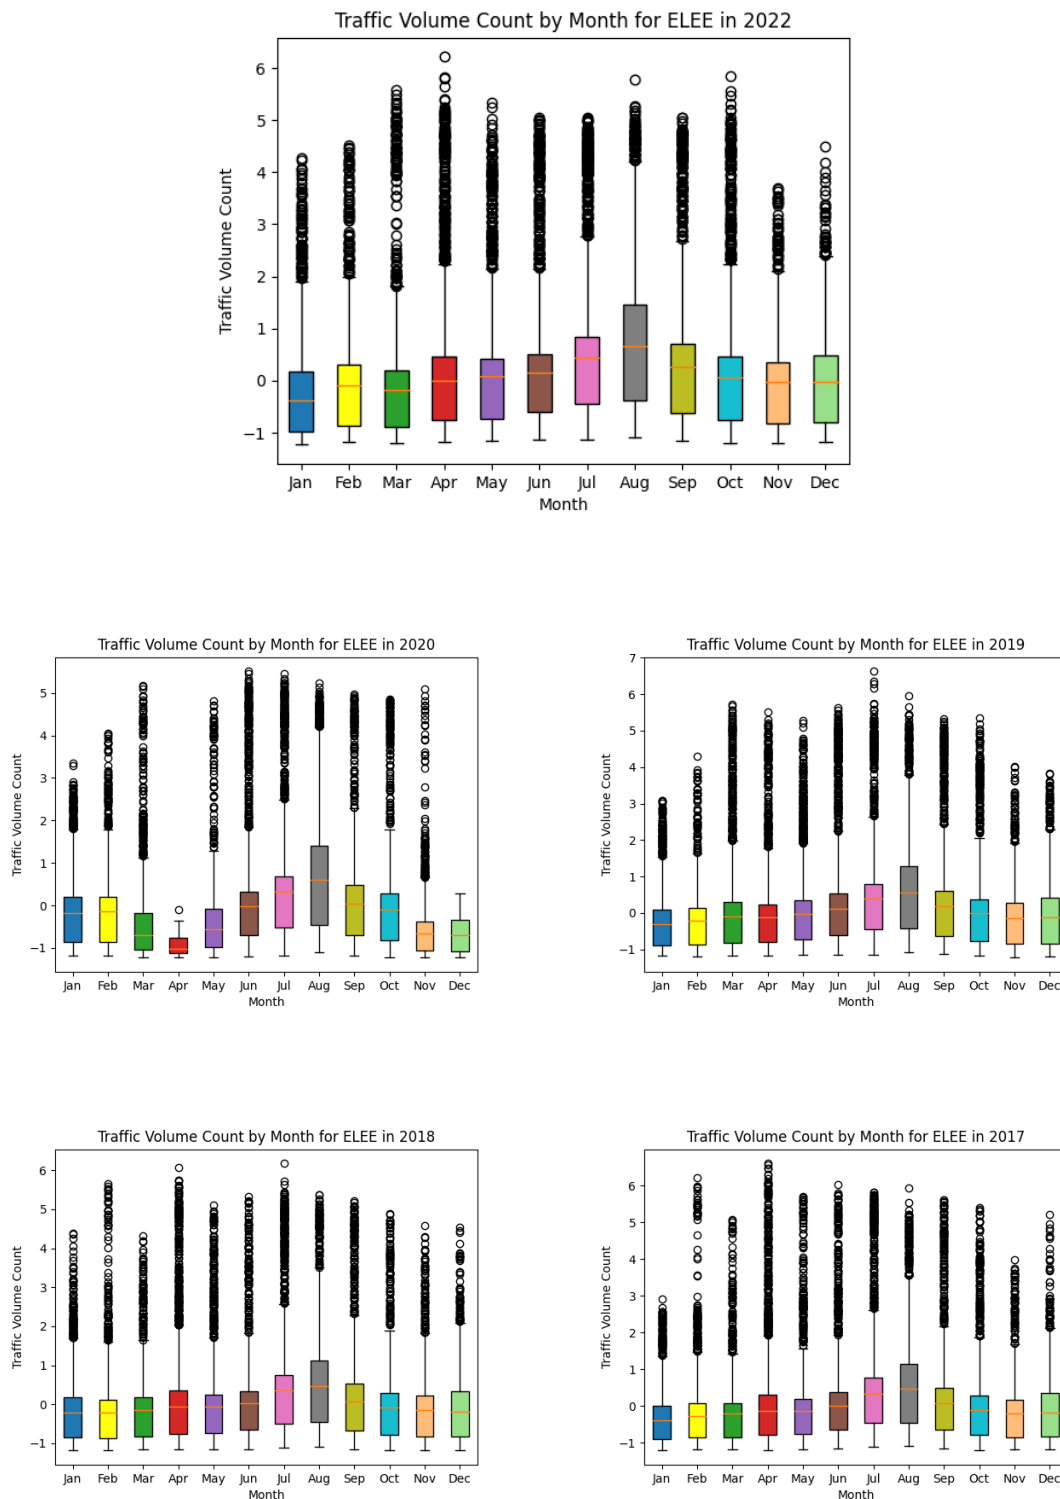
Σχήμα 4.1: Όγκος κυκλοφορίας ανά έτος για όλους τους σταθμούς διοδίων

## 4.6 Ευφυές Σύστημα Μεταφορών

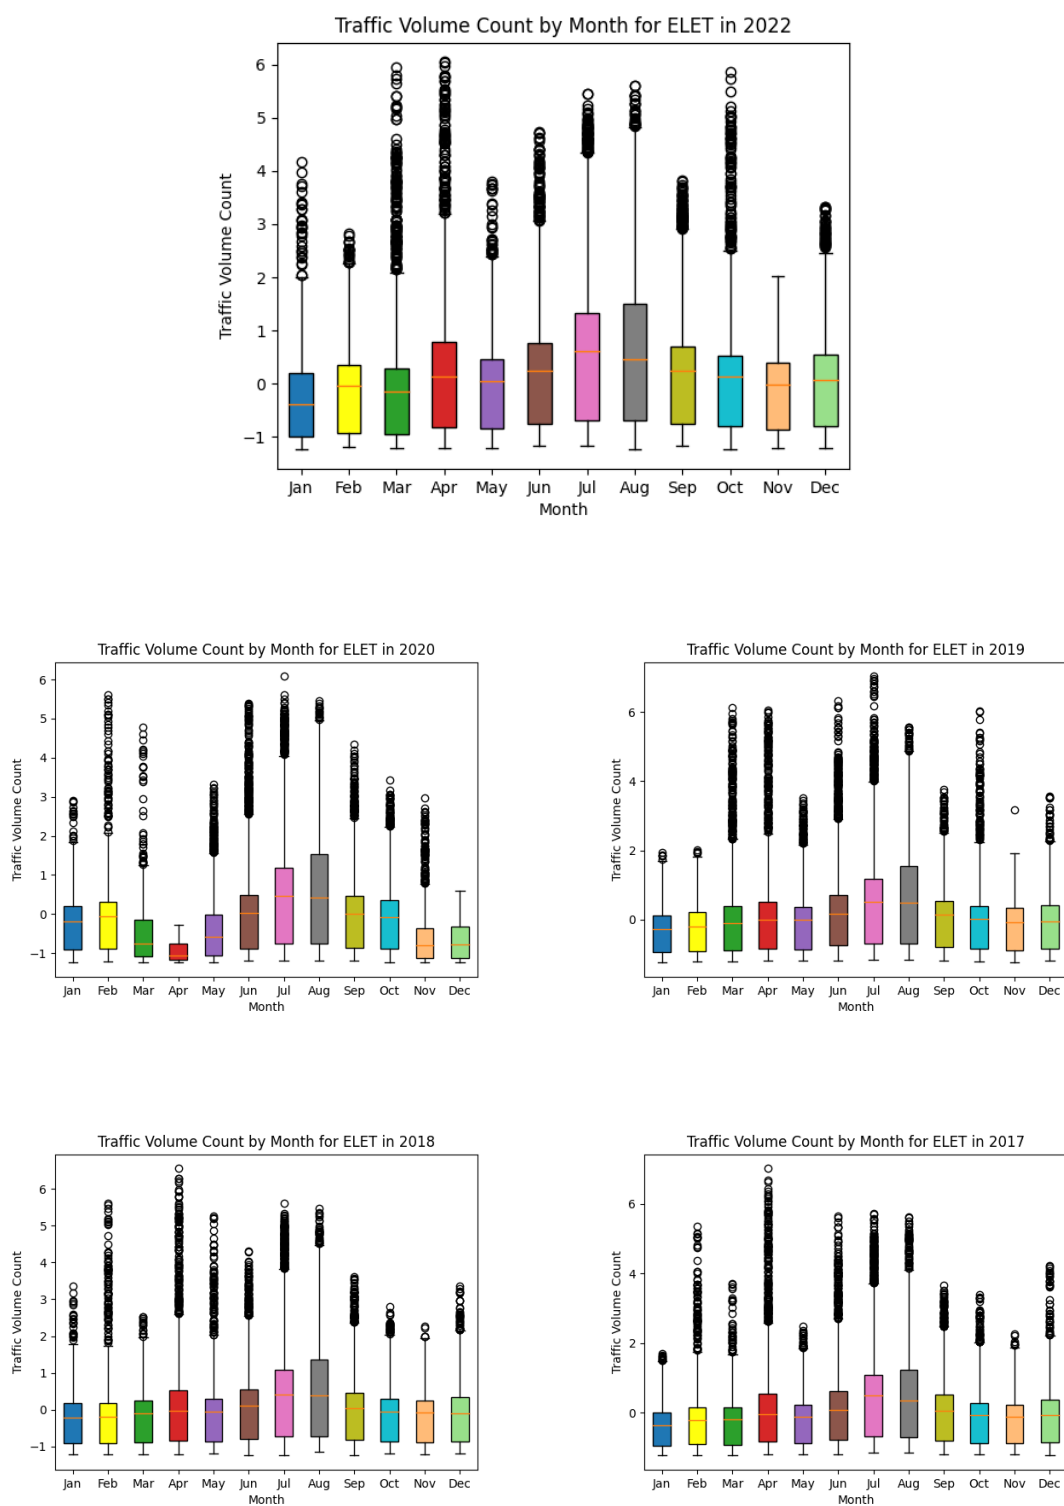
Η βαθιά μάθηση έχει αποκτήσει τεράστια δημοτικότητα τα τελευταία χρόνια λόγω των αξιοσημείωτων επιδόσεών της σε διάφορους τομείς, όπως η αναγνώριση εικόνας και ομιλίας, η επεξεργασία φυσικής γλώσσας και η πρόβλεψη χρονοσειρών. Παρ' όλα αυτά, η κλιμακωτή ανάπτυξη μοντέλων βαθιάς μάθησης σε επίπεδο παραγωγής εξακολουθεί να αποτελεί πρόκληση, καθώς απαιτεί τη δημιουργία κατάλληλων υποδομών και υπολογιστικών πόρων που μπορούν να αναπαράγουν το μοντέλο για να επιτύχουν παρόμοια αποτελέσματα με αυτά της διαδικασίας εκπαίδευσης. Ωστόσο, η εκπαίδευση ενός μοντέλου BND είναι από μόνη της μια χρονοβόρα διαδικασία που μπορεί να διαρκέσει αρκετούς μήνες, οπότε η συνολική διαδικασία, από την αρχική απόφαση για τη χρήση της βαθιάς μάθησης έως την τελική ανάπτυξη του μοντέλου, είναι ακόμη πιο περίπλοκη.

Σε αυτό το πλαίσιο, μια από τις κύριες συνεισφορές της παρούσας διατριβής είναι ο σχεδιασμός και η ανάπτυξη ενός ΕΣΜ για βελτιστοποιημένες αποφάσεις μετακίνησης και αποτελεσματική διαχείριση της κυκλοφορίας στα διόδια της Ολυμπίας Οδού και γενικότερα σε αυτοκινητόδρομους, δρόμους και γέφυρες. Το σύστημα αυτό περιλαμβάνει μια καινοτόμα συνολική αρχιτεκτονική για τη συλλογή δεδομένων σε πραγματικό χρόνο, την εκπαίδευση, τη

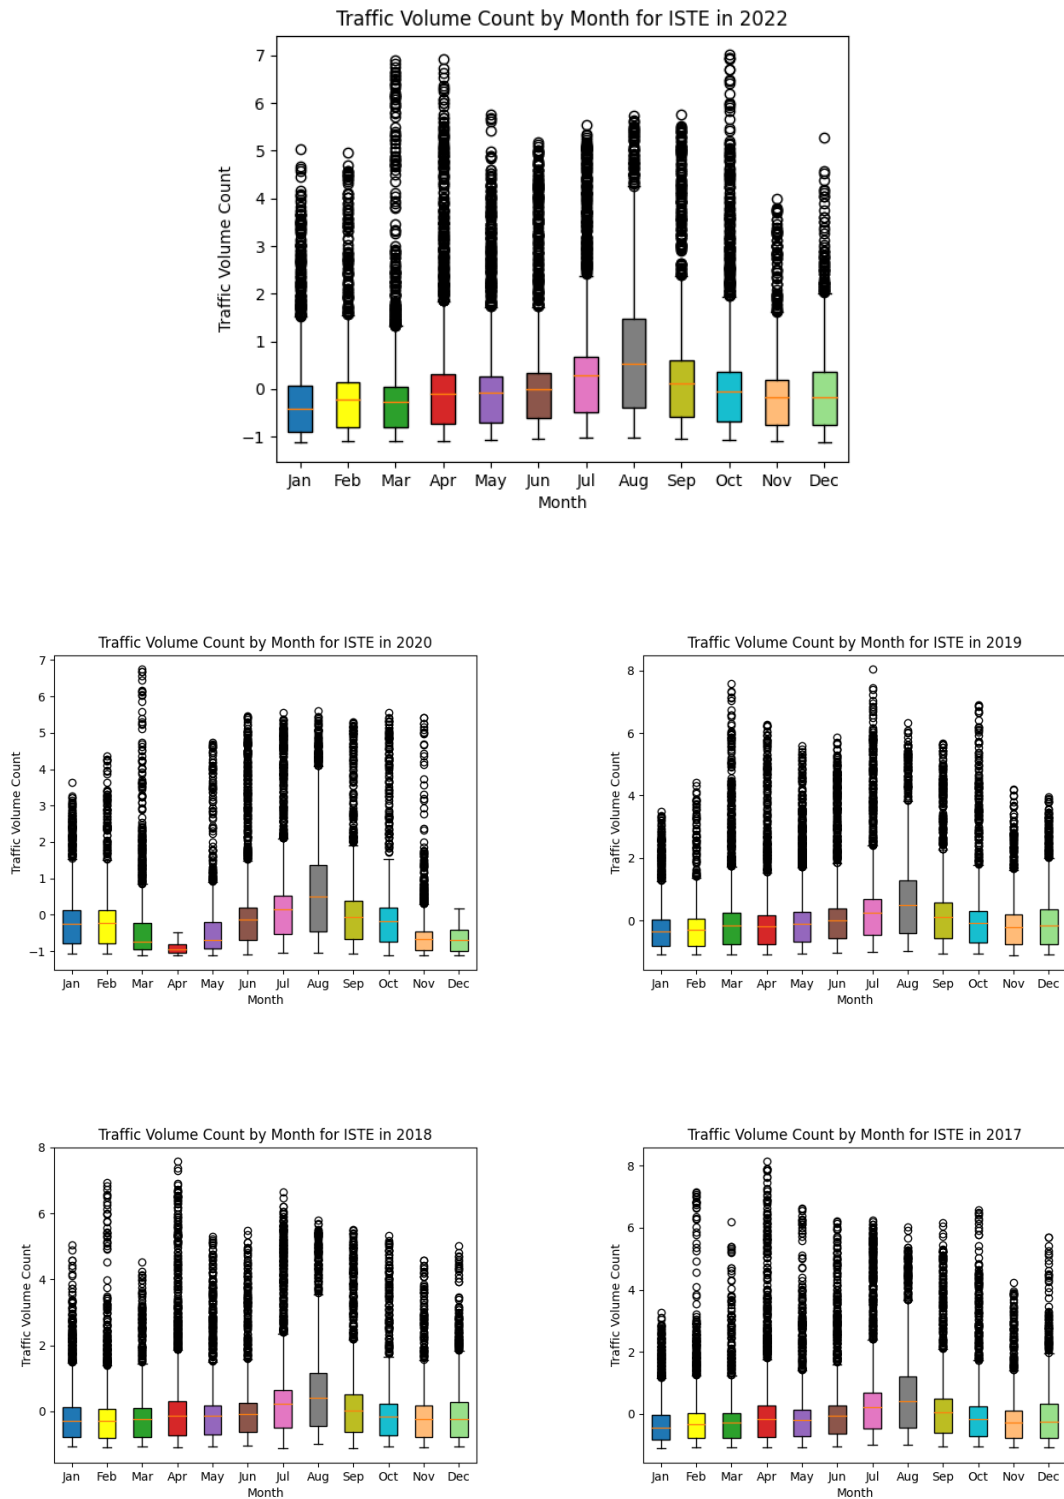




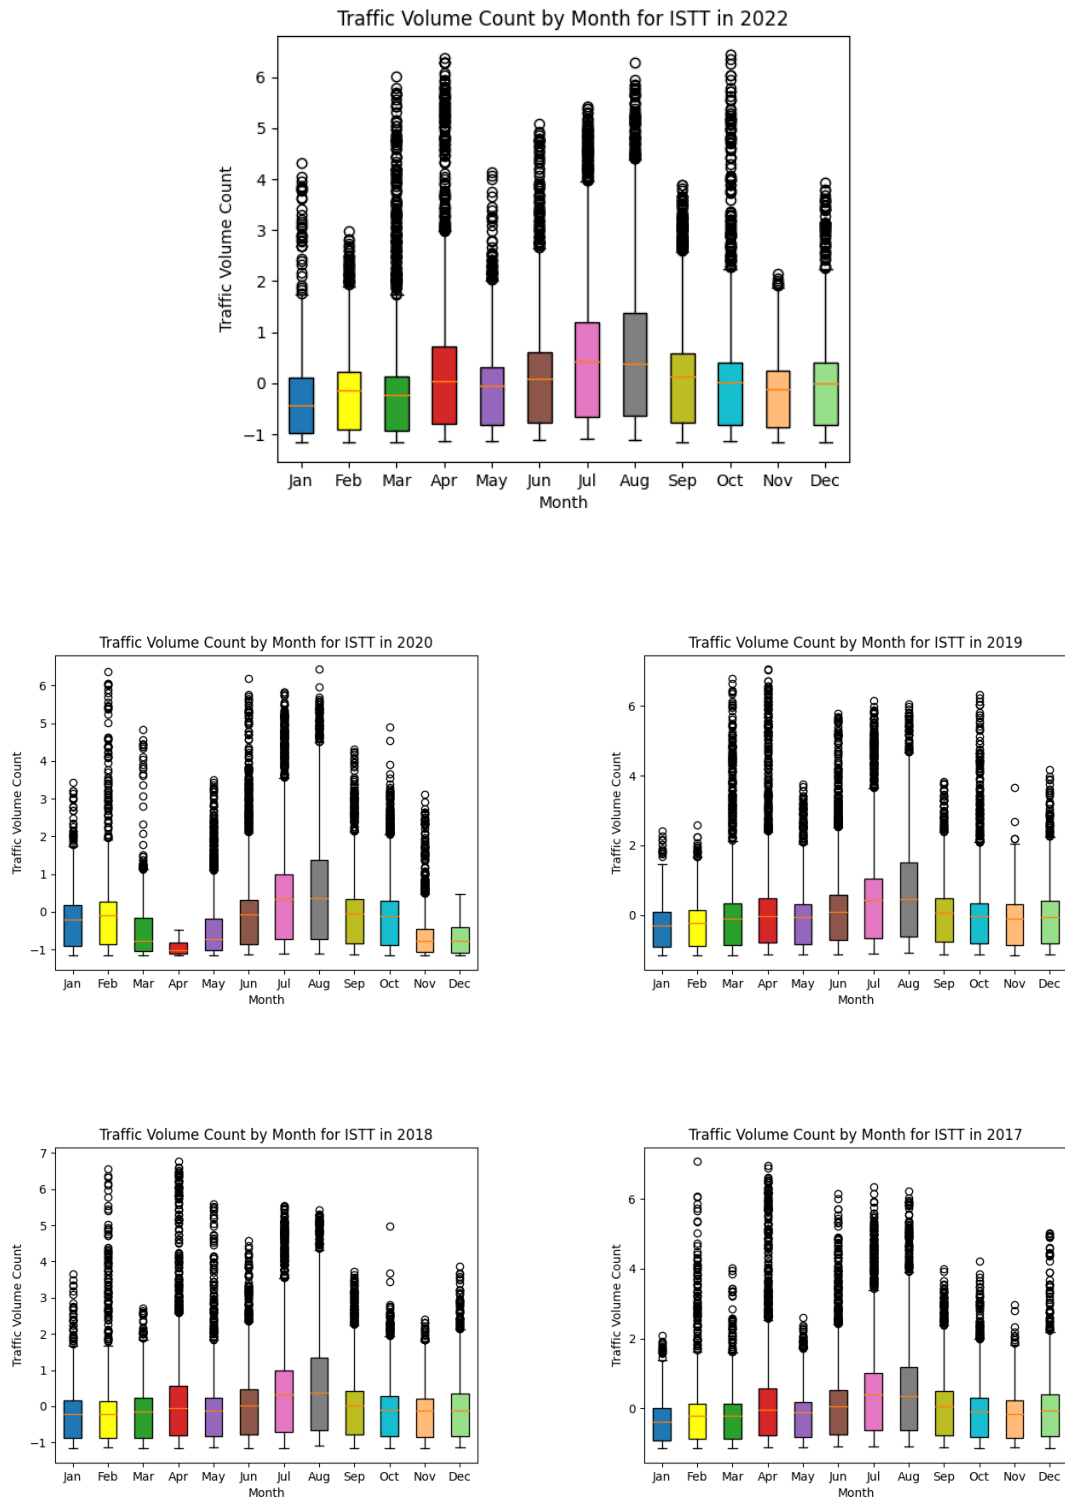
Σχήμα 4.2: Όγκος κυκλοφορίας ανά μήνα για την κατεύθυνση ELEE για τα έτη 2022, 2020, 2019, 2018 και 2017.



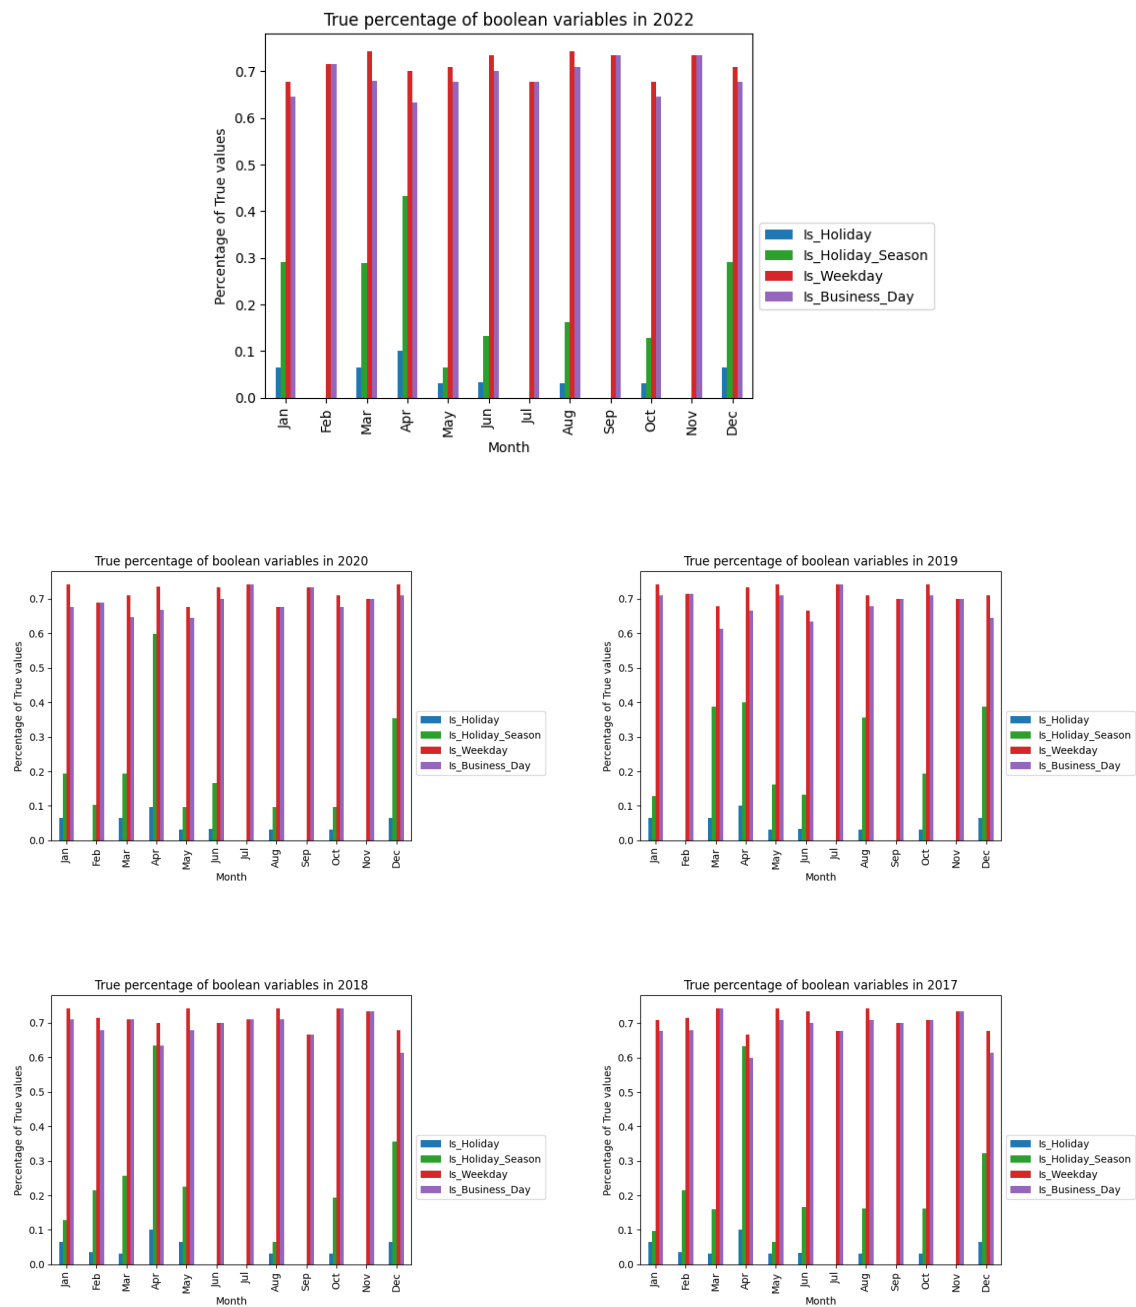
Σχήμα 4.3: Όγκος κυκλοφορίας ανά μήνα για την κατεύθυνση ELET για τα έτη 2022, 2020, 2019, 2018 και 2017.



Σχήμα 4.4: Όγκος κυκλοφορίας ανά μήνα για την κατεύθυνση ISTE για τα έτη 2022, 2020, 2019, 2018 και 2017.



Σχήμα 4.5: Όγκος κυκλοφορίας ανά μήνα για την κατεύθυνση ISTT για τα έτη 2022, 2020, 2019, 2018 και 2017.



Σχήμα 4.6: Ποσοστό Αληθών τιμών των δυαδικών μεταβλητών τα έτη 2022, 2020, 2019, 2018 και 2017.

δοκιμή και την ανάπτυξη μοντέλων χρονοσειρών, ένα διαδραστικό πλαίσιο για την οπτικοποίηση των αποτελεσμάτων και μια προγραμματιστική διεπαφή πρόβλεψης, η οποία μπορεί να χρησιμοποιηθεί τόσο για σκοπούς ανάπτυξης όσο και παραγωγής. Η παρούσα ενότητα παρέχει μια ολοκληρωμένη επισκόπηση των κύριων στοιχείων του συστήματος, των εργαλείων και των πλαισίων που χρησιμοποιήθηκαν στη διαδικασία δημιουργίας και ανάπτυξης μιας υπηρεσίας πραγματικού χρόνου με σκοπό την πρόβλεψη χρονοσειρών.

Η συνολική διαδικασία δημιουργίας και ανάπτυξης της υπηρεσίας περιλαμβάνει τα παρακάτω επιμέρους βήματα:

1. Συλλογή δεδομένων για την εκπαίδευση του μοντέλου
2. Προεπεξεργασία και σχεδιασμός χαρακτηριστικών
3. Επιλογή μοντέλου και σχεδιασμός αρχιτεκτονικής
4. Εκπαίδευση και επικύρωση μοντέλου
5. Οπτικοποίηση των αποτελεσμάτων του μοντέλου
6. Ανάπτυξη της υπηρεσίας

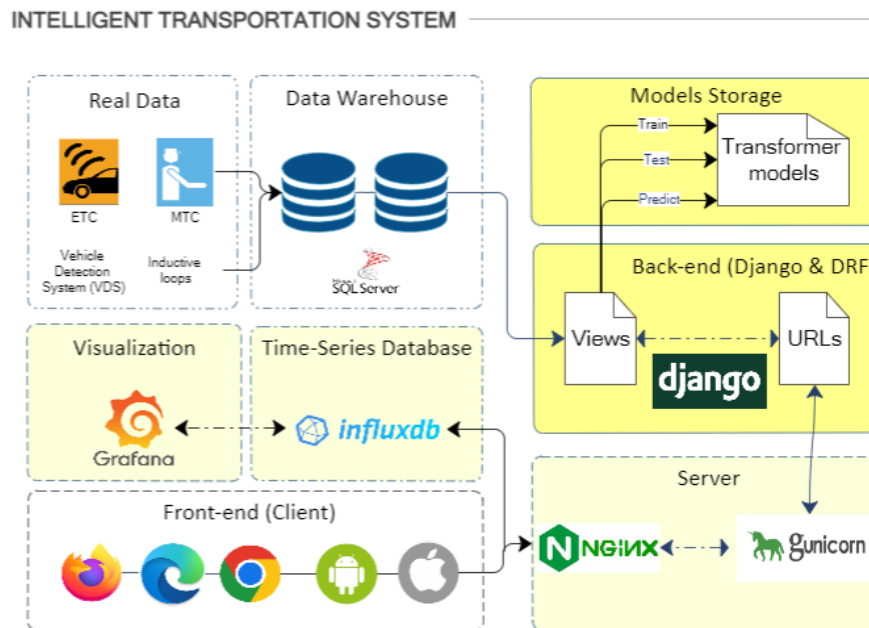
Συνολικά, το σύστημα παρέχει μια ολοκληρωμένη λύση για την πρόβλεψη χρονοσειρών σε πραγματικό χρόνο, προσφέροντας μια στιβαρή αρχιτεκτονική και εργαλεία για την ανάπτυξη και την εγκατάσταση μοντέλων σε πραγματικές εφαρμογές.

#### 4.6.1 Στοιχεία συστήματος

Το Σχήμα 4.7 παρέχει μια επισκόπηση της αρχιτεκτονικής του συστήματός μας και των κύριων συνιστωσών της ροής εργασίας της προγραμματιστικής διεπαφής. Τα στοιχεία που παρουσιάζονται στο Σχήμα 4.7 με έντονη κίτρινη απόχρωση αντιπροσωπεύουν τα κύρια τμήματα της συγκεκριμένης μελέτης, ενώ τα στοιχεία με απαλή κίτρινη απόχρωση αντιπροσωπεύουν τα μέρη στα οποία πραγματοποιήθηκαν τροποποιήσεις για τους σκοπούς της εργασίας. Όσον αφορά τα υπόλοιπα στοιχεία, δεν υπήρξε καμία τροποποίηση.

1. **Πελάτης:** Ο πελάτης στο ΕΣΜ μπορεί να είναι οποιαδήποτε συσκευή ή μια τριτογενής εφαρμογή που ζητά από τον διακομιστή τις προβλέψεις του εκπαιδευμένου μοντέλου, όπως ο ιστότοπος και η εφαρμογή της Ολυμπίας Οδού που λαμβάνουν προβλέψεις από την υπηρεσία πρόβλεψης της κυκλοφορίας.
2. **Nginx:** Ένας διακομιστής ιστού ανοικτού κώδικα που επικεντρώνεται στον υψηλό παραλληλισμό, την απόδοση και τη χαμηλή χρήση μνήμης, ενώ μπορεί επίσης να χρησιμοποιηθεί ως εξισορροπητής φορτίου<sup>2</sup> [66]. Μπορεί να λειτουργήσει υπό μεγάλα φορτία με

<sup>2</sup>Ένας εξισορροπητής φορτίου επιχειρεί να διανείμει το φόρτο εργασίας (αιτήσεις) σε πολλούς διακομιστές ή πόρους σε μια συστοιχία διακομιστών. Στόχος του εξισορροπιστή φορτίου είναι η ελαχιστοποίηση του χρόνου απόκρισης και η μεγιστοποίηση της απόδοσης, αποφεύγοντας την υπερφόρτωση οποιουδήποτε μεμονωμένου πόρου.



Σχήμα 4.7: Αρχιτεκτονική του ευφυούς συστήματος κυκλοφορίας για εφαρμογές πραγματικού χρόνου

τη δημιουργία διεργασιών εργασίας, κάθε μία από τις οποίες μπορεί να χειριστεί χιλιάδες συνδέσεις. Ο διακομιστής NGINX λειτουργεί επίσης και ως αντίστροφος διακομιστής μεσολάβησης, που λαμβάνει αιτήσεις HTTP και τις προωθεί σε διάφορες εφαρμογές υποδοχής. Με άλλα λόγια, χρησιμοποιείται για την εξυπηρέτηση στατικού περιεχομένου και για τη διαμεσολάβηση αιτήσεων στον διακομιστή εφαρμογών Gunicorn [22].

3. **Gunicorn:** Ένας διακομιστής HTTP που χρησιμοποιείται για την εκτέλεση της διαδικτυακής εφαρμογής Django [22, 27]. Δημιουργεί πολλαπλές διακλαδώσεις, που ονομάζονται 'εργάτες', για τη διεκπεραίωση των αιτήσεων, παρέχοντας υψηλό επίπεδο συγχρονισμού και επιτρέποντας τη διεκπεραίωση πολλαπλών αιτήσεων ταυτόχρονα. Το Gunicorn λειτουργεί για διάφορα διαδικτυακά πλαίσια Python και είναι απαραίτητο για την εισαγωγή του Django στην παραγωγή. Το Django (και η Python γενικότερα) χρειάζεται ένα Web Server Gateway Interface (WSGI) [33] για να χειρίζεται όλες τις συνδέσεις με έναν διακομιστή ιστού όπως ο Nginx.
4. **Django και DRF:** Το Django [27] είναι ένα υψηλού επιπέδου διαδικτυακό πλαίσιο της Python που χρησιμοποιείται για την ανάπτυξη σύνθετων διαδικτυακών εφαρμογών και υπηρεσιών γρήγορα και αποτελεσματικά. Το Django REST Framework (DRF) είναι μια βιβλιοθήκη λογισμικού που επεκτείνει το Django για να διευκολύνει τη δημιουργία προγραμματιστικών διεπαφών σύμφωνα με το πρότυπο REST [67]. Το DRF περιλαμβάνει χαρακτηριστικά όπως η σειριοποίηση, ο έλεγχος ταυτότητας και τα δικαιώματα, τα οποία είναι ειδικά σχεδιασμένα για τη δημιουργία προγραμματιστικών διεπαφών. Το DRF χρησιμοποιήθηκε για τον ορισμό των τελικών σημείων και των μεθόδων για τις

προγραμματιστικές διεπαφές και για τον χειρισμό των εισερχόμενων αιτήσεων από το Gunicorn.

5. **Pytorch:** Ένα πλαίσιο μηχανικής μάθησης ανοικτού κώδικα που παρέχει μια σειρά εργαλείων και βιβλιοθηκών, χτισμένων πάνω στη βιβλιοθήκη Torch, για την ανάπτυξη και την εκπαίδευση νευρωνικών δικτύων [63]. Η PyTorch χρησιμοποιείται ευρέως στην έρευνα και τη βιομηχανία για την ανάπτυξη μοντέλων βαθιάς μάθησης. Στο πλαίσιο αυτής της παρουσιαζόμενης αρχιτεκτονικής συστήματος, η PyTorch χρησιμοποιήθηκε για την ανάπτυξη των μοντέλων πρόβλεψης που βασίζονται σε δίκτυα μετασχηματιστών.
6. **MS SQL Server:** Ο Microsoft SQL Server [56] είναι ένα σύστημα διαχείρισης σχεσιακών βάσεων δεδομένων που χρησιμοποιείται για την αποθήκευση δεδομένων στο πλαίσιο της διαδικασίας ETL, σε διάφορες μορφές. Ο MS SQL Server έχει σχεδιαστεί για την ασφαλή και αποτελεσματική διαχείριση και αποθήκευση μεγάλου όγκου δεδομένων. Αποτελεί δημοφιλή επιλογή για πολλές εφαρμογές υψηλής έντασης δεδομένων, συμπεριλαμβανομένων εκείνων που περιλαμβάνουν μεγάλους όγκους δεδομένων χρονοσειρών. Ένας MS SQL Server χρησιμοποιήθηκε για την αποθήκευση (i) δεδομένων σχετικών με τον όγκο κυκλοφορίας συγκεκριμένων σταθμών διοδίων, (ii) στατιστικών στοιχείων κυκλοφορίας, (iii) δεδομένων ημερολογίου και (iv) μετεωρολογικών προβλέψεων.
7. **InfluxDB:** Μια βάση δεδομένων χρονοσειρών ανοικτού κώδικα που είναι βελτιστοποιημένη για την αποθήκευση και την αναζήτηση δεδομένων με χρονοσήμανση. Έχει σχεδιαστεί για να διαχειρίζεται μεγάλους όγκους δεδομένων και παρέχει έναν απλό και αποτελεσματικό τρόπο αποθήκευσης και ανάκτησης δεδομένων χρονοσειρών μέσω 'κάδων'. Η InfluxDB [72] χρησιμοποιήθηκε για την αποθήκευση των αποτελεσμάτων της πρόβλεψης και για τον έλεγχο της απόδοσης της πρόβλεψης σε πραγματικό χρόνο. Αυτό επέτρεψε στο σύστημα να παρέχει επικαιροποιημένες πληροφορίες σχετικά με την ακρίβεια και την αξιοπιστία του μοντέλου πρόβλεψης, κάτι που είναι απαραίτητο για τη λήψη αποφάσεων σε πολλές εφαρμογές.
8. **Grafana:** Μια πλατφόρμα οπτικοποίησης και ανάλυσης ανοικτού κώδικα που χρησιμοποιείται για την οπτικοποίηση δεδομένων χρονοσειρών [15]. Παρέχει ένα ευρύ φάσμα εργαλείων και χαρακτηριστικών για τη δημιουργία ταμπλό, γραφημάτων και άλλων οπτικοποιήσεων που μπορούν να χρησιμοποιηθούν για την παρακολούθηση της απόδοσης ενός συστήματος σε πραγματικό χρόνο. Η Grafana χρησιμοποιήθηκε για την παρακολούθηση της απόδοσης των προβλέψεων και για την εμφάνιση των αποτελεσμάτων των προβλέψεων σε πραγματικό χρόνο.
9. **TensorBoard:** Μια διαδικτυακή εφαρμογή για τη γραφική αναπαράσταση και παρακολούθηση της διαδικασίας εκπαίδευσης των μοντέλων [89]. Παρέχει ένα ευρύ φάσμα χαρακτηριστικών για την οπτικοποίηση και την ανάλυση της διαδικασίας εκπαίδευσης των μοντέλων βαθιάς μάθησης. Αυτό περιλαμβάνει την απεικόνιση των καμπυλών απώλειας και ακρίβειας, την οπτικοποίηση της δομής του δικτύου και την εξέταση της κατανομής των βαρών και των πωλώσεων.



## Κεφάλαιο 5

# Μοντέλα Μετασχηματιστών

Σε αυτό το κεφάλαιο εξετάζονται τα μοντέλα μετασχηματιστών από τη βιβλιογραφία που χρησιμοποιήθηκαν στα πειράματα της παρούσας διπλωματικής εργασίας. Συγκεκριμένα, θα αναλυθούν η γενική αρχιτεκτονική και τα κύρια στοιχεία του βασικού μοντέλου μετασχηματιστή [88], ο οποίος αναφέρεται ως *vanilla Transformer*, καθώς και ορισμένες παραλλαγές (σε επίπεδο μονάδας προσοχής) για την πρόβλεψη χρονοσειρών, όπως ο *Informer* [104], ο *FEDFormer* [105], ο *Autoformer* [97] και ο *ETSFormer* [96].

Οι κύριες αρχιτεκτονικές αυτών των παραλλαγών είναι παρόμοιες με τον *vanilla Transformer*, με μικρές τροποποιήσεις σε ορισμένα τμήματα της αρχιτεκτονικής. Σε αυτό το κεφάλαιο θα συζητηθούν οι παραλλαγές που έχουν τροποποιήσει την μονάδα της προσοχής της αρχιτεκτονικής του μετασχηματιστή. Συνολικά, αυτό το κεφάλαιο παρέχει μια εμπειρισταωμένη επισκόπηση των μοντέλων μετασχηματιστών που χρησιμοποιήθηκαν στα πειράματα και των επιρροών τους στην έρευνα.

### 5.1 Vanilla Transformer

Οι Vaswani et al. [88] πρότειναν το μοντέλο *vanilla Transformer* στην δημοσίευση “*Attention Is All You Need*”, η οποία εισήγαγε την έννοια του μηχανισμού προσοχής για μοντέλα ακολουθίας-σε-ακολουθία, ιδίως για τη μηχανική μετάφραση. Όπως περιγράφεται στην Ενότητα 3.2.1, ο *vanilla Transformer* είναι ένα μοντέλο ακολουθίας-σε-ακολουθία σχεδιασμένο σύμφωνα με την αρχιτεκτονική κωδικοποιητή-αποκωδικοποιητή. Τόσο ο κωδικοποιητής όσο και ο αποκωδικοποιητής αποτελούνται από πολλαπλά τμήματα, με κάθε τμήμα να έχει πανομοιότυπη δομή. Κάθε τμήμα κωδικοποιητή περιλαμβάνει μια μονάδα αυτοπροσοχής πολλαπλών κεφαλών και ένα δίκτυο προώθησης κατά θέση, ενώ κάθε τμήμα αποκωδικοποιητή προσθέτει μοντέλα διασταυρούμενης προσοχής μεταξύ της μονάδας αυτοπροσοχής πολλαπλών κεφαλών και του δικτύου προώθησης κατά θέση. Η ακολουθία εισόδου επεξεργάζεται πρώτα από τον κωδικοποιητή, ο οποίος παράγει μια ακολουθία κρυφών καταστάσεων που συλλαμβάνουν τις απαραίτητες πληροφορίες της ακολουθίας εισόδου και στη συνέχεια ο αποκωδικοποιητής χρησιμοποιεί αυτές τις κρυφές καταστάσεις για να παράγει την ακολουθία εξόδου ή πρόβλεψης.

Το βασικό συστατικό του μοντέλου μετασχηματιστή είναι ο μηχανισμός αυτοπροσοχής ή

που ακολουθεί το μοντέλο Query-Key-Value (QKV) για τον υπολογισμό των βαθμολογιών προσοχής μεταξύ διαφορετικών τμημάτων της ακολουθίας εισόδου (Ενότητα 3.2.2). Ο μετασχηματιστής χρησιμοποιεί προσοχή πολλαπλών κεφαλών με πολλαπλά διαφορετικά σύνολα μαθημένων προβολών αντί για μία μόνο συνάρτηση προσοχής.

Ένα άλλο βασικό συστατικό των μετασχηματιστών είναι η κωδικοποίηση θέσης, η οποία επιτρέπει στα μοντέλα να ενσωματώνουν και να κωδικοποιούν πληροφορίες θέσης προκειμένου να διατηρείται η χρονολογική σειρά των στοιχείων της ακολουθίας εισόδου. Αυτό επιτυγχάνεται προσθέτοντας ένα σταθερό διάνυσμα κωδικοποίησης θέσης στα εμφυτεύματα εισόδου ή μαθαίνοντας ένα σύνολο εμφυτευμάτων θέσης [35, 26]. Γενικά, η κωδικοποίηση θέσης προστίθεται στα εμφυτεύματα εισόδου και τροφοδοτείται στο μετασχηματιστή.

Συμπερασματικά, το μοντέλο μετασχηματιστή που εισήγαγαν οι Vaswani et al. [88] είναι μια ισχυρή αρχιτεκτονική νευρωνικών δικτύων που έχει τη δυνατότητα να συλλαμβάνει σύνθετες εξαρτήσεις και πληροφορίες από ακολουθίες δεδομένων. Ο μηχανισμός αυτοπροσοχής και η κωδικοποίηση θέσης είναι τα δύο βασικά στοιχεία που του επιτρέπουν να διατηρεί τις διαδοχικές πληροφορίες, ενώ παράλληλα απαλλάσσεται από τη συμβατική έννοια της επανάληψης [39]. Αυτές οι τεχνικές έχουν οδηγήσει σε πολυάριθμες προόδους διάφορες εργασίες μηχανικής μάθησης, όπως η μηχανική μετάφραση και η γλωσσική μοντελοποίηση. Επιπλέον, οι τεχνικές αυτές διευκολύνουν την αξιοποίηση του παραλληλισμού που προσφέρουν συγκεκριμένα κυκλώματα υλικού όπως οι κάρτες γραφικών, καθιστώντας τους μετασχηματιστές ακρογωνιαίο λίθο της έρευνας, που συνεχίζει να εμπνέει νέες εξελίξεις και εφαρμογές όχι μόνο στον τομέα της επεξεργασίας φυσικής γλώσσας αλλά και σε άλλες εργασίες μηχανικής και βαθιάς μάθησης.

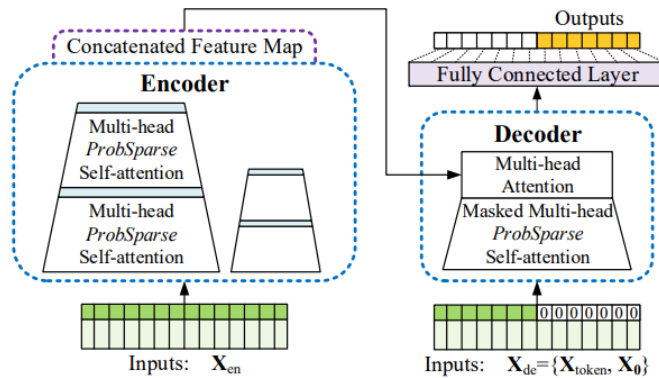
## 5.2 Informer

Οι Zhou et al. πρότειναν τον Informer [104] (Σχήμα 5.1) προκειμένου να αντιμετωπίσουν ορισμένους σημαντικούς περιορισμούς του vanilla Transformer για την πρόβλεψη χρονοσειρών μακράς ακολουθίας:

1. Ο μηχανισμός αυτοπροσοχής έχει τετραγωνική πολυπλοκότητα χρόνου και μνήμης ανά στρώμα,  $\mathcal{O}(L^2)$ . Προκειμένου να βελτιώσει την πολυπλοκότητα υπολογισμού, ο Informer χρησιμοποιεί τον μηχανισμό αυτο-προσοχής *ProbSparse* που επιτυγχάνει πολυπλοκότητα χρόνου και μνήμης  $\mathcal{O}(L \log L)$ .
2. Η στοίβα των  $J$  στρωμάτων οδηγεί τη συνολική χωρική πολυπλοκότητα σε  $\mathcal{O}(J \cdot L^2)$ , γεγονός που περιορίζει την επεκτασιμότητα του μοντέλου. Για να αντιμετωπιστεί αυτό το ζήτημα, προτείνεται μια λειτουργία απόσπασης της αυτοπροσοχής που προκρίνει τους κυρίαρχους βαθμούς προσοχής σε  $J$  στρώματα στοίβαξης και επιτυγχάνει  $\mathcal{O}((2-\epsilon)L \log L)$  συνολική χωρική πολυπλοκότητα.
3. Η επαναληπτική εξαγωγή προβλέψεων είναι εξίσου αργή με τα μοντέλα που βασίζονται σε ANΔ για μεγάλες εξόδους. Για το λόγο αυτό, οι Zhou et al. πρότειναν μια γενετική

μέθοδο άμεσης πρόβλεψης, έτσι ώστε το μοντέλο να προβλέπει άμεσα όλα τα μελλοντικά χρονικά βήματα ταυτόχρονα, δεδομένης της διαθέσιμης πληροφορίας εισόδου.

4. Οι χρονοσημάνσεις δεν χρησιμοποιούνται συνήθως στο μοντέλο vanilla Transformer. Όταν πρόκειται για δεδομένα χρονοσειρών σε σενάρια του πραγματικού κόσμου, είναι συνήθως διαθέσιμες πληροφορίες χρόνου, όπως ημερολογιακές χρονικές ενδείξεις (π.χ. δευτερόλεπτα, λεπτά, ώρες, εβδομάδα, μήνας και έτος) και ειδικές χρονικές ενδείξεις (π.χ. αργίες και γεγονότα), οι οποίες μπορούν να παρέχουν πολύτιμες πληροφορίες. Για να αντιμετωπιστεί αυτός ο περιορισμός, ο Informer εισήγαγε μια προσέγγιση για την κωδικοποίηση των χρονοσήμων ως πρόσθετη κωδικοποίηση θέσης με τη χρήση πιο σύνθετων επιπέδων εμφύτευσης. Οι Autoformer [97] και FEDformer [105], που θα εξηγηθούν παρακάτω, υιοθέτησαν επίσης παρόμοιες τεχνικές κωδικοποίησης χρονοσήμανσης. Με την ενσωμάτωση της συγκεκριμένης κωδικοποίησης, τα μοντέλα μπορούν να συλλάβουν καλύτερα τα χρονοεξαρτώμενα πρότυπα και να βελτιώσουν τις επιδόσεις τους σε πραγματικές εφαρμογές.



Σχήμα 5.1: Αρχιτεκτονική του Informer (Πηγή: [104])

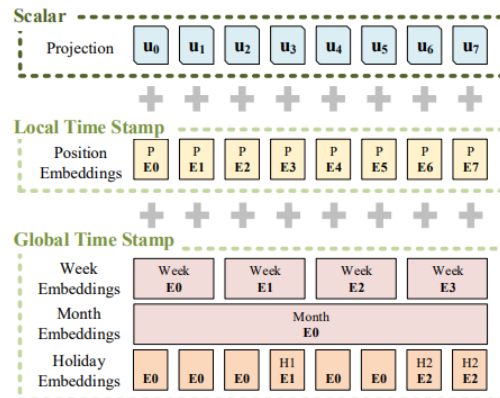
Στην εργασία τους, οι Zhou et al. [104] διαπίστωσαν ότι ο χάρτης χαρακτηριστικών της αυτοπροσοχής όχι μόνο παρουσιάζει αραιότητα, αλλά και ακολουθεί μια κατανομή «μακράς ουράς», γεγονός που σημαίνει ότι μερικά ζεύγη στοιχείων συμβάλλουν σημαντικά στη συνολική προσοχή, ενώ τα υπόλοιπα μπορούν να αγνοηθούν. Ως αποτέλεσμα, πρότειναν τον μηχανισμό αυτοπροσοχής *ProbSparse*, ο οποίος επιτρέπει σε κάθε κλειδί να παρακολουθεί μόνο τα  $T - u$  κυρίαρχα ερωτήματα. Αυτός ο μηχανισμός εκφράζεται μαθηματικά στην Εξίσωση 5.1

$$ProbSparse(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}(\tilde{\mathbf{Q}}\mathbf{K}^T) / \sqrt{d_k} \quad (5.1)$$

όπου,  $\tilde{\mathbf{Q}}$  είναι ένας αραιός πίνακας ίδιου μεγέθους με τον  $\mathbf{Q}$ , που περιέχει μόνο τα  $T - u$  κυρίαρχα ερωτήματα με βάση τις ομοιότητες ερωτημάτων και κλειδιών. Η επιλογή αυτή γίνεται με τη χρήση μιας μέτρησης αραιότητας ερωτημάτων, η οποία είναι μια προσέγγιση της απόκλισης Kullback-Leibler.


Εκτός από το *ProbSparse*, μια άλλη σημαντική συνεισφορά των Zhou et al. [104] είναι η χρήση μιας ομοιόμορφης αναπαράστασης εισόδου στο μοντέλο τους, η οποία αποτυπώνει τις

εξαρτήσεις μεγάλης εμβέλειας. Αυτό επιτυγχάνεται με την ενσωμάτωση καθολικών πληροφοριών όπως ιεραρχικές χρονοσημάνσεις (εβδομάδα, μήνας και έτος) και αγνωστικές χρονοσημάνσεις (αργίες, γεγονότα) μέσω εκπαιδευόμενων εμφυτευμάτων με περιορισμένο μέγεθος λεξιλογίου για λόγους απόδοσης. Η αναπαράσταση της εισόδου αποτελείται από τρία ξεχωριστά μέρη: (i) μια κλιμακωτή προβολή, (ii) μια τοπική (θέση) και (iii) μια καθολική εμφύτευση χρονοσημάνσεων, όπως φαίνεται στο Σχήμα 5.2. Οι εξωγενείς εισόδοι εκτός από τις χρονοσημάνσεις, που συμβολίζονται ως  $x_i^t$ , προβάλλονται σε ένα  $d_{model}$ -διάστατο διάνυσμα  $u_i^t$  χρησιμοποιώντας 1-D φίλτρα συνελίξεων, όπως φαίνεται στο Σχήμα 5.3.



Σχήμα 5.2: Η αναπαράσταση εισόδου του Informer [104]

Η τελική κρυφή αναπαράσταση του κωδικοποιητή προκύπτει από τη συνένωση των εξόδων όλων των στοιβών, γνωστών και ως χαρτών χαρακτηριστικών. Η κύρια στοιβή, η οποία λαμβάνει ολόκληρη την ακολουθία εισόδου, παρουσιάζεται στο Σχήμα 5.3. Τα κόκκινα στρώματα αναπαριστούν εσωτερικό γινόμενο πινάκων, οι οποίοι αποκτούν κλιμακωτή μείωση εφαρμόζοντας την διάσπαση της αυτοπροσοχής σε κάθε στρώμα. Αυτή η λειτουργία διάσπασης βοηθά στη δημιουργία ενός πιο εστιασμένου χάρτη χαρακτηριστικών αυτοπροσοχής στο επόμενο στρώμα, δίνοντας προτεραιότητα στις επικρατούσες τιμές προσοχής με κυρίαρχα χαρακτηριστικά και αποκλείοντας τις περιττές πληροφορίες για τα επόμενα στρώματα.

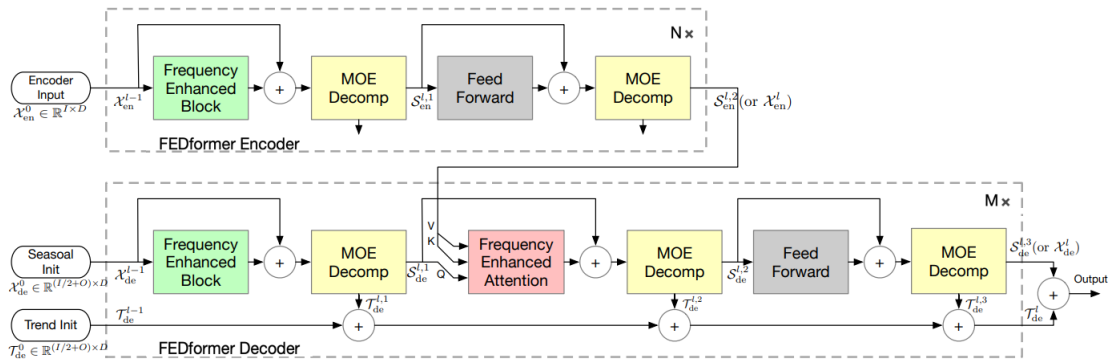


Σχήμα 5.3: Αρχιτεκτονική του κωδικοποιητή του Informer [104]

### 5.3 FEDFormer

Η επόμενη αρχιτεκτονική μετασχηματιστή που θα εξεταστεί είναι ο FEDFormer που προτάθηκε επίσης από τους Zhou et al. [105]. Το όνομα FEDFormer προέρχεται από το Frequency Enhanced Decomposition Transformer (μετασχηματιστής αποσύνθεσης ενισχυμένης συχνότητας), επειδή εφαρμόζει αποσύνθεση χρονοσειρών στην εποχική συνιστώσα και στην συνιστώσα τάσης, όπως περιγράφεται στην Ενότητα 2.2, εφαρμόζοντας τη λειτουργία προσοχής στο πεδίο της συχνότητας. Συνδυάζοντας την ανάλυση συχνοτήτων, ιδίως την ανάλυση Φουριερ, με τη μέθοδο του μετασχηματιστή για τη μακροπρόθεσμη πρόβλεψη χρονοσειρών, επιτυγχάνει γραμμικό υπολογιστικό κόστος. Για να γίνει αυτό, οι Zhou et al. πρότειναν δύο διαφορετικούς τύπους ενισχυμένων μπλοκ, τα ενισχυμένα μπλοκ *Fourier* και *Wavelet*, τα οποία είναι ισοδύναμα με τα μπλοκ αυτοπροσοχής και διασταυρούμενης προσοχής.

Προκειμένου να αναπαραστήσει κατάλληλα την πληροφορία σε χρονοσειρές χρησιμοποιώντας την ανάλυση Fourier, ο FEDFormer επιλέγει τυχαία ένα υποσύνολο σταθερού μεγέθους συνιστωσών συχνότητας, συμπεριλαμβανομένων τόσο των υψηλών όσο και των χαμηλών συχνοτήτων. Παρόλο που η διατήρηση όλων των συνιστωσών Fourier είναι μη απωλεστική, δηλαδή όλες οι ιστορικές πληροφορίες λαμβάνονται υπόψη στο μοντέλο, ενδέχεται να οδηγήσει σε υπερπροσαρμογή και, συνεπώς, σε ανακριβή πρόβλεψη. Ομοίως, τα ορθογώνια πολυώνυμα wavelet, όπως τα πολυώνυμα Legendre, μπορούν επίσης να χρησιμοποιηθούν για τη σύλληψη πληροφοριών σε χρονοσειρές. Η αναπαράσταση με βάση τα wavelets είναι πιο αποτελεσματική στη σύλληψη τοπικών προτύπων στις χρονοσειρές και συνεπώς μπορεί να είναι πιο αποτελεσματική για ορισμένες εργασίες πρόβλεψης.



Σχήμα 5.4: Αρχιτεκτονική του FEDFormer (Πηγή: [105])

Τα τρία κύρια στοιχεία της αρχιτεκτονικής του FEDFormer (Σχήμα 5.4) είναι τα ακόλουθα:

1. Frequency Enhanced Block: έχει δύο διαφορετικές εκδόσεις οι οποίες υλοποιούνται μέσω του διακριτού μετασχηματισμού Fourier και Wavelet, αντίστοιχα και μπορούν να αντικαταστήσουν απρόσκοπτα το μπλοκ αυτοπροσοχής.
2. Frequency Enhanced Attention: έχει δύο διαφορετικές εκδόσεις οι οποίες υλοποιούνται μέσω προβολής του διακριτού μετασχηματισμού Fourier και Wavelet, αντίστοιχα με

βάση τη μέθοδο προσοχής και μπορούν να αντικαταστήσουν το μπλοκ διασταυρούμενης προσοχής.

3. Mixture of Experts Decomposition block (MOEDecomp): Περιέχει ένα σύνολο φίλτρων μέσης τιμής με διαφορετικά μεγέθη για την εξαγωγή πολλαπλών συνιστωσών τάσης από το σήμα εισόδου και ένα σύνολο βαρών που εξαρτώνται από τα δεδομένα για τον συνδυασμό τους ως τελική τάση (Εξίσωση 5.2)

$$X_{trend} = Softmax(L(x)) * (F(x)) \quad (5.2)$$

όπου  $F(\cdot)$  είναι ένα σύνολο φίλτρων συγκέντρωσης μέσω όρων και  $Softmax(L(x))$  είναι τα βάρη για την ανάμειξη αυτών των εξαγόμενων τάσεων.

## 5.4 ETSFormer

Ο ETSFormer [96] είναι η αρχιτεκτονική μετασχηματιστή που μελετήθηκε και αξιολογήθηκε εκτενώς στην παρούσα διατριβή. Εμπνευσμένοι από τις μεθόδους εκθετικής εξομάλυνσης που συζητήθηκαν στο Κεφάλαιο 2, οι Woo et al. πρότειναν τον εκθετικό μετασχηματιστή χρονοσειρών (Exponential Time-Series Transformer), ή εν συντομία ETSFormer.

Καταρχάς, ο ETSformer ενσωματώνει τις επαγωγικές μεροληψίες των δομών χρονοσειρών μέσω μιας αποσύνθεσης κατά στρώματα που διαχωρίζει τη χρονοσειρά σε τρεις συνιστώσες: (i) επίπεδο, (ii) ανάπτυξη και (iii) εποχικότητα. Οι συνιστώσες επιπέδου και ανάπτυξης συνδυάζονται και σχηματίζουν τη συνιστώσα τάσης. Αυτή η αποσύνθεση βασίζεται στην προσθετική μέθοδο Holt-Winters, η οποία επιτρέπει τη μοντελοποίηση των πολύπλοκων εξαρτήσεων των λανθανόντων προτύπων ανάπτυξης και εποχικότητας που εξάγονται από τον ETSFormer. Συγκεκριμένα, ελέγχοντας τους σταθμισμένους μέσους όρους των εξισώσεων εξομάλυνσης με κατάλληλες παραμέτρους, όπως απεικονίζεται στις Εξισώσεις 5.3- 5.6, ο ETSFormer μπορεί να συλλάβει τα υποκείμενα πρότυπα των χρονοσειρών και να παρέχει ακριβείς προβλέψεις.

$$\text{Επίπεδο:} \quad e_t = \alpha(y_t - s_{t-p}) + (1 - \alpha)(e_{t-1} + b_{t-1}) \quad (5.3)$$

$$\text{Ανάπτυξη:} \quad b_t = \beta(e_t - e_{t-1}) + (1 - \beta)b_{t-1} \quad (5.4)$$

$$\text{Εποχικότητα:} \quad s_t = \gamma(y_t - e_t) + (1 - \gamma)s_{t-p} \quad (5.5)$$

$$\text{Πρόβλεψη:} \quad \hat{y}_{t:t+H} = e_t + hb_t + s_{t+h-p} \quad (5.6)$$

όπου  $p$  είναι η διάρκεια του εποχιακού κύκλου και  $\hat{y}_{t:t+H}$  είναι η πρόβλεψη της χρονοσειράς.

Όπως φαίνεται στις Εξισώσεις 5.3-5.6, η συνιστώσα του επιπέδου υπολογίζεται ως σταθμισμένος μέσος όρος της εποχικά προσαρμοσμένης παρατήρησης ( $y_t - s_{t-p}$ ) και της μη εποχικής πρόβλεψης, που προκύπτει από την άθροιση του προηγούμενου επιπέδου και της αύξησης ( $e_{t-1} + b_{t-1}$ ). Η εξίσωση εξομάλυνσης της ανάπτυξης υλοποιείται με έναν σταθμισμένο μέσο όρο μεταξύ της διαδοχικής διαφοράς του αποεποχικοποιημένου επιπέδου ( $e_t - e_{t-1}$ ) και της προηγούμενης ανάπτυξης  $b_{t-1}$ . Τέλος, η εξίσωση της εποχικής εξομάλυνσης υλοποιείται με έναν σταθμισμένο μέσο όρο μεταξύ της διαφοράς της παρατήρησης και του επιπέδου ( $y_t - e_t$ ) και του προηγούμενου εποχικού δείκτη  $s_{t-p}$ . Οι παράμετροι  $\alpha$ ,  $\beta$  και  $\gamma$  είναι παράμετροι

εξομάλυνσης που ελέγχουν τον σταθμισμένο μέσο όρο των Εξισώσεων 5.3, 5.5 και 5.6, αντίστοιχα.

Η αρχιτεκτονική ETSFormer περιλαμβάνει επίσης δύο καινοτόμους μηχανισμούς προσοχής, τον Exponential Smoothing Attention (ESA) και τον Frequency Attention (FA), οι οποίοι έχουν σχεδιαστεί για να βελτιώσουν τον τυπικό μηχανισμό προσοχής που χρησιμοποιείται στον vanilla Transformer [88]. Ο μηχανισμός ESA χρησιμοποιεί τη σχετική χρονική υστέρηση σε σχέση με το ερώτημα για τον υπολογισμό των βαθμών προσοχής και έχει πολυπλοκότητα  $\mathcal{O}(L \log L)$  για ένα παράθυρο αναδρομής μήκους  $L$ . Είναι ιδιαίτερα αποτελεσματικός στη μοντελοποίηση της συνιστώσας ανάπτυξης των δεδομένων χρονοσειρών. Ταυτόχρονα, ο μηχανισμός FA χρησιμοποιεί το μετασχηματισμό Fourier για τον εντοπισμό των κυρίαρχων εποχιακών προτύπων επιλέγοντας τις  $K$  συνιστώσες Fourier με τα μεγαλύτερα πλάτη στο πεδίο της συχνότητας. Όπως και ο ESA, έχει πολυπλοκότητα  $\mathcal{O}(L \log L)$ . Αυτοί οι μηχανισμοί προσοχής ενσωματώνονται στην αρχιτεκτονική ETSFormer για την καλύτερη καταγραφή των πολύπλοκων εξαρτήσεων στα δεδομένα χρονοσειρών. Τέλος, η τελική πρόβλεψη είναι μια σύνθεση συνιστωσών επιπέδου, τάσης και εποχικότητας, γεγονός που την καθιστά ερμηνεύσιμη από τον άνθρωπο.

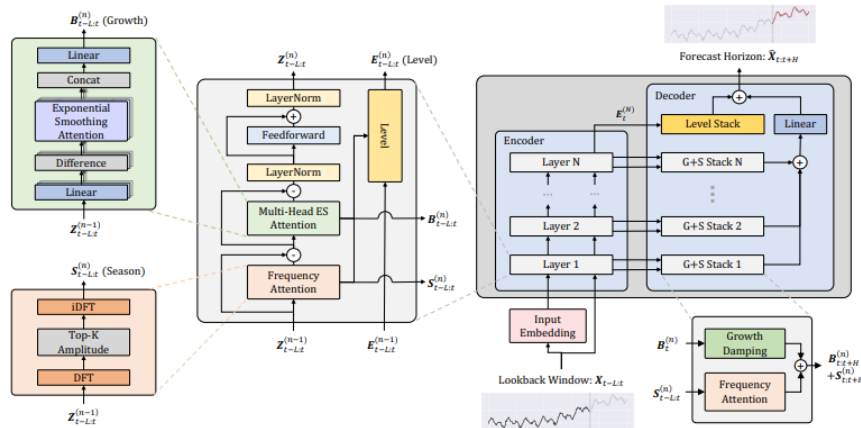


Figure 2: ETSformer model architecture.

Σχήμα 5.5: Αρχιτεκτονική του ETSFormer (Πηγή: [96])

Στο Σχήμα 5.5 απεικονίζεται η συνολική αρχιτεκτονική ETSFormer, η οποία ακολουθεί την κλασική προσέγγιση κωδικοποιητή-αποκωδικοποιητή. Ο κωδικοποιητής και ο αποκωδικοποιητής αποτελούνται από πολλαπλά επίπεδα. Σε κάθε στρώμα  $n$ , ο κωδικοποιητής εξαγει επαναληπτικά τις αυξητικές,  $\mathbf{B}_{t-L:t}^{(n)}$ , και τις εποχικές,  $\mathbf{S}_{t-L:t}^{(n)}$ , λανθάνουσες συνιστώσες από το παράθυρο αναδρομής  $L$  χρησιμοποιώντας κατάλληλα τις μονάδες FA και ESA. Η μονάδα FA κάνει χρήση του διακριτού μετασχηματισμού Fourier και του αντίστροφου του για να βρει τα Top- $K$  πλάτη στο πεδίο της συχνότητας, που αποτελούν την εποχιακή λανθάνουσα συνιστώσα.

Η μονάδα FA τροφοδοτείται με την υπολειμματική αναπαράσταση του προηγούμενου στρώματος κωδικοποιητή,  $\mathbf{Z}_{t-L:t}^{(n-1)}$ . Ο μηχανισμός ESA χρησιμοποιείται στη μονάδα προσοχής Multi-

Head ES που εξάγει την λανθάνουσα συνιστώσα ανάπτυξης και λαμβάνει ως είσοδο την υπολειμματική αναπαράσταση του προηγούμενου στρώματος κωδικοποιητή, αφού εκπέμψει την εποχική αναπαράσταση από τον προηγούμενο μηχανισμό FA για το παράθυρο αναδρομής. Η υπολειμματική αναπαράσταση εξόδου προκύπτει από το προηγούμενο στρώμα κωδικοποιητή  $\mathbf{Z}_{t-L:t}^{(n-1)}$ , μετά την εκπομπή της εποχικής λανθάνουσας αναπαράστασης που λαμβάνεται από τη μονάδα MH-ESA, η οποία τροφοδοτείται σε ένα στρώμα κανονικοποίησης και σε ένα δίκτυο προώθησης κατά θέση. Εκτός από την υπολειμματική έξοδο, ο κωδικοποιητής εξάγει επίσης το επίπεδο σε κάθε χρονικό βήμα  $t$  δεδομένης της λανθάνουσας ανάπτυξης και των εποχιακών αναπαραστάσεων από κάθε στρώμα, που εκφράζεται μαθηματικά από την Εξίσωση 5.7, η οποία ακολουθεί την Εξίσωση 5.3 από τη μέθοδο Holt-Winters:

$$\mathbf{E}_t^{(n-1)} = \alpha * (\mathbf{E}_t^{(n-1)} - \text{Linear}(\mathbf{S}_t^{(n)})) + (1 - \alpha) * (\mathbf{E}_{t-1}^{(n)} + \text{Linear}(\mathbf{B}_{t-1}^{(n)})) \quad (5.7)$$

όπου  $\alpha \in \mathbf{R}^m$  είναι μια εκπαιδευόμενη παράμετρος εξομάλυνσης,  $*$  δηλώνει την πράξη του πολλαπλασιασμού κατά στοιχείο, και  $\text{Linear}(\cdot) : \mathbf{R}^d \rightarrow \mathbf{R}^m$  απεικονίζει τις αναπαραστάσεις στο χώρο παρατήρησης ( $m$  και  $d$  είναι οι διαστάσεις εισόδου και εξόδου του στρώματος εμφύτευσης εισόδου που περιγράφεται αργότερα σε αυτή την ενότητα).

Ο αποκωδικοποιητής, από την άλλη πλευρά, αξιοποιεί τα  $\mathbf{B}_t^{(n)}$ ,  $\mathbf{S}_{t-L:t}^{(n)}$  και  $\mathbf{E}_t^{(n)}$  προκειμένου να δημιουργήσει την τελική πρόβλεψη του βήματος  $H$ . Η τελική πρόβλεψη είναι μια σύνθεση από προβλέψεις επιπέδου  $\mathbf{E}_{t:t+H}^{(n)}$ , αναπαραστάσεις ανάπτυξης  $\mathbf{B}_{t:t+H}^{(n)}$  και εποχικές αναπαραστάσεις  $\mathbf{S}_{t:t+H}^{(n)}$  στον ορίζοντα πρόβλεψης. Ο αποκωδικοποιητής αποτελείται από  $N$  στοιβες Growth + Seasonal (G+S), και μια στοιβή επιπέδων που συνδέονται κατάλληλα για να ληφθεί η τελική πρόβλεψη.

Όσον αφορά το στρώμα εμφύτευσης της εισόδου, αποτελείται από ένα χρονικό φίλτρο συνελίξεων με κανάλι εισόδου  $m$  και κανάλι εξόδου  $d$ , το οποίο λαμβάνει τα ακατέργαστα σήματα από το παράθυρο αναδρομής και επιστρέφει την αναπαράστασή τους στο λανθάνοντα χώρο. Σε αντίθεση με προηγούμενες αρχιτεκτονικές μετασχηματιστών [88, 104, 97, 105], οι εισοδοί του ETSFormer δεν περιλαμβάνουν εξωγενή δεδομένα ή χειροκίνητα σχεδιασμένες δυναμικές χρονοεξαρτώμενες μεταβλητές, όπως ο μήνας, η ημέρα της εβδομάδας κ.λπ., τόσο για το παράθυρο αναδρομής όσο και για τον ορίζοντα πρόβλεψης. Αυτό οφείλεται στο γεγονός ότι η προτεινόμενη μονάδα FA είναι σε θέση να αποκαλύψει αυτόματα αυτά τα εποχικά μοτίβα, γεγονός που την καθιστά πιο εφαρμόσιμη για δύσκολα σενάρια χωρίς αυτές τις διακριτές μεταβλητές και μειώνει την ανάγκη σχεδιασμού χαρακτηριστικών. Επιπλέον, ο αποκωδικοποιητής λαμβάνει ως είσοδο μόνο τις αναπαραστάσεις εξόδου του κωδικοποιητή και δεν λαμβάνει υπόψη του άλλες πληροφορίες που μπορεί να είναι διαθέσιμες για ακριβέστερη πρόβλεψη.

## 5.5 Επιλογή μοντέλου

Στην συγκεκριμένη Ενότητα παρουσιάζεται μια σύγκριση μεταξύ των διαφορετικών μοντέλων μετασχηματιστή χρονοσειρών και του τελικού μοντέλου που επιλέχθηκε για το σκοπό της παρούσας διπλωματικής εργασίας. Ο Πίνακας 5.1 συνοψίζει την πολυπλοκότητα χρόνου και μνήμης, καθώς και τον αριθμό των βημάτων πρόβλεψης, για κάθε ένα από τα μοντέλα που



Μέθοδος	Εκπαίδευση		Αξιολόγηση
	Χρόνος	Μνήμη	Βήματα
LSTM	$\mathcal{O}(L)$	$\mathcal{O}(L)$	$L$
Transformer	$\mathcal{O}(L^2)$	$\mathcal{O}(L^2)$	$L$
Informer	$\mathcal{O}(L \log L)$	$\mathcal{O}(L \log L)$	1
FEDFormer	$\mathcal{O}(L)$	$\mathcal{O}(L)$	1
ETSFormer	$\mathcal{O}(L \log L)$	$\mathcal{O}(L \log L)$	1

Πίνακας 5.1: Ανάλυση πολυπλοκότητας διαφορετικών μοντέλων πρόβλεψης (Πηγή: [105])

συζητήθηκαν προηγουμένως. Ο FEDFormer είναι ένα μοντέλο που χρησιμοποιεί ένα τυχαίο υποσύνολο του διακριτού μετασχηματισμού Fourier και του αντίστροφου του, το οποίο του επιτρέπει να επιτυγχάνει την ίδια πολυπλοκότητα χρόνου και μνήμης με τον Informer και τον ETSFormer. Ωστόσο, επιλέγοντας τον δείκτη λειτουργίας πριν από την εκτέλεση των πράξεων του διακριτού μετασχηματισμού Fourier και του αντίστροφου του, ο FEDFormer μπορεί να επιτύχει ακόμη καλύτερη χρονική πολυπλοκότητα και χρήση μνήμης  $\mathcal{O}(N)$ , όπως φαίνεται στον Πίνακα 5.1.

Σημειώνεται ότι ο ETSFormer [96] είναι ένα ενδιαφέρον μοντέλο για μη στάσιμα δεδομένα χρονοσειρών, καθώς αναλύει τη χρονοσειρά σε συνιστώσες επιπέδου, αύξησης και τάσης. Επιπλέον, ο ETSFormer προσφέρει μεγαλύτερη ερμηνευσιμότητα από άλλα μοντέλα, γεγονός που τον καθιστά ιδιαίτερα κατάλληλο για ανάλυση και αξιολόγηση στην παρούσα διατριβή. Ως εκ τούτου, ο ETSFormer επιλέχθηκε ως η πρωταρχική αρχιτεκτονική μετασχηματιστή που μελετήθηκε εκτενέστερα.

Μια από τις κύριες συνεισφορές της παρούσας διατριβής είναι μια απλή τροποποίηση του ETSFormer που βελτιώνει την απόδοση του μοντέλου για μια εφαρμογή σε πραγματικό κόσμο. Η προσθήκη ενός πλήρως διασυνδεδεμένου επιπέδου ως τελευταίου στρώματος επιτρέπει στο μοντέλο να λαμβάνει εξωγενή δεδομένα εισόδου και, συνεπώς, να εκμεταλλεύεται επιπλέον εποχικές πληροφορίες. Αυτή η πρόσθετη είσοδος βοηθά το μοντέλο να ανταποκριθεί στις απαιτήσεις μιας πραγματικής εφαρμογής.

Για το συγκεκριμένο έργο, η ΟΛΥΜΠΙΑ ΟΔΟΣ Α.Ε. είναι ο βασικός εμπλεκόμενος φορέας και έχει κάποιες απλές απαιτήσεις:

1. Ο ορίζοντας πρόβλεψης ορίζεται ρητά σε 3 ημέρες. Λόγω του γεγονότος ότι τα δεδομένα κυκλοφορίας συλλέγονται κάθε 15 λεπτά, το παράθυρο πρόβλεψης ορίζεται σε  $288 = 3$  (ημέρες) \* 96 (αριθμός 15λεπτων διαστημάτων ανά ημέρα).
2. Το μοντέλο πρέπει να δίνει έμφαση και να μην υποτιμά τις ακραίες τιμές. Αυτό συμβαίνει επειδή ο κύριος στόχος της πρόβλεψης της κυκλοφορίας είναι η αποφυγή της κυκλοφοριακής συμφόρησης, η οποία διακρίνεται σε ελαφριά και βαριά. Για την ικανοποίηση αυτής της απαίτησης το μοντέλο μας ενσωματώνει μια προσαρμοσμένη συνάρτηση απωλειών, που αποτελεί επέκταση της συνάρτησης απώλειας του μέσου τετραγωνικού σφάλματος.



# Κεφάλαιο 6

## Πειράματα

### 6.1 Τροποποιημένος ETSFormer

Ο ETSFormer τροποποιήθηκε με σκοπό όχι μόνο για να επιτευχθούν καλύτερα αποτελέσματα, αλλά και για να ικανοποιηθούν οι απαιτήσεις που έθεσε η ΟΛΥΜΠΙΑ ΟΔΟΣ Α.Ε. και συζητήθηκαν στο προηγούμενο Κεφάλαιο. Ο τροποποιημένος ETSFormer θα αναφέρεται για το υπόλοιπο της εργασίας ως METSFormer (Modified ETSFormer).

Όπως φαίνεται στο Σχήμα 5.5, ο αποκωδικοποιητής δεν δέχεται άμεση είσοδο δεδομένων, αλλά λαμβάνει μόνο τις αναπαραστάσεις εξόδου του κωδικοποιητή. Για το λόγο αυτό, προστίθεται ένα τελικό πλήρως διασυνδεδεμένο επίπεδο που λαμβάνει ως είσοδο τις τελικές προβλέψεις του αποκωδικοποιητή αλλά και κάποιες επιπλέον δυαδικές μεταβλητές `Is_Holiday`, `Is_Holiday_Season`, `Is_Weekday` και `Is_Business_Day`, οι οποίες επεξηγήθηκαν στον Πίνακα 4.2. Αυτές οι μεταβλητές μπορούν να χρησιμοποιηθούν ως χαρακτηριστικά σε μοντέλα πρόβλεψης χρονοσειρών για τη βελτίωση της ακρίβειας και της ερμηνευσιμότητάς τους. Αναλύοντας τον αντίκτυπο των αργιών, των εποχών αργιών, των καθημερινών και των εργάσιμων ημερών στα δεδομένα χρονοσειρών, μπορεί κανείς να κατανοήσει καλύτερα τα υποκείμενα πρότυπα και τις τάσεις.

### 6.2 Πληροφορίες υλοποίησης

#### 6.2.1 Υπερπαράμετροι

Για όλα τα πειράματα, χρησιμοποιήθηκαν οι ίδιες υπερπαράμετροι για τα στρώματα κωδικοποιητή, τις στοίβες αποκωδικοποιητή, τις διαστάσεις του μοντέλου, τις διαστάσεις του εσωτερικού επιπέδου ΠΤ, τον αριθμό των κεφαλών στην προσοχή εκθετικής εξομάλυνσης πολλαπλών κεφαλών και το μέγεθος του πυρήνα για τα εμφυτεύματα της εισόδου, όπως αναφέρονται στον Πίνακα 6.1.

Πραγματοποιήθηκε προσαρμογή των υπερπαραμέτρων μέσω δοκιμής και πειράματος, επειδή δεν ήταν χρονικά και πρακτικά εφικτό να γίνει αναζήτηση πλέγματος σε όλες αυτές τις μεταβλητές για 4 διαφορετικά μοντέλα (για τους 4 διαφορετικούς σταθμούς διοδίων). Για το λόγο αυτό, διενεργήθηκαν διάφορα πειράματα και αποκλείστηκαν ορισμένες ρυθμίσεις που

Υπερπαράμετρος	Τιμές
Στρώματα κωδικοποιητή (enc.layers)	2, 4
Στρώματα αποκωδικοποιητή (dec.layers)	2, 4, 6
Διάσταση μοντέλου (d_model)	512, 1024
Εσωτερική διάσταση προώθησης	2048
Πολλαπλές κεφαλές ESA	2, 4, 8
Μέγεθος πυρήνα ενσωμάτωσης εισόδου	3
K	1, 2, 3, 4
Μέγεθος παραθύρου αναδρομής	288
Μέγεθος παραθύρου πρόβλεψης	288
Ρυθμός μάθησης	1e-3
Επίπεδα ΠΤ	1,2
Διαστάσεις επιπέδων ΠΤ	1024, 2048, 4096

Πίνακας 6.1: Υπερπαράμετροι που χρησιμοποιήθηκαν στο ETSFormer

ήταν αναποτελεσματικές και ανακριβείς στην τελική πρόβλεψη. Επιλέχθηκαν οι ρυθμίσεις που αποδίδουν καλύτερα όχι μόνο στο σύνολο δοκιμής (έτος 2017) με βάση τις επιλεγμένες μετρικές, αλλά και στα αθέατα δεδομένα του έτους 2023 που περιλαμβάνουν την περίοδο διακοπών της Καθαράς Δευτέρας και της 25<sup>ης</sup> Μαρτίου που παρατηρήθηκε αυξημένη κίνηση. Με άλλα λόγια, κάθε μοντέλο που εκπαιδεύτηκε, εφαρμόστηκε και δοκιμάστηκε για την περίοδο των εορτών της Καθαράς Δευτέρας (συγκεκριμένα 24-28 Φεβρουαρίου 2023) και της 25<sup>ης</sup> Μαρτίου, που είναι μία από τις ελληνικές εθνικές εορτές.

### 6.2.2 Βελτιστοποίηση, συνάρτηση απώλειας και μετρικές αξιολόγησης

Όλα τα μοντέλα εκπαιδεύτηκαν με τη χρήση του βελτιστοποιητή ADAM [47] με  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$ , και  $\epsilon = 1e - 08$  και μέγεθος δέσμης 32, ίδιο με το [96]. Ο ρυθμός μάθησης προγραμματίστηκε με γραμμική προθέρμανση σε 3 εποχές και ελάχιστο ρυθμό μάθησης  $10^{-30}$ . Όπως αναφέρθηκε προηγουμένως στην παρούσα διατριβή, σχεδιάστηκε και χρησιμοποιήθηκε μια προσαρμοσμένη συνάρτηση απώλειας προκειμένου να ικανοποιηθούν οι απαιτήσεις των ενδιαφερομένων φορέων. Όλα τα δίκτυα βαθιάς μάθησης υλοποιήθηκαν σε PyTorch [63] και εκπαιδεύτηκαν σε κάρτες γραφικών NVIDIA A16 16GB, που φιλοξενούνται σε διακομιστή της ΟΛΥΜΠΙΑΣ ΟΔΟΣ ΑΕ.

Αναλυτικότερα, το μοντέλο προτιμά να υπερεκτιμά και όχι να υποεκτιμά τον όγκο της κυκλοφορίας, ώστε να αποφεύγεται η κυκλοφοριακή συμφόρηση, η οποία διακρίνεται σε ελαφριά και βαριά. Για να αντιμετωπιστούν οι ειδικές απαιτήσεις της εργασίας πρόβλεψης του όγκου κυκλοφορίας, σχεδιάστηκε μια προσαρμοσμένη συνάρτηση απώλειας που επέκτεινε το μέσο τετραγωνικό σφάλμα. Η προσαρμοσμένη συνάρτηση απώλειας περιλαμβάνει δύο πρόσθετους όρους: (i) ο ένας ποινικοποιεί την υποεκτίμηση κατά έναν παράγοντα  $\alpha$  και (ii) ο άλλος ποινικοποιεί το μέσο τετραγωνικό σφάλμα υψηλών τιμών κατά έναν παράγοντα  $\beta$ .

Η προσαρμοσμένη συνάρτηση απώλειας ορίζεται στην Εξίσωση 6.1

$$L = \text{MSE} + 2 * \max(0, \hat{Y} - Y) + 5 * \text{MSE}_{high} \quad (6.1)$$

όπου  $\hat{Y}$  είναι η προβλεπόμενη τιμή του όγκου κυκλοφορίας,  $Y$  είναι η πραγματική τιμή και  $\text{MSE}_{high}$  είναι το μέσο τετραγωνικό σφάλμα των υψηλών τιμών. Ο πρώτος όρος αντιπροσωπεύει την τυπική απώλεια του μέσου τετραγωνικού σφάλματος, η οποία ποινικοποιεί τις αποκλίσεις από την πραγματική τιμή ανεξάρτητα από την κατεύθυνση. Ο δεύτερος όρος προσθέτει μια ποινή για την υποεκτίμηση, διπλασιάζοντας ουσιαστικά την απώλεια όταν η προβλεπόμενη τιμή είναι χαμηλότερη από την πραγματική τιμή. Ο τρίτος όρος στοχεύει στην αντιμετώπιση της πρόβλεψης υψηλών τιμών, αυξάνοντας το βάρος του μέσου τετραγωνικού σφάλματος για αυτές τις τιμές κατά 5 φορές.

Για την αξιολόγηση των επιδόσεων των μοντέλων για μια εργασία πρόβλεψης χρονοσειρών, υπάρχουν αρκετές κοινώς χρησιμοποιούμενες μετρικές που χρησιμοποιήθηκαν στην παρούσα μελέτη για λόγους πληρότητας.

- **Προσαρμοσμένη μετρική:** Χρησιμοποιήθηκε μια προσαρμοσμένη μετρική, παρόμοια με την προσαρμοσμένη συνάρτηση απώλειας που περιγράφηκε προηγουμένως, και ήταν η κύρια μετρική που χρησιμοποιήθηκε για την αξιολόγηση της απόδοσης των μοντέλων. Επεκτείνει τη μετρική του μέσου τετραγωνικού σφάλματος προσθέτοντας κάποιους όρους ποινής για υποεκτίμηση και για σφάλματα σε υψηλές πραγματικές τιμές. Η προσαρμοσμένη μετρική περιγράφεται στην Εξίσωση 6.2

$$\text{CustomMetric} = \frac{1}{f} \sum_{i=t_0}^{t_0+f} L_{1,i} + L_{2,i} \quad (6.2)$$

όπου:

- $L_{1,i} = \begin{cases} 2(y_i - \hat{y}_i)^2, & \text{αν } y_i > \hat{y}_i (y_i - \hat{y}_i) \\ 0, & \text{διαφορετικά} \end{cases}$
- $L_{2,i} = \begin{cases} 10(y_i - \hat{y}_i), & \text{αν } y_i > 1050 \text{ και } \hat{y}_i \leq 1050 \\ 0, & \text{διαφορετικά} \end{cases}$
- $\hat{y}_i$ : οι προβλεπόμενες τιμές για τον ορίζοντα πρόβλεψης  $f$
- $y_i$ : οι πραγματικές τιμές της μεταβλητής-στόχου (όγκος κυκλοφορίας)

- **Μέσο τετραγωνικό σφάλμα:** Είναι μια κοινή μετρική που χρησιμοποιείται για την αξιολόγηση της απόδοσης των μοντέλων πρόβλεψης χρονοσειρών. Υπολογίζεται ως ο μέσος όρος των τετραγωνικών διαφορών μεταξύ των προβλεπόμενων και των πραγματικών τιμών και δίνει μεγαλύτερη έμφαση στα μεγαλύτερα σφάλματα από ό,τι στα μικρότερα, λόγω του τετραγωνισμού των διαφορών. Τυπικά, δίνεται από την Εξίσωση 6.3

$$\text{MSE} = \frac{1}{f} \sum_{i=t_0}^{t_0+f} (y_i - \hat{y}_i)^2 \quad (6.3)$$

Γενικά, μια χαμηλότερη τιμή μέσου τετραγωνικού σφάλματος υποδηλώνει καλύτερη απόδοση του μοντέλου, αλλά μπορεί να είναι ευαίσθητη σε ακραίες τιμές και μεγάλα σφάλματα, επειδή μετράται στο υπόλοιπο των μονάδων των τιμών-στόχων.

- **Ρίζα μέσου τετραγωνικού σφάλματος:** Είναι μια παραλλαγή του μέσου τετραγωνικού σφάλματος, όπου λαμβάνεται η τετραγωνική ρίζα του. Αυτό το καθιστά πιο ερμηνεύσιμο, καθώς υπολογίζεται στις ίδιες μονάδες με τη μεταβλητή-στόχο. Δίνεται από την Εξίσωση 6.4

$$RMSE = \sqrt{\frac{1}{f} \sum_{i=t_0}^{t_0+f} (y_i - \hat{y}_i)^2} \quad (6.4)$$

- **Μέσο απόλυτο σφάλμα:** Είναι μια ευρέως χρησιμοποιούμενη μετρική αξιολόγησης για εργασίες παλινδρόμησης, καθώς δείχνει άμεσα το σφάλμα μεταξύ των προβλέψεων και των πραγματικών ετικετών. Είναι λιγότερο ευαίσθητο στις ακραίες τιμές από το μέσο τετραγωνικό σφάλμα και περιγράφεται στην Εξίσωση 6.5

$$MAE = \frac{1}{f} \sum_{i=t_0}^{t_0+f} |y_i - \hat{y}_i| \quad (6.5)$$

Κατά την ερμηνεία του μέσου απόλυτου σφάλματος είναι σημαντικό να λαμβάνονται υπόψη τα στατιστικά στοιχεία των δεδομένων, ιδίως η τυπική απόκλιση, καθώς επηρεάζεται σε μεγάλο βαθμό από τα εύρη τιμών των δεδομένων και τις απαιτήσεις της εργασίας.

- **Μέσο τετραγωνικό ποσοστιαίο σφάλμα:** Είναι μια μετρική που μετρά τη σχετική απόδοση του μοντέλου λαμβάνοντας το λόγο του μέσου τετραγωνικού σφάλματος προς το μέσο όρο των πραγματικών τιμών στο τετράγωνο. Είναι χρήσιμη κατά την αξιολόγηση μοντέλων σε μεταβλητές-στόχους διαφορετικής κλίμακας. Γενικά, χαμηλότερη τιμή συνεπάγεται καλύτερη απόδοση. Συνήθως έχει τη μορφή της Εξίσωσης 6.6

$$MSPE = \frac{1}{f} \sum_{i=t_0}^{t_0+f} \left( \frac{y_i - \hat{y}_i}{y_i} \right)^2 \quad (6.6)$$

- **Μέσο απόλυτο ποσοστιαίο σφάλμα:** Υπολογίζει το απόλυτο ποσοστιαίο σφάλμα μεταξύ των προβλεπόμενων και των πραγματικών τιμών (Εξίσωση 6.7)

$$MAPE = \frac{1}{f} \sum_{i=t_0}^{t_0+f} \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (6.7)$$

Ενώ οι μετρικές των Εξισώσεων 6.6-6.7 είναι συνήθως χρήσιμες, μπορεί να μην είναι κατάλληλες σε περιπτώσεις όπου οι πραγματικές τιμές είναι πολύ μικρές, λόγω της διαίρεσης με σχεδόν μηδενικές τιμές που επηρεάζουν τις προκύπτουσες τιμές και ως εκ τούτου μπορεί να μην παρέχουν μια ακριβή αναπαράσταση της απόδοσης του μοντέλου σε τέτοιες περιπτώσεις. Για το λόγο αυτό, οι τιμές των ποσοστιαίων σφαλμάτων που παρουσιάζονται στο Κεφάλαιο 7 παρήχθησαν αφού πρώτα έγινε αντίστροφος μετασχηματισμός των κλιμακωτών δεδομένων στα αρχικά δεδομένα (ως προς τις μονάδες).

### 6.2.3 Τεχνικές κανονικοποίησης

Προκειμένου να αποτραπεί η υπερπροσαρμογή των μοντέλων στα δεδομένα κατά τη διάρκεια της εκπαίδευσης, ενσωματώθηκαν δύο τεχνικές κανονικοποίησης, όπως προτείνονται στο [96]:

**Επαυξήσεις Δεδομένων:** Για να αυξηθεί η ευρωστία του μοντέλου και να αποτραπεί η υπερπροσαρμογή στα δεδομένα εκπαίδευσης, εφαρμόστηκαν τρεις διαφορετικές επαυξήσεις δεδομένων με πιθανότητα 0,5, με την ακόλουθη σειρά: (i) κλιμάκωση, (ii) μετατόπιση και (iii) προσθήκη θορύβου.

Η πρώτη επαύξηση, περιλαμβάνει την κλιμάκωση της χρονοσειράς  $s$  με μία τυχαία βαθμωτή τιμή, η οποία λαμβάνεται με δειγματοληψία  $\epsilon_1$  από μια κανονική κατανομή με μέση τιμή 0 και τυπική απόκλιση 0,2. Στη συνέχεια, κάθε χρονικό βήμα της σειράς πολλαπλασιάστηκε με τη δειγματοληπτική κλιμακωτή τιμή, με αποτέλεσμα μια τροποποιημένη χρονοσειρά  $\tilde{x}_t = \epsilon_1 x_t$ . Η δεύτερη επαύξηση περιλαμβάνει τη μετατόπιση της χρονοσειράς κατά μία τυχαία βαθμωτή τιμή, η οποία λαμβάνεται με δειγματοληψία του  $\epsilon_2$  από μια κανονική κατανομή με μέση τιμή 0 και τυπική απόκλιση 0,2. Κάθε χρονικό βήμα στη σειρά προστίθεται στη συνέχεια στη δειγματοληπτούμενη τιμή, με αποτέλεσμα μια τροποποιημένη χρονοσειρά  $\tilde{x}_t = x_t + \epsilon_2$ . Τέλος, η τρίτη επαύξηση περιλαμβάνει την προσθήκη ανεξάρτητου και πανομοιότυπα κατανεμημένου γκαουσιανού θορύβου σε κάθε χρονικό βήμα από μια κανονική κατανομή με μέση τιμή 0 και τυπική απόκλιση 0,2. Κάθε χρονικό βήμα της σειράς προστίθεται στη συνέχεια στο δειγματοληπτούμενο θόρυβο, με αποτέλεσμα μια τροποποιημένη χρονοσειρά  $\tilde{x}_t = x_t + \epsilon_t$ , όπου  $\epsilon_t \sim \mathcal{N}(0, 0.2)$ .

Η τελική τροποποίηση κάθε χρονικού βήματος περιγράφεται στην Εξίσωση 6.8

$$\tilde{x}_t = \epsilon_1 x_t + \epsilon_2 + \epsilon_t \quad (6.8)$$

**Dropout:** Εκτός από τις επαυξήσεις των δεδομένων, εφαρμόστηκε επίσης κανονικοποίηση dropout σε όλο το μοντέλο. Το dropout εφαρμόστηκε σε διάφορα στοιχεία του μοντέλου για να αποφευχθεί η υπερπροσαρμογή, συμπεριλαμβανομένων των μπλοκ εμφύτευσης εισόδου, των μηχανισμών FA και ESA πολλαπλών κεφαλών, καθώς και του εσωτερικού μπλοκ τροφοδότησης (μετά την ενεργοποίηση και πριν από την κανονικοποίηση) και των βαρών προσοχής. Εφαρμόστηκε dropout με πιθανότητα  $p = 0,2$  για αυτά τα στοιχεία. Για τα τελευταία στρώματα τροφοδότησης, το dropout εφαρμόστηκε με χαμηλότερη πιθανότητα  $p = 0,1$ . Η χρήση της κανονικοποίησης dropout αποδείχθηκε αποτελεσματική τεχνική για τη βελτίωση της απόδοσης γενίκευσης του μοντέλου και τη μείωση της υπερπροσαρμογής στα δεδομένα εκπαίδευσης.

## 6.3 Μοντέλα βάσης

Όπως μπορεί να παρατηρηθεί από τους Πίνακες 7.1 και 7.2, οι σταθμοί διοδίων στην ίδια κατεύθυνση τείνουν να έχουν παρόμοιες τιμές υπερπαραμέτρων, γεγονός αναμενόμενο επειδή έχουν παρόμοια μοτίβα και χαρακτηριστικά κυκλοφορίας. Ωστόσο, αυτό δεν σημαίνει απαραίτητα ότι ο όγκος κυκλοφορίας στους συγκεκριμένους σταθμούς μπορεί να προβλεφθεί

με το ίδιο μοντέλο, καθώς αποδείχθηκε ότι τα μοντέλα που χρησιμοποιούνται για κάθε σταθμό έχουν διαφορετικές παραμέτρους. Αυτό υποδηλώνει ότι ενώ τα δεδομένα μπορεί να έχουν παρόμοια συμπεριφορά, δεν είναι ακριβώς πανομοιότυπα. Παρ' όλα αυτά, το γεγονός ότι τα μοντέλα μπορούν να αποτυπώσουν με επιτυχία τα πρότυπα των δεδομένων κυκλοφορίας σε κάθε σταθμό διοδίων αποδεικνύει την αποτελεσματικότητά τους.

Για λόγους σύγκρισης, υλοποιήθηκαν τα μοντέλα vanilla Transformer, Informer και FEDFormer<sup>1</sup> [88, 104, 105] και εκπαιδεύτηκαν ως μοντέλα βάσης. Οι τιμές των υπερπαραμέτρων τους παρουσιάζονται στους Πίνακες 6.2-6.4. Για όλα τα μοντέλα που χρησιμοποιούν εμφύτευση χρονοσήμανσης, αυτή σχεδιάστηκε ως γραμμικό επίπεδο με διάσταση εισόδου 5 (λεπτό, ώρα, ημέρα, μήνας, έτος) και διάσταση εξόδου 512 (ίση με τη διάσταση του μοντέλου).

Υπερπαραμέτρος	Τιμή
Στρώματα κωδικοποιητή	2
Στρώματα αποκωδικοποιητή	1
Διάσταση μοντέλου	512
Διάσταση Pos-wise επιπέδου ΠΤ	2048
Πολλαπλές κεφαλές ESA	8
Μέγεθος παραθύρου αναδρομής	288
Μέγεθος παραθύρου πρόβλεψης	288
Ρυθμός μάθησης	$10^{-3}$
Dropout	0.05

Πίνακας 6.2: Βασικές τιμές υπερπαραμέτρων του vanilla Transformer

Υπερπαραμέτρος	Τιμή
Στρώματα κωδικοποιητή	2
Στρώματα αποκωδικοποιητή	1
Διάσταση μοντέλου	512
Διάσταση Pos-wise επιπέδου ΠΤ	2048
Πολλαπλές κεφαλές ESA	8
Μέγεθος παραθύρου αναδρομής	288
Μέγεθος παραθύρου πρόβλεψης	288
Ρυθμός εκμάθησης	$10^{-3}$
Συντελεστής ProbSparse	5
Distilling	Αληθές
Dropout	0.05

Πίνακας 6.3: Βασικές τιμές υπερπαραμέτρων του Informer

<sup>1</sup>Για το μοντέλο FEDFormer, το Low Mode Selection αναφέρεται στο γεγονός ότι ο δείκτης λειτουργίας δεν επιλέχθηκε τυχαία αλλά ρητά πριν από τη λειτουργία του διακριτού μετασχηματισμού Fourier για λόγους απόδοσης.



Υπερπαράμετρος	Τιμή
Στρώματα κωδικοποιητή	2
Στρώματα αποκωδικοποιητή	1
Διάσταση μοντέλου	512
Διάσταση Pos-wise επιπέδου ΠΤ	2048
Πολλαπλές κεφαλές ESA	8
Μέγεθος παραθύρου αναδρομής	288
Μέγεθος παραθύρου πρόβλεψης	288
Ρυθμός μάθησης	$10^{-3}$
Έκδοση	Fourier, Wavelets
Επιλογή τρόπου λειτουργίας	Low
Dropout	0.05


Πίνακας 6.4: Βασικές τιμές υπερπαραμέτρων του FEDFormer

## 6.4 Συνδυαστικό Μοντέλο

Εκτός από το Modified ETSFormer και τα μοντέλα βάσης, χρησιμοποιήθηκαν, εκπαιδεύτηκαν και αξιολογήθηκαν και συνδυαστικά μοντέλα προκειμένου να επιτευχθούν καλύτερα αποτελέσματα, τα οποία παρουσιάζονται στο Κεφάλαιο 7. Το συνδυαστικό μοντέλο, που απεικονίζεται στο Σχήμα 6.1 είναι μια προσέγγιση μηχανικής μάθησης για το συνδυασμό πολλαπλών διαφορετικών μοντέλων στη διαδικασία πρόβλεψης. Τα μοντέλα αυτά αναφέρονται ως εκτιμητές βάσης. Στην παρούσα ενότητα περιγράφεται ένα συνδυαστικό μοντέλο που συγκεντρώνει την έξοδο δύο μοντέλων, που συμβολίζονται ως Μοντέλο A και Μοντέλο B, για να κάνει προβλέψεις με δύο στόχους: τη μείωση του σφάλματος του μοντέλου και τη διατήρηση της γενίκευσης του μοντέλου. Το προτεινόμενο συνδυαστικό μοντέλο πραγματοποιεί πρόβλεψη με βάση τους ακόλουθους κανόνες:

1. Εάν η έξοδος του μοντέλου A είναι μικρότερη από ένα κατώφλι  $\alpha$ , τότε η πρόβλεψη του συνδυαστικού μοντέλου είναι ίση με την έξοδο του μοντέλου A.
2. Εάν η έξοδος του Μοντέλου A είναι μεγαλύτερη ή ίση με  $\alpha$ , τότε η πρόβλεψη είναι ίση με τη μέγιστη έξοδο του Μοντέλου A και του Μοντέλου B.
3. Εάν η ακολουθία εισόδου έχει μέγιστη τιμή πάνω από ένα άλλο κατώφλι  $\beta$ , τότε η πρόβλεψη είναι ίση με τη μέγιστη έξοδο των μοντέλων A και B.

Τυπικά, έστω  $x$  η ακολουθία εισόδου,  $f_A(x)$  και  $f_B(x)$  οι έξοδοι του Μοντέλου A και του Μοντέλου B, αντίστοιχα, και  $\hat{y}$  η πρόβλεψη του προτεινόμενου συνδυαστικού μοντέλου συνόλου (Αλγόριθμος 1). Να σημειωθεί ότι τα κατώφλια  $\alpha$  και  $\beta$  είναι υπερπαραμέτροι που πρέπει να ρυθμιστούν και για αυτό χρησιμοποιείται μια προσέγγιση αναζήτησης πλέγματος για



Σχήμα 6.1: Βασική αρχιτεκτονική ενός συνδιαστικού μοντέλου

την εύρεση των βέλτιστων τιμών τους.

---

**Algorithm 1** Ensemble Model Forecasting Algorithm

---

**Require:** Input sequence  $x$  with length  $enc.in = 288$

**Require:** Model A with output  $f_A(x)$

**Require:** Model B with output  $f_B(x)$

**Require:** Threshold  $\alpha$ , Threshold  $\beta$

**Ensure:** Prediction  $\hat{y}$

- 1: Compute the maximum value of  $x$  for the last 96 values:  $max_x \leftarrow \max(x[-96 :])$
  - 2: **if**  $f_A(x) \geq \alpha$  **or**  $max_x \geq \beta$  **then**
  - 3:    $\hat{y} \leftarrow \max(f_A(x), f_B(x))$
  - 4: **else**
  - 5:    $\hat{y} \leftarrow f_A(x)$
  - 6: **end if**
  - 7: **return**  $\hat{y}$
- 

Το έργο της πρόβλεψης υψηλών τιμών και, γενικά, κορυφώσεων του όγκου κυκλοφορίας αποτελεί μια ιδιαίτερη πρόκληση, καθώς απαιτεί την ικανότητα ακριβούς μοντελοποίησης και πρόβλεψης ενός μεγάλου εύρους τιμών. Για να ξεπεραστεί αυτή η πρόκληση, χρησιμοποιήθηκε ένα συνδιαστικό μοντέλο, το οποίο συνδυάζει τα πλεονεκτήματα δύο μεμονωμένων μοντέλων. Η εκπαίδευση ενός μεμονωμένου μοντέλου για την πρόβλεψη μόνο υψηλών τιμών και αιχμών θα ήταν πρόκληση, δεδομένης της μεταβλητότητας και του απρόβλεπτου των δεδομένων του όγκου κυκλοφορίας. Ως εκ τούτου, χρησιμοποιήθηκε μια προσαρμοσμένη συνάρτηση απωλειών για να βοηθήσει τα μοντέλα να βελτιστοποιήσουν καλύτερα την απόδοσή τους στις υψηλές τιμές όγκου κυκλοφορίας. Με τον κατάλληλο συνδυασμό των προβλέψεων των μεμονωμένων μοντέλων, το συνδιαστικό μοντέλο ήταν σε θέση να παρέχει πιο ακριβείς και αξιόπιστες προβλέψεις για το επιθυμητό εύρος τιμών του όγκου κυκλοφορίας. Συνολικά, το συνδιαστικό μοντέλο αποδείχθηκε αποτελεσματική λύση για τη συγκεκριμένη εργασία, επιτρέποντας ακριβέστερη και πιο αξιόπιστη πρόβλεψη των τάσεων του όγκου κυκλοφορίας.

## Κεφάλαιο 7

# Αποτελέσματα

Σε αυτό το Κεφάλαιο θα παρουσιαστούν τα αποτελέσματα των πειραμάτων που διενεργήθηκαν στα πλαίσια της παρούσας εργασίας, αναδεικνύοντας τα πλεονεκτήματα και τους περιορισμούς των μοντέλων μετασχηματιστών σχετικά με τα χρονοσειριακά δεδομένα κυκλοφορίας. Τα πειράματα πραγματοποιήθηκαν για τέσσερις σταθμούς διοδίων: ELEE, ELET, ISTT και ISTE. Για κάθε σταθμό δοκιμάστηκαν διάφορες ρυθμίσεις υπερπαραμέτρων και οι βέλτιστες παρουσιάζονται στους Πίνακες 7.1 και 7.2.

Υπερπαραμέτρος	Τιμή
Στρώματα κωδικοποιητή	2
Στρώματα αποκωδικοποιητή	2
Διάσταση μοντέλου	512
Διάσταση Pos-wise επιπέδου ΠΤ	2048
Πολλαπλές κεφαλές ESA	2
Μέγεθος πυρήνα εμφύτευσης εισόδου	3
K	4
Μέγεθος παραθύρου αναδρομής	288
Μέγεθος παραθύρου πρόβλεψης	288
Ρυθμός μάθησης	$10^{-3}$
Πλήρως διασυνδεδεμένα επίπεδα	1
Διαστάσεις πλήρως διασυνδεδεμένων επιπέδων	1024

Πίνακας 7.1: Βέλτιστες τιμές υπερπαραμέτρων του ETSFormer για τους σταθμούς διοδίων **ELEE** και **ISTE**

### 7.1 Επιλογή μοντέλου

Στον Πίνακα 7.3 παρουσιάζονται οι τελικές υπερπαραμέτροι για το πρωτεύον μοντέλο Modified ETSFormer (METSFormer) που επιλέχθηκαν για κάθε σταθμό διοδίων. Πραγματοποιήθηκαν πάνω από 100 πειράματα για την κατεύθυνση ELEE, ενώ για τις άλλες τρεις

Υπερπαραμέτρος	Τιμή
Στρώματα κωδικοποιητή	4
Στρώματα αποκωδικοποιητή	4
Διάσταση μοντέλου	512
Διάσταση Pos-wise επιπέδου ΠΤ	2048
Πολλαπλές κεφαλές ESA	4
Μέγεθος πυρήνα εμφύτευσης εισόδου	3
K	3
Μέγεθος παραθύρου αναδρομής	288
Μέγεθος παραθύρου πρόβλεψης	288
Ρυθμός μάθησης	$10^{-3}$
Πλήρως διασυνδεδεμένα επίπεδα	1
Διαστάσεις πλήρως διασυνδεδεμένων επιπέδων	1024

Πίνακας 7.2: Βέλτιστες τιμές υπερπαραμέτρων του ETSFormer για τους σταθμούς διοδίων **ELET** και **ISTT**

κατευθύνσεις πραγματοποιήθηκαν κάποια πιο στοχευμένα πειράματα που έδειξαν εξαιρετικά αποτελέσματα. Επίσης, στον Πίνακα 7.4 παρουσιάζονται τα συνδυαστικά μοντέλα (Αλγόριθμος 1).

Όνομα	Κατεύθυνση	Τιμές υπερπαραμέτρων						
		enc.layers	dec.layers	d_model	heads	K	FFN.layers	FFN_dim
METSFormer_ELEE <sub>1</sub>	ELEE	2	2	512	2	4	1	1024
METSFormer_ELEE <sub>2</sub>	ELEE	2	2	512	2	4	1	2048
METSFormer_ELEE <sub>3</sub>	ELEE	2	2	512	2	4	2	4096, 1024
METSFormer_ELEE <sub>4</sub>	ELEE	4	4	512	4	3	1	1024
METSFormer_ELET <sub>1</sub>	ELET	2	2	512	2	4	1	1024
METSFormer_ELET <sub>2</sub>	ELET	2	2	512	8	3	1	1024
METSFormer_ELET <sub>3</sub>	ELET	4	4	512	4	3	1	1024
METSFormer_ELET <sub>4</sub>	ELET	4	4	512	4	3	1	2048
METSFormer_ISTE <sub>1</sub>	ISTE	2	2	512	2	4	1	1024
METSFormer_ISTE <sub>2</sub>	ISTE	4	4	512	4	3	1	1024
METSFormer_ISTT <sub>1</sub>	ISTT	2	2	512	2	4	1	1024
METSFormer_ISTT <sub>2</sub>	ISTT	4	4	512	4	3	1	1024

Πίνακας 7.3: Παραλλαγές του Modified ETSFormer για κάθε σταθμό διοδίων

## 7.2 Αποτελέσματα αξιολόγησης

Ο Πίνακας 7.5 απεικονίζει τις επιδόσεις των μοντέλων Modified ETSFormer, των οποίων οι ρυθμίσεις παρουσιάζονται στον Πίνακα 7.3, σε αντίθεση με τα κλασικά μοντέλα ETSFormer, τα οποία εκπαιδεύονται με τις καλύτερες υπερπαραμέτρους που παρουσιάζονται στους Πίνακες 7.1 και 7.2. Όλα τα μοντέλα METSFormer για όλους τους σταθμούς διοδίων επιτυγχάνουν

Όνομα	Κατεύθυνση	Βασικά Μοντέλα
Ensemble_ELEE	ELEE	METSFormer_ELEE <sub>1</sub> και vanilla Transformer
Ensemble_ELET	ELET	METSFormer_ELET <sub>2</sub> και vanilla Transformer
Ensemble_ISTE	ISTE	METSFormer_ISTE <sub>1</sub> και vanilla Transformer
Ensemble_ISTT	ISTT	METSFormer_ISTT <sub>2</sub> και vanilla Transformer

Πίνακας 7.4: Συνδυαστικά μοντέλα για κάθε σταθμό διοδίων

καλύτερα αποτελέσματα για όλες τις μετρικές, ειδικά για την προσαρμοσμένη μετρική, η οποία είναι η κύρια μετρική αξιολόγησης για τη συγκεκριμένη εργασία. Αυτό αποδεικνύει τη μεγάλη διαφορά στην απόδοση που επιτυγχάνεται με την προσθήκη του τελευταίου επίπεδου ΠΤ στο μοντέλο ETSFormer. Ωστόσο, τα δίκτυα ΠΤ αποτελούν «μαύρα κουτιά», που σημαίνει ότι τα βάρη τους δεν είναι εύκολα ερμηνεύσιμα. Παρόλα αυτά, μπορούν να ληφθούν κάποιες πληροφορίες για τις συνιστώσες επιπέδου, ανάπτυξης και εποχής από την έξοδο του αποκωδικοποιητή, η οποία δυστυχώς δεν αντιπροσωπεύει πλήρως τα τελικά αποτελέσματα λόγω της παρεμβολής του πλήρως διασυνδεδεμένου επιπέδου στην έξοδο.

Όνομα Μοντέλου	Κατεύθυνση	Custom	MSE	RMSE	MAE	MAPE	MSPE
ETSFormer_ELEE	ELEE	1.253	0.641	0.522	0.800	0.731	2.124
METSFormer_ELEE <sub>1</sub>	ELEE	<b>0.342</b>	<b>0.120</b>	<b>0.203</b>	<b>0.347</b>	<b>0.244</b>	0.223
METSFormer_ELEE <sub>2</sub>	ELEE	0.468	0.155	0.242	0.393	0.301	0.336
METSFormer_ELEE <sub>3</sub>	ELEE	0.458	0.123	0.220	0.351	0.291	0.267
METSFormer_ELEE <sub>4</sub>	ELEE	0.347	0.126	0.221	0.355	0.259	<b>0.214</b>
ETSFormer_ELET	ELET	1.044	0.267	0.347	0.517	0.558	1.218
METSFormer_ELET <sub>1</sub>	ELET	0.542	0.117	0.210	0.342	0.242	0.164
METSFormer_ELET <sub>2</sub>	ELET	4.211	1.290	0.654	1.135	0.726	2.092
METSFormer_ELET <sub>3</sub>	ELET	0.291	0.102	0.209	0.319	0.265	0.198
METSFormer_ELET <sub>4</sub>	ELET	<b>0.230</b>	<b>0.064</b>	<b>0.168</b>	<b>0.253</b>	<b>0.231</b>	<b>0.149</b>
ETSFormer_ISTE	ISTE	1.317	0.765	0.549	0.875	0.846	3.214
METSFormer_ISTE <sub>1</sub>	ISTE	<b>0.346</b>	<b>0.132</b>	0.214	<b>0.364</b>	0.284	<b>0.282</b>
METSFormer_ISTE <sub>2</sub>	ISTE	<b>0.346</b>	0.133	<b>0.213</b>	<b>0.364</b>	<b>0.283</b>	0.309
ETSFormer_ISTT	ISTT	0.856	0.295	0.366	0.543	0.666	1.939
METSFormer_ISTT <sub>1</sub>	ISTT	0.488	0.127	0.211	0.356	<b>0.275</b>	<b>0.246</b>
METSFormer_ISTT <sub>2</sub>	ISTT	<b>0.258</b>	<b>0.106</b>	<b>0.204</b>	<b>0.326</b>	0.284	0.275

Table 7.5: Αποτελέσματα μονομεταβλητής πρόβλεψης μακράς ακολουθίας για παραλλαγές του METSFormer. Τα καλύτερα αποτελέσματα επισημαίνονται με **bold**.

Στον Πίνακα 7.5 παρουσιάζονται τα αποτελέσματα μονομεταβλητών προβλέψεων χρονοσειρών μακράς ακολουθίας για τις παραλλαγές του METSFormer στο σύνολο δεδομένων, από τα οποία προκύπτουν αρκετές σημαντικές παρατηρήσεις. Υπενθυμίζεται ότι το σύνολο δεδομένων περιέχει δεδομένα κυκλοφορίας από 4 σταθμούς διοδίων που βρίσκονται στην Ολυμπία Οδό, τα οποία συλλέγονται κάθε 15 λεπτά. Ο στόχος είναι η πρόβλεψη του όγκου κυκλοφορίας για τις επόμενες 3 ημέρες με βάση τα δεδομένα των προηγούμενων 3 ημερών.

Κατ' αρχήν, είναι προφανές ότι τα μοντέλα Modified ETSFormer (METSFormer) υπερτερούν των μοντέλων ETSFormer όσον αφορά όλες τις μετρικές αξιολόγησης για κάθε σταθμό διοδίων (ELEE, ELET, ISTE και ISTT). Επιπλέον, οι επιδόσεις των μοντέλων METSFormer διαφέρουν σημαντικά στις διάφορες παραλλαγές, γεγονός που υποδεικνύει ότι η προσαρμογή των υπερπαραμέτρων είναι ζωτικής σημασίας για την επίτευξη βέλτιστων επιδόσεων. Για παράδειγμα, το μοντέλο  $METSFormer_{ELET_2}$  επέδειξε σημαντικά χειρότερες επιδόσεις όσον αφορά την προσαρμοσμένη μετρική, το MSE και το MAE σε σύγκριση με άλλα μοντέλα METSFormer.

Γενικά, οι σταθμοί διοδίων ELEE και ISTE παρουσίασαν σταθερά υψηλότερα ποσοστά σφάλματος από τους σταθμούς διοδίων ELET και ISTT, όπως αποδεικνύεται από τις υψηλότερες βαθμολογίες MSE, RMSE, MAE και MAPE. Ωστόσο, η μετρική MSPE ήταν σχετικά σταθερή σε όλους τους σταθμούς διοδίων.

Εξετάζοντας τα αποτελέσματα για τον σταθμό διοδίων ELEE, είναι προφανές ότι τα μοντέλα METSFormer υπερέχουν του μοντέλου ETSFormer όσον αφορά την προσαρμοσμένη μετρική, με τιμές που κυμαίνονται από 0,347 έως 0,468 σε σύγκριση με 1,253 για το ETSFormer\_ELEE. Επιπλέον, τα μοντέλα METSFormer είχαν γενικά καλύτερες επιδόσεις από το ETSFormer όσον αφορά τα MSE, RMSE, MAE, MAPE και MSPE, υποδεικνύοντας ότι είναι σε θέση να προβλέψουν με μεγαλύτερη ακρίβεια τον όγκο κυκλοφορίας για την κατεύθυνση ELEE.

Για τον σταθμό διοδίων ELET, το  $METSFormer_{ELET_4}$  υπερέχει όλων των άλλων μοντέλων όσον αφορά την προσαρμοσμένη μετρική, με τιμή 0,230 σε σύγκριση με τιμές που κυμαίνονται από 0,254 έως 4,211 για τα άλλα μοντέλα. Όσον αφορά τις άλλες μετρικές, τα μοντέλα  $METSFormer_{ELET_1}$  και  $METSFormer_{ELET_4}$  είχαν γενικά καλύτερες επιδόσεις, υποδεικνύοντας ότι είναι καταλληλότερα για την ακριβή πρόβλεψη του όγκου κυκλοφορίας για την κατεύθυνση ELET.

Για τις κατευθύνσεις ISTE και ISTT, υπήρχαν λιγότερα μοντέλα για σύγκριση, αλλά φαίνεται ότι τα μοντέλα METSFormer υπερέχουν έναντι του ETSFormer όσον αφορά την προσαρμοσμένη μετρική και τις περισσότερες άλλες μετρικές. Συγκεκριμένα, τα  $METSFormer_{ISTE_1}$  και  $METSFormer_{ISTE_2}$  επέτειχαν και τα δύο τιμές προσαρμοσμένης μετρικής 0,346, οι οποίες είναι πολύ χαμηλότερες από την τιμή 1,317 για το ETSFormer\_ISTE. Παρομοίως, το  $METSFormer_{ISTT_1}$  είχε προσαρμοσμένη μετρική τιμή 0,488, η οποία είναι χαμηλότερη από την τιμή 0,856 για το ETSFormer\_ISTT.

Επομένως, όπως προκύπτει από τα παραπάνω αποτελέσματα για τους σταθμούς διοδίων ELEE και ISTE, οι καλύτερες υπερπαραμέτροι περιέχουν 2 στρώματα κωδικοποιητή και αποκωδικοποιητή με 2 κεφαλές προσοχής και επιλέγονται τα 4 καλύτερα πλάτη στο πεδίο της συχνότητας, τα οποία αποτελούν την εποχική λανθάνουσα συνιστώσα. Ομοίως, για τους σταθμούς διοδίων ELET και ISTT οι καλύτερες υπερπαραμέτροι περιέχουν 4 στρώματα κωδικοποιητή και αποκωδικοποιητή με 4 κεφαλές προσοχής και επιλέγονται τα 3 καλύτερα πλάτη στο πεδίο της συχνότητας. Τα αποτελέσματα αυτά έρχονται σε έντονη αντίθεση με τα αποτελέσματα των συγγραφέων του [96] οι οποίοι προτείνουν 2 στρώματα κωδικοποιητή και αποκωδικοποιητή με 8 κεφαλές προσοχής και επιλέγονται τα 3 καλύτερα πλάτη στο πεδίο

της συχνότητας. Οι διαφορές στις τιμές των υπερπαραμέτρων μπορεί να οφείλονται στο γεγονός ότι το σύνολο δεδομένων ενδέχεται να περιλαμβάνει περισσότερα διακριτά μοτίβα και συσχετίσεις δεδομένων, καθιστώντας ευκολότερο για το μοντέλο να αναλύσει τη χρονοσειρά σε συνιστώσες και να τις μάθει περαιτέρω. Ταυτόχρονα, η εισαγωγή εξωγενών παραγόντων στην είσοδο του μοντέλου συνέβαλε καθοριστικά στη βελτίωση της απόδοσης του και αποτελεί πιθανώς τον λόγο για τον οποίο το μοντέλο είναι σε θέση να προβλέψει με ακρίβεια τον όγκο κυκλοφορίας με λιγότερες κεφαλές προσοχής.

Όπως έχει εξηγηθεί, με τη χρήση πολλαπλών κεφαλών προσοχής, το μοντέλο μπορεί να μάθει διαφορετικές σχέσεις μεταξύ των δεδομένων εισόδου αποδίδοντας προσοχή σε διαφορετικές θέσεις στην ακολουθία με διαφορετικά ερωτήματα και κλειδιά. Κάθε κεφαλή προσοχής μαθαίνει μια διαφορετική αναπαράσταση της ακολουθίας εισόδου, επιτρέποντας στο μοντέλο να συλλάβει καλύτερα τις πολύπλοκες εξαρτήσεις μεταξύ των δεδομένων χρονοσειράς και να βελτιώσει την απόδοσή του.

Η προσθήκη περισσότερων επιπέδων στο μοντέλο μετασχηματιστή αυξάνει το βάθος του δικτύου, επιτρέποντάς του να μαθαίνει πιο σύνθετα μοτίβα και σχέσεις μεταξύ των ακολουθιών εισόδου και εξόδου. Αυτό το αυξημένο βάθος μπορεί να είναι ιδιαίτερα χρήσιμο για μεγαλύτερες ακολουθίες, όπου μπορεί να απαιτούνται περισσότερα στρώματα για την πλήρη καταγραφή των εξαρτήσεων μεταξύ απομακρυσμένων σημείων της ακολουθίας.

Τέλος, η υπερπαραμέτρος  $K$  καθορίζει τον αριθμό των καλύτερων συνιστωσών στο πεδίο της συχνότητας. Η εποχική λανθάνουσα συνιστώσα μιας χρονοσειράς αντιπροσωπεύει το υποκείμενο εποχικό πρότυπο που δεν είναι άμεσα παρατηρήσιμο στα δεδομένα. Προσδιορίζοντας τα κορυφαία  $K$  πλάτη στο πεδίο της συχνότητας, το μοντέλο  $ETSFormer$  μπορεί να εξάγει τα πιο σημαντικά εποχικά μοτίβα από τα δεδομένα και να τα χρησιμοποιήσει για να κάνει πιο ακριβείς προβλέψεις. Η επιλογή μιας μεγαλύτερης τιμής  $K$  επιτρέπει στο μοντέλο να συλλάβει πιο σύνθετα εποχικά μοτίβα που μπορεί να μην αντιπροσωπεύονται πλήρως από έναν μικρότερο αριθμό συνιστωσών. Ωστόσο, η αύξηση του αριθμού των ληφθέντων συνιστωσών αυξάνει επίσης την πολυπλοκότητα του μοντέλου και δύναται να οδηγήσει σε υπερεκπαίδευση.

Συνολικά, τα αποτελέσματα υποδηλώνουν ότι το μοντέλο  $METSFormer$  είναι μια πολλά υποσχόμενη προσέγγιση για την πρόβλεψη χρονοσειρών, υπερτερώντας των μοντέλων  $ETSFormer$  σε όλους τους σταθμούς διόδων όσον αφορά την προσαρμοσμένη μετρική και άλλες βασικές μετρικές. Συγκεκριμένα, τα  $METSFormer_{ELEE_1}$  και  $METSFormer_{ELET_4}$  εμφανίζονται ως τα καλύτερα μοντέλα για τις κατευθύνσεις  $ELEE$  και  $ELET$ , αντίστοιχα, ενώ τα  $METSFormer_{ISTE_1}$  και  $METSFormer_{ISTT_2}$  εμφανίζονται ως τα καλύτερα μοντέλα για τις κατευθύνσεις  $ISTE$  και  $ISTT$ , αντίστοιχα. Εκτός αυτών, τα αποτελέσματα αναδεικνύουν επίσης τη σημασία της προσαρμογής των υπερπαραμέτρων και της επιλογής της έκδοσης του μοντέλου για την επίτευξη βέλτιστης απόδοσης.

Ο Πίνακας 7.6 παρουσιάζει τα αποτελέσματα της μονομεταβλητής πρόβλεψης μακράς ακολουθίας στο σύνολο δεδομένων διαφόρων αρχιτεκτονικών μετασχηματιστή, συμπεριλαμβανομένων των καλύτερων μοντέλων  $METSFormer$  που επισημαίνονται στον Πίνακα 7.5, σε έξι διαφορετικές μετρικές αξιολόγησης: MSE, RMSE, MAE, MAPE και MSPE. Ο πίνακας χωρίζεται σε τέσσερις ενότητες, με κάθε ενότητα να παρουσιάζει τα αποτελέσματα των μοντέλων

Όνομα Μοντέλου	Κατεύθυνση	Custom	MSE	RMSE	MAE	MAPE	MSPE
Transformer	ELEE	<u>0.327</u>	<b>0.098</b>	<b>0.176</b>	<u>0.313</u>	<b>0.169</b>	<b>0.068</b>
Informer	ELEE	0.742	0.167	0.204	0.409	0.200	0.137
FEDFormer	ELEE	1.119	0.491	0.469	0.700	0.619	1.217
METSFormer_ELEE <sub>1</sub>	ELEE	0.342	0.120	0.203	0.347	0.244	0.223
Ensemble <sub>1</sub>	ELEE	<b>0.297</b>	<u>0.118</u>	<u>0.185</u>	<b>0.144</b>	<u>0.182</u>	<u>0.102</u>
Transformer	ELET	<u>0.261</u>	<b>0.067</b>	<b>0.148</b>	<b>0.259</b>	<u>0.141</u>	<u>0.038</u>
Informer	ELET	0.319	0.092	0.182	0.304	0.194	0.095
METSFormer_ELET <sub>4</sub>	ELET	0.230	0.064	0.168	0.253	0.231	0.149
Ensemble <sub>2</sub>	ELET	<b>0.211</b>	<u>0.075</u>	<u>0.156</u>	<u>0.275</u>	<b>0.149</b>	<b>0.047</b>
Transformer	ISTE	<u>0.248</u>	<b>0.081</b>	<b>0.155</b>	<b>0.286</b>	<b>0.161</b>	<b>0.064</b>
Informer	ISTE	0.720	0.168	0.194	0.410	0.208	0.148
METSFormer_ISTE <sub>1</sub>	ISTE	0.346	0.132	0.214	0.364	0.284	0.282
Ensemble <sub>3</sub>	ISTE	<b>0.234</b>	<u>0.104</u>	<u>0.167</u>	<u>0.323</u>	<u>0.172</u>	<u>0.087</u>
Transformer	ISTT	<u>0.250</u>	<b>0.074</b>	<b>0.148</b>	<b>0.273</b>	<b>0.151</b>	<b>0.062</b>
Informer	ISTT	0.294	0.109	0.189	0.331	0.226	0.172
METSFormer_ISTT <sub>2</sub>	ISTT	0.258	0.106	0.204	0.326	0.284	0.275
Ensemble <sub>4</sub>	ISTT	<b>0.183</b>	<u>0.079</u>	<u>0.153</u>	<u>0.282</u>	<u>0.155</u>	<u>0.066</u>

Table 7.6: Αποτελέσματα μονομεταβλητής πρόβλεψης μακράς ακολουθίας για διαφορετικές αρχιτεκτονικές Μετασχηματιστή στο σύνολο δεδομένων. Τα καλύτερα αποτελέσματα επισημαίνονται με **έντονη γραφή** και τα δεύτερα καλύτερα αποτελέσματα με υπογράμμιση.

σε ένα συγκεκριμένο σταθμό διοδίων: ELEE, ELET, ISTE και ISTT.

Τα μοντέλα που αξιολογήθηκαν περιλαμβάνουν μοντέλα βαθιάς μάθησης που έχουν προταθεί τα τελευταία χρόνια για την πρόβλεψη χρονοσειρών, όπως ο vanilla Transformer, ο Informer, ο FEDFormer (μόνο για τον σταθμό διοδίων ELEE) και ο METSFormer. Επιπλέον, ο πίνακας εμφανίζει την απόδοση τεσσάρων συνδυαστικών μοντέλων (ένα για κάθε σταθμό διοδίων) που συνδυάζουν ορισμένα βασικά μοντέλα που παρουσιάζονται στον Πίνακα 7.4.

Τα αποτελέσματα αποκαλύπτουν ότι το μοντέλο vanilla Transformer έχει σταθερά καλές επιδόσεις και στους τέσσερις σταθμούς διοδίων, επιτυγχάνοντας τα καλύτερα αποτελέσματα όσον αφορά όλες τις μετρικές εκτός από τη προσαρμοσμένη μετρική. Το γεγονός αυτό δεν είναι παράδοξο, καθώς το μοντέλο μετασχηματιστή έχει αποδειχθεί ότι αποδίδει καλά σε ένα ευρύ φάσμα εργασιών πρόβλεψης χρονοσειρών, χάρη στον μηχανισμό πλήρους προσοχής, ο οποίος του επιτρέπει να συλλαμβάνει μακροπρόθεσμες εξαρτήσεις και μοτίβα στα δεδομένα. Όσον αφορά την προσαρμοσμένη μετρική, τα συνδυαστικά μοντέλα επιτυγχάνουν τα καλύτερα αποτελέσματα για όλους τους σταθμούς διοδίων, υποδεικνύοντας ότι είναι τα καταλληλότερα μοντέλα για τη συγκεκριμένη εργασία. Τα συνδυαστικά μοντέλα αποτελούν συνδυασμό ενός μοντέλου μετασχηματιστή, το οποίο είναι το καλύτερο μεμονωμένο μοντέλο για κάθε σταθμό διοδίων, και ενός μοντέλου METSFormer, καταλήγοντας στο συμπέρασμα ότι το METSFormer βελτιώνει την απόδοση του μοντέλου μετασχηματιστή για υψηλές κορυφές, λόγω του



γεγονότος ότι η προσαρμοσμένη μετρική μειώνεται. Ο μόνος τρόπος με τον οποίο μπορεί να μειωθεί η προσαρμοσμένη μετρική είναι να υπάρχουν μικρότερα σφάλματα για υψηλές τιμές και λιγότερη υποεκτίμηση των πραγματικών τιμών. Παρόλο που το METSFormer δεν υπερέχει έναντι των άλλων μοντέλων σε κοινές μετρικές, όπως MSE, MAE και RMSE, έχει καλή απόδοση για το συγκεκριμένη εργασία και δείχνει τη σημασία της αξιολόγησης των μοντέλων με βάση τις απαιτήσεις της εκάστοτε εργασίας.

Από την άλλη πλευρά, το μοντέλο Informer επιτυγχάνει τη χειρότερη επίδοση μεταξύ όλων των μοντέλων, εκτός από τον σταθμό διοδίων ELEE όπου το FEDFormer παρουσιάζει χαμηλότερη επίδοση. Όπως φαίνεται από τον Πίνακα 7.6 για τους σταθμούς διοδίων ELEE και ISTE ο Informer αδυνατεί να συλλάβει τις εξαρτήσεις των δεδομένων, σε αντίθεση με τους σταθμούς ELET και ISTT που επιτυγχάνει παρόμοια αποτελέσματα με άλλα μοντέλα και σε ορισμένες περιπτώσεις αποδίδει καλύτερα, π.χ. για τις μετρικές MAPE και MSPE σε σύγκριση με το METSFormer). Το μοντέλο Informer είναι επίσης ένα μοντέλο που βασίζεται στην προσοχή και ενσωματώνει πολλαπλούς ορίζοντες πρόβλεψης και έναν μηχανισμό αυτοπροσοχής ProbSparse. Τα αποτελέσματα δείχνουν ότι ο μηχανισμός FA ενδείκνυται περισσότερο για το συγκεκριμένο σύνολο δεδομένων, αλλά οι επιδόσεις του ProbSparse και των άλλων μηχανισμών προσοχής μπορεί να επηρεάζονται από το παράθυρο αναδρομής και τον ορίζοντα πρόβλεψης, οι οποίες είναι δύο υπερ-παράμετροι που είχαν προκαθοριστεί με δυνατότητα διαμόρφωσης μόνο από την ΟΛΥΜΠΙΑ ΟΔΟΣ Α.Ε.. Με άλλα λόγια, για ένα μεγαλύτερο παράθυρο αναδρομής (π.χ. 576, 864 κ.λπ.), άλλοι μηχανισμοί προσοχής μπορεί να είχαν εμφανίσει καλύτερα αποτελέσματα, αλλά αποδεικνύεται ότι θα είχαν επιδείξει χειρότερη χρονική και χωρική πολυπλοκότητα.

Το μοντέλο FEDFormer δεν εξετάστηκε λεπτομερώς σε αυτή τη διπλωματική εργασία, διότι όπως φαίνεται για τον σταθμό διοδίων ELEE δεν απέδωσε σε σύγκριση με τα άλλα μοντέλα, οπότε επιλέχθηκε να μην εξεταστεί περαιτέρω. Τα αποτελέσματά του για την κατεύθυνση ELEE είναι παρόμοια με τα αποτελέσματα του κλασικού ETSFormer (στον Πίνακα 7.5, υποδεικνύοντας ότι η απόδοση του FEDFormer μπορεί να βελτιωθεί (αλλά με κόστος την ερμηνευσιμότητα) με την προσθήκη ενός τελευταίου πλήρως διασυνδεδεμένου επιπέδου που αποτυπώνει τις εξαρτήσεις των εξόδων εποχικότητας και τάσης από τον αποκωδικοποιητή. Γενικά, διαφαίνεται ότι η αποσύνθεση στο πεδίο της συχνότητας για τη συγκεκριμένη εργασία και το συγκεκριμένο σύνολο δεδομένων δεν είναι αρκετή και δεν είναι ικανή να αποσυνθέσει τις χρονοσειρές πιο αποτελεσματικά από τα μοντέλα αποσύνθεσης που βασίζονται στο χρόνο, όπως ο Transformer και ο Informer.

Τέλος, το συνδυαστικό μοντέλο επιτυγχάνει καλά αποτελέσματα και στα τέσσερα σύνολα δεδομένων, με τα δεύτερα καλύτερα αποτελέσματα για τα MSE, MAE, RMSE, MAPE και MSPE και τα καλύτερα αποτελέσματα για την προσαρμοσμένη μετρική για όλους τους σταθμούς διοδίων. Το συνδυαστικό μοντέλο συνδυάζει υπό συνθήκες τις προβλέψεις δύο βασικών μοντέλων και μπορεί να επωφεληθεί από την ποικιλομορφία των επιμέρους προβλέψεων. Ωστόσο, απαιτεί επίσης προσεκτική ρύθμιση των κατωφλίων για την επίτευξη καλών επιδόσεων.

Συνοπτικά, τα αποτελέσματα δείχνουν ότι το μοντέλο μετασχηματιστή είναι μια αξιόπιστη

επιλογή για τη μονομεταβλητή πρόβλεψη του όγκου κυκλοφορίας. Το μοντέλο Informer μπορεί επίσης να αποτελέσει καλή επιλογή σε ορισμένες περιπτώσεις, αλλά φαίνεται να είναι λιγότερο αξιόπιστο από το μοντέλο μετασχηματιστή. Το καλύτερο μοντέλο σε συνάρτηση με την προσαρμοσμένη μετρική, η οποία βασίζεται στις απαιτήσεις της συγκεκριμένης εργασίας, είναι για όλους τους σταθμούς διοδίων το προτεινόμενο συνδυαστικό μοντέλο.

### 7.2.1 Απώλεια εκπαίδευσης και επικύρωσης


Στο Σχήμα 7.1 εμφανίζονται οι απώλειες εκπαίδευσης και επικύρωσης για δύο σταθμούς διοδίων, ELEE και ELET, για κάθε μοντέλο που παρουσιάζεται στον Πίνακα 7.6. Η προσαρμοσμένη μετρική, όπως περιγράφηκε προηγουμένως στην παρούσα εργασία, χρησιμοποιήθηκε για τη μέτρηση τόσο των απωλειών εκπαίδευσης όσο και των απωλειών επικύρωσης. Η απώλεια επικύρωσης χρησιμοποιήθηκε κυρίως για την αξιολόγηση της απόδοσης των μοντέλων κατά τη διαδικασία εκπαίδευσης και για τη διεξαγωγή μιας προκαταρκτικής αξιολόγησης του συνόλου δεδομένων από το 2019. Ωστόσο, δεν χρησιμοποιήθηκε για την πρόωρη διακοπή, η οποία είναι μια τεχνική που αποτρέπει την υπερπροσαρμογή των μοντέλων μηχανικής μάθησης. Αντ' αυτού, ορίστηκε ένας σταθερός αριθμός εποχών για κάθε μοντέλο πριν από την εκπαίδευση, και ανά δύο εποχές πραγματοποιούνταν επικύρωση για την αξιολόγηση των επιδόσεων του μοντέλου.

Όπως απεικονίζεται στο Σχήμα 7.1, τα μοντέλα Transformer, Informer και METSFormer\_1 επέδειξαν αποτελεσματικότερη και ταχύτερη κλιμάκωση, με μικρότερες τελικές απώλειες εκπαίδευσης από τα υπόλοιπα μοντέλα, και για τους δύο σταθμούς διοδίων. Ειδικότερα, το μοντέλο Transformer πέτυχε τις μικρότερες απώλειες εκπαίδευσης για κάθε σταθμό διοδίων. Αξίζει να σημειωθεί ότι ο μηχανισμός πλήρους προσοχής του μοντέλου μετασχηματιστή και η απλούστερη αρχιτεκτονική του διευκόλυναν σημαντικά χαμηλότερες απώλειες, ακόμη και από την πρώτη εποχή. Αντίθετα, τα μοντέλα FEDFormer και το κλασικό ETSFormer εμφάνισαν την υψηλότερη απώλεια εκπαίδευσης και για τους δύο σταθμούς διοδίων. Η μικρότερη απώλεια εκπαίδευσης του μοντέλου METSFormer\_1, παρά το γεγονός ότι διαθέτει μικρότερο αριθμό στρωμάτων κωδικοποιητή και αποκωδικοποιητή και πλήρως διασυνδεδεμένο επίπεδο μικρότερων διαστάσεων, υποδηλώνει ότι το σύνολο δεδομένων της παρούσας εργασίας περιγράφεται και μοντελοποιείται καλύτερα από απλούστερες αρχιτεκτονικές. Επιπλέον, το κλασικό μοντέλο ETSFormer δεν μπόρεσε να μάθει μοτίβα και τάσεις, όπως αποδεικνύεται από την αποτυχία του να μειώσει την απώλεια εκπαίδευσης για τον σταθμό διοδίων ELET, παρόμοια με τα άλλα μοντέλα.


Όσον αφορά τις απώλειες επικύρωσης, τα μοντέλα FEDFormer και ETSFormer παρουσίασαν τις χειρότερες επιδόσεις, ενώ τα μοντέλα Transformer και METSFormer\_1 παρουσίασαν τα καλύτερα αποτελέσματα. Ωστόσο, όλα τα μοντέλα, εκτός από το μοντέλο ETSFormer, επέδειξαν επίπεδη απώλεια επικύρωσης, που δεν υποδεικνύει μείωση ή αύξηση μετά από δύο εποχές. Αυτό είναι επίσης εμφανές στην απώλεια εκπαίδευσης, όπου η απώλεια όλων των μοντέλων πέφτει σημαντικά μετά από μία εποχή και μειώνεται αργά στη συνέχεια. Ωστόσο, αυτό δεν φάνηκε στα στοιχεία των απωλειών επικύρωσης, καθώς η επικύρωση πραγματοποιήθηκε

κάθε δύο εποχές, ξεκινώντας από τη δεύτερη εποχή.


Στο Παράρτημα Α' παρατίθεται παρόμοια ανάλυση για τους σταθμούς διοδίων ISTE και ISTT με τη χρήση των ίδιων μοντέλων μετασχηματιστών. Συνολικά, τα αποτελέσματα υποδηλώνουν ότι τα μοντέλα Transformer, Informer και METSFormer\_1 υπερτερούν έναντι των μοντέλων FEDFormer και των κλασικών μοντέλων ETSFormer όσον αφορά τόσο τις απώλειες εκπαίδευσης όσο και τις απώλειες επικύρωσης. Επιπλέον, οι απλούστερες αρχιτεκτονικές των μοντέλων Transformer και METSFormer\_1 κρίθηκαν καταλληλότερες για τη μοντελοποίηση του συνόλου δεδομένων της παρούσας εργασίας.




(a) Απώλεια εκπαίδευσης στο ELEE



(b) Απώλεια επικύρωσης στο ELEE



(c) Απώλεια εκπαίδευσης στο ELET



(d) Απώλεια επικύρωσης στο ELET


Figure 7.1: Απώλειες εκπαίδευσης και επικύρωσης για τους σταθμούς διοδίων ELEE και ELET, για κάθε μοντέλο του Πίνακα 7.6

### 7.3 Προβλέψεις κυκλοφορίας

Στην Ενότητα αυτή παρουσιάζονται τα αποτελέσματα της πρόβλεψης του όγκου της κυκλοφορίας των συνδυαστικών μοντέλων για δύο σταθμούς διοδίων, τους ELEE και ELET. Τα αποτελέσματα πρόβλεψης και για τους τέσσερις σταθμούς διοδίων βρίσκονται στο Παράρτημα Α'. Για λόγους απορρήτου, στα γραφήματα που παρουσιάζονται δεν εμφανίζονται οι πραγματικές τιμές του όγκου κυκλοφορίας. Κάθε διάγραμμα στα αποτελέσματα περιλαμβάνει μία πράσινη γραμμή, η οποία αντιπροσωπεύει τις πραγματικές τιμές, μία κίτρινη γραμμή που αντιπροσωπεύει τις προβλέψεις του μοντέλου και μία μπλε γραμμή που αντιπροσωπεύει τη διαφορά μεταξύ τους. Οι τρεις πρώτες ημέρες κάθε σχήματος αντιπροσωπεύουν το παράθυ-

ρο αναδρομής, ενώ οι τρεις τελευταίες ημέρες αντιπροσωπεύουν τον ορίζοντα πρόβλεψης. Η Grafana χρησιμοποιήθηκε για τη δημιουργία όλων των ακόλουθων σχημάτων.

Όπως φαίνεται στο Σχήμα 7.2, το συνδυαστικό μοντέλο αποτυπώνει με ακρίβεια την αύξηση και το επίπεδο του όγκου κυκλοφορίας. Ωστόσο, το συγκεκριμένο σχήμα αναδεικνύει επίσης έναν σημαντικό περιορισμό του συνδυαστικού μοντέλου, ο οποίος είναι η ασυνέχεια, μιας και συνδυάζει την έξοδο δύο μοντέλων για να κάνει προβλέψεις, αλλά χρησιμοποιεί κάποια κατώτατα όρια που δημιουργούν ασυνέχεια εάν οι έξοδοι των μοντέλων είναι κοντά σε αυτά. Επομένως, παρόλο που το Ensemble\_ELEE πέτυχε την καλύτερη επίδοση όσον αφορά την προσαρμοσμένη μετρική στο σύνολο δοκιμών για το έτος 2017, εξακολουθεί να χρειάζεται κάποιες βελτιώσεις για να είναι πιο εύρωστο και αξιόπιστο.



Σχήμα 7.2: Προβλέψεις των συνδυαστικών μοντέλων για τον σταθμό διοδίων ELEE και ELET. Το παράθυρο αναδρομής είναι από 20/02/2023 00:00 έως 22/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 23/02/2023 00:00 έως 25/02/2023 00:00.

### 7.3.1 Τελικό συνδυαστικό μοντέλο

Προς αυτή την κατεύθυνση, εισάγεται ένα ακόμη συνδυαστικό μοντέλο, που συνδυάζει την έξοδο των δύο μοντέλων για να κάνει προβλέψεις με βάση τους ακόλουθους κανόνες:

1. Εάν οι προβλέψεις αφορούν την επόμενη ημέρα, τότε η πρόβλεψη είναι ίση με τη μέγιστη έξοδο των δύο μοντέλων.
2. Εάν οι προβλέψεις ΔΕΝ είναι για την επόμενη ημέρα και εάν η μέγιστη τιμή των προβλέψεων για την προηγούμενη ημέρα είναι πάνω από ένα κατώφλι, τότε η πρόβλεψη είναι ίση με τη μέγιστη έξοδο των δύο μοντέλων.
3. Εάν οι προβλέψεις ΔΕΝ αφορούν την επόμενη ημέρα και εάν η μέγιστη τιμή των προβλέψεων για την τελευταία ημέρα ΔΕΝ είναι πάνω από ένα όριο, τότε η πρόβλεψη είναι ίση με την έξοδο του πρώτου μοντέλου.

Τυπικά, έστω  $x$  η ακολουθία εισόδου,  $f_A(x)$  και  $f_B(x)$  οι έξοδοι του μοντέλου Α και του μοντέλου Β, αντίστοιχα, και  $\hat{y}$  η πρόβλεψη του τελικού συνδυαστικού μοντέλου. Τότε, η πρόβλεψη χρονοσειρών με το συγκεκριμένο μοντέλο περιγράφεται από τον Αλγόριθμο 2.

---

#### Algorithm 2 Final Ensemble Model Forecasting Algorithm

---

**Require:** Input sequence  $x$  with length  $enc\_in = 288$

**Require:** Model A with output  $f_A(x)$

**Require:** Model B with output  $f_B(x)$

**Require:** Threshold  $\alpha$

**Ensure:** Prediction  $\hat{y}$

```

for  $t \in \text{range}(\text{len}(x))$  do
2:   if  $t \leq 96$  then
        $\hat{y}_t \leftarrow \max(f_A(x, t), f_B(x, t))$ 
4:   else
       Compute the maximum value of  $\hat{y}$  for previous day:  $max\_prev \leftarrow \max(\hat{y}[(t - t \bmod 96 - 96) : (t - t \bmod 96)])$ 
6:   if  $max\_prev \geq \alpha$  then
        $\hat{y}_t \leftarrow \max(f_A(x, t), f_B(x, t))$ 
8:   else
        $\hat{y}_t \leftarrow f_A(x)$ 
10:  end if
      end if
12: end for
return  $\hat{y}$ 

```

---


Ο Αλγόριθμος 2 προέκυψε από μια σειρά παρατηρήσεων που έγιναν κατά τη διάρκεια της αξιολόγησης της απόδοσης των μοντέλων. Παρόλο που το μοντέλο Transformer υπερέχει του METSFormer\_1 όσον αφορά τις συνολικές μετρικές αξιολόγησης, παρατηρήθηκε ότι το

METSFormer\_1 ήταν καταλληλότερο για την καταγραφή των τάσεων και των αιχμών στις χρονοσειρές του όγκου κυκλοφορίας για συγκεκριμένες περιπτώσεις· πρόβλεψη της επόμενης ημέρας και πρόβλεψη για τις επόμενες ημέρες όταν οι προβλέψεις της προηγούμενης ημέρας είναι υψηλές. Το νέο συνδυαστικό μοντέλο χρησιμοποιεί το Transformer για τις κοινές προβλέψεις, όπου δεν πληρούνται οι προαναφερθείσες προϋποθέσεις, και το METSFormer\_1 για τις ειδικές περιπτώσεις που αναφέρθηκαν παραπάνω. Όσον αφορά τις μετρικές αξιολόγησης, το νέο συνδυαστικό μοντέλο δεν επιτυγχάνει τα ίδια αποτελέσματα με το προηγούμενο (Αλγόριθμο 1), αλλά εξακολουθεί να επιτυγχάνει καλύτερα αποτελέσματα από τα μοντέλα Transformer για όλους τους σταθμούς διοδίων. Ο Αλγόριθμος 2 δεν αντιμετωπίζει πλήρως τον περιορισμό της ασυνέχειας, αλλά σίγουρα βελτιώνει την απόδοση, επειδή εξαρτάται μόνο από ένα κατώφλι, σε αντίθεση με τα δύο κατώφλια στο προηγούμενο συνδυαστικό μοντέλο. Η μόνη ασυνέχεια που μπορεί να εμφανιστεί με τον Αλγόριθμο 2 είναι μεταξύ δύο διαδοχικών ημερών σε μια περίοδο πρόβλεψης 3 ημερών. Επιπλέον, είναι λογικό ότι αν την προηγούμενη ημέρα η μέγιστη τιμή είναι μικρή, τότε οι τιμές στην έναρξη της τρέχουσας ημέρας θα είναι μικρότερες ή παρόμοιες με τη μέγιστη τιμή της προηγούμενης ημέρας, οπότε η ασυνέχεια που μπορεί να εμφανιστεί θα είναι αρκετά μικρή ώστε να μην είναι αναγνωρίσιμη.

Η απόδοση του νέου συνδυαστικού μοντέλου αξιολογήθηκε για την περίοδο των διακοπών της Καθαρής Δευτέρας 2023 (27 Φεβρουαρίου 2023) και τα αποτελέσματα παρουσιάζονται στα Σχήματα 7.3 - 7.7, με το καθένα να αντιπροσωπεύει τα αποτελέσματα πρόβλεψης 3 ημερών ξεκινώντας την πρόβλεψη από τις 23/02/2023 (Σχήμα 7.3) έως τις 27/02/2023 (Σχήμα 7.7). Παρατηρήθηκε ότι τα αποτελέσματα πρόβλεψης για τις ημέρες που βρίσκονται πιο κοντά στην ημέρα έναρξης ήταν καλύτερα από εκείνα των επόμενων ημερών. Για παράδειγμα, η πρόβλεψη για τις 27/02/2023 είναι καλύτερη στο Σχήμα 7.6 από το Σχήμα 7.5 και ακόμη καλύτερη στο Σχήμα 7.7. Αυτό είναι λογικό επειδή το μοντέλο λαμβάνει περισσότερες σχετικές εισόδους για την πρόβλεψη της επόμενης ημέρας παρά των επόμενων ημερών. Γενικά, το συνδυαστικό μοντέλο κατάφερε να συλλάβει ικανοποιητικά την τάση τόσο για τους σταθμούς διοδίων του ELEE όσο και για τους σταθμούς διοδίων του ELET, όπως αποδεικνύεται από τη μπλε γραμμή στα σχήματα, η οποία αντιπροσωπεύει τη διαφορά μεταξύ των πραγματικών και των προβλεπόμενων τιμών. Το μοντέλο υπερεκτίμησε τον όγκο της κυκλοφορίας στις περισσότερες περιπτώσεις, αλλά και τον υποεκτίμησε σε ορισμένες περιπτώσεις, ιδίως μετά τις αιχμές. Εάν η διαφορά μεταξύ των πραγματικών και των προβλεπόμενων τιμών είναι πάνω από μηδέν στη μέση μιας ημέρας, αυτό σημαίνει ότι το μοντέλο δεν κατάφερε να καταγράψει την αιχμή, που είναι ένας από τους κύριους στόχους του μοντέλου.

Στο Παράρτημα Α' απεικονίζεται η πρόβλεψη της κυκλοφορίας για όλους τους σταθμούς διοδίων, συμπεριλαμβανομένων των ISTT και ISTE, για τις περιόδους αργίας της Καθαράς Δευτέρας 2023 και της 25<sup>ης</sup> Μαρτίου. Υψηλή κίνηση παρατηρείται στα διόδια της Ολυμπίας Οδού κατά τη διάρκεια αυτών των περιόδων εορτών λόγω του μεγάλου αριθμού ταξιδιωτών. Φυσικά, το μοντέλο δεν είναι τέλει, όπως απεικονίζεται στα Σχήματα Α'.9 - Α'.11 στο Παράρτημα Α', όπου το μοντέλο απέτυχε να συλλάβει την υψηλότερη αιχμή για τον σταθμό διοδίων ELEE στις 26 Μαρτίου 2023. Παρατηρήθηκε επίσης ότι υπάρχει υψηλή κίνηση στους σταθμούς διοδίων ELET και ISTT τις ημέρες έναρξης μιας περιόδου διακοπών ή τα Σαβ-


βατοκύριακα, καθώς πολλοί κάτοικοι της Αθήνας αποφασίζουν να πάνε διακοπές τις ημέρες αυτές. Αντίστοιχα, παρατηρήθηκε υψηλή κίνηση στους σταθμούς διοδίων ELEE και ISTE τις τελευταίες ημέρες μιας περιόδου διακοπών ή τις ημέρες πριν από τις εργάσιμες ημέρες, καθώς οι άνθρωποι επιστρέφουν στα σπίτια τους από τις διακοπές τους. Προς αυτή την κατεύθυνση, οι σταθμοί διοδίων ELEE και ISTE παρουσίασαν παρόμοια συμπεριφορά, με τον ELEE να έχει ελαφρώς υψηλότερη κίνηση, ενώ η ίδια τάση παρατηρήθηκε και για τους σταθμούς ELET και ISTT, όπου ο ELET είχε ελαφρώς μεγαλύτερη κίνηση από τον ISTT.



Σχήμα 7.3: Προβλέψεις του προτεινόμενου συνδυαστικού μοντέλου για τους σταθμούς διοδίων ELEE και ELET. Το παράθυρο αναδρομής είναι από 20/02/2023 00:00 έως 22/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 23/02/2023 00:00 έως 25/02/2023 00:00.

## 7.4 Πολυμεταβλητή πρόβλεψη κυκλοφορίας

Εκτός από τη μονομεταβλητή πρόβλεψη χρονοσειρών, η παρούσα μελέτη αναδεικνύει τη σημασία της διερεύνησης της πολυμεταβλητής πρόβλεψης χρονοσειρών για την πρόβλεψη του



Σχήμα 7.4: Προβλέψεις του προτεινόμενου συνδυαστικού μοντέλου για τους σταθμούς διοδίων ELEE και ELET. Το παράθυρο αναδρομής είναι από 21/02/2023 00:00 έως 23/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 24/02/2023 00:00 έως 26/02/2023 00:00.


όγκου κυκλοφορίας. Τα μοντέλα μετασχηματιστών έχουν χρησιμοποιηθεί εκτενώς για την πρόβλεψη πολλαπλών μεταβλητών με ένα μόνο μοντέλο, και η προσέγγιση αυτή εφαρμόστηκε και στην παρούσα διατριβή. Τα αποτελέσματα έδειξαν ότι πρόκειται για μια πολλά υποσχόμενη λύση όσον αφορά την υπολογιστική αποδοτικότητα, καθώς συνδυάζει πολλαπλά μοντέλα σε ένα (στην προκειμένη περίπτωση τέσσερα μοντέλα συνδυάστηκαν σε ένα), μειώνοντας όχι μόνο τον συνολικό χρόνο εκπαίδευσης αλλά και την υπολογιστική ισχύ που απαιτείται για την εκπαίδευση. Η προσέγγιση αυτή μπορεί επίσης να καταγράψει τις αλληλεξαρτήσεις μεταξύ διαφορετικών μεταβλητών. Αυτό περιλαμβάνει τις συσχετίσεις και τις αλληλεπιδράσεις μεταξύ σταθμών διοδίων που βρίσκονται στην ίδια κατεύθυνση και τις διασταυρούμενες επιδράσεις μεταξύ σταθμών διοδίων σε διαφορετικές κατευθύνσεις κατά τη διάρκεια περιόδων διακοπών. Το μοντέλο μετασχηματιστή καταφέρνει να συλλάβει αυτές τις εξαρτήσεις με τη χρήση πολλαπλών κεφαλών προσοχής στο μηχανισμό προσοχής. Αυτές οι κεφαλές επιτρέπουν






Σχήμα 7.5: Προβλέψεις του προτεινόμενου συνδυαστικού μοντέλου για τους σταθμούς διοδίων ELEE και ELET. Το παράθυρο αναδρομής είναι από 22/02/2023 00:00 έως 24/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 25/02/2023 00:00 έως 27/02/2023 00:00.

στο μοντέλο να εστιάζει σε διαφορετικά μέρη της ακολουθίας εισόδου και να σταθμίζει τη σημασία τους, επιτρέποντάς του να συλλαμβάνει καλύτερα πολύπλοκα μοτίβα και σχέσεις. Με τη χρήση πολλαπλών κεφαλών προσοχής, το μοντέλο μπορεί να μάθει να παρακολουθεί ταυτόχρονα διαφορετικές πτυχές της εισόδου, αυξάνοντας την ικανότητά του να συλλαμβάνει πιο διαφοροποιημένες σχέσεις και εξαρτήσεις. Επιπλέον, ο μηχανισμός προσοχής επιτρέπει στο μοντέλο να προσαρμόζει δυναμικά τη σημασία των διαφόρων τμημάτων της ακολουθίας με βάση τη σημασία τους για την τρέχουσα πρόβλεψη, οδηγώντας σε πιο ακριβείς και αξιόπιστες προβλέψεις. Αυτό καθιστά την αρχιτεκτονική των μετασχηματιστών κατάλληλη για εργασίες όπως η πρόβλεψη πολυμεταβλητών χρονοσειρών, όπου η καταγραφή των αλληλεπιδράσεων μεταξύ πολλαπλών μεταβλητών είναι κρίσιμη για ακριβείς προβλέψεις.



Σχήμα 7.6: Προβλέψεις του προτεινόμενου συνδυαστικού μοντέλου για τους σταθμούς διοδίων ELEE και ELET. Το παράθυρο αναδρομής είναι από 23/02/2023 00:00 έως 25/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 26/02/2023 00:00 έως 28/02/2023 00:00.



Σχήμα 7.7: Προβλέψεις του προτεινόμενου συνδυαστικού μοντέλου για τους σταθμούς διοδίων ELEE και ELET. Το παράθυρο αναδρομής είναι από 24/02/2023 00:00 έως 26/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 27/02/2023 00:00 έως 29/02/2023 00:00.



## Κεφάλαιο 8

# Συμπεράσματα και μελλοντική έρευνα

Συνοψίζοντας, είναι αρκετοί οι λόγοι για τους οποίους η παρούσα έρευνα είναι σημαντική. Πρώτον, η ακριβής πρόβλεψη του όγκου κυκλοφορίας είναι κρίσιμη για τη διαχείριση και τον προγραμματισμό των μετακινήσεων. Με την ακριβή πρόβλεψη του όγκου της κυκλοφορίας, οι υπηρεσίες μεταφορών μπορούν να λαμβάνουν τεκμηριωμένες αποφάσεις σχετικά με την κατανομή των πόρων, όπως το προσωπικό και ο εξοπλισμός, ώστε να διασφαλίζεται η αποτελεσματική ροή της κυκλοφορίας και να μειώνεται η κυκλοφοριακή συμφόρηση. Δεύτερον, η ανάπτυξη αποτελεσματικών μοντέλων πρόβλεψης του όγκου κυκλοφορίας μπορεί να ωφελήσει το επιβατικό κοινό μειώνοντας την ταλαιπωρία και την απογοήτευση που συνδέονται με την κυκλοφοριακή συμφόρηση. Τέλος, η παρούσα έρευνα μπορεί να συμβάλει στον αυξανόμενο όγκο γνώσεων σχετικά με τις εφαρμογές μηχανικής μάθησης στις μεταφορές και μπορεί να οδηγήσει σε περαιτέρω εξελίξεις στον τομέα αυτό.

Η παρούσα διατριβή διερευνά την αποτελεσματικότητα των μοντέλων μετασχηματιστή στη μονομεταβλητή πρόβλεψη της κυκλοφορίας, χρησιμοποιώντας πραγματικά δεδομένα από τον εθνικό αυτοκινητόδρομο της Ολυμπίας Οδού στην Ελλάδα. Η μελέτη περιλαμβάνει τόσο μεμονωμένα όσο και συνδυαστικά μοντέλα μετασχηματιστή, τα οποία αξιολογήθηκαν ως προς την ικανότητά τους να προβλέπουν με ακρίβεια τον όγκο της κυκλοφορίας. Τα αποτελέσματα καταδεικνύουν ότι οι μετασχηματιστές είναι σε θέση να επιτύχουν ικανοποιητικές επιδόσεις σε αυτή την πολύπλοκη εργασία.

Σύμφωνα με το σύνολο δεδομένων που χρησιμοποιήθηκε στην παρούσα διατριβή, η μεγάλη κυκλοφοριακή συμφόρηση στους αυτοκινητόδρομους εμφανίζεται συνήθως κατά τη διάρκεια των περιόδων διακοπών, οι οποίες αντιπροσωπεύουν μόνο ένα μικρό ποσοστό του έτους, καθώς οι περισσότερες ημέρες είναι εργάσιμες. Κατά συνέπεια, η διεξαγωγή μιας διαδικασίας ETL και η αποτελεσματική προεπεξεργασία δεδομένων είναι απαραίτητη για την αξιοποίηση των δεδομένων που σχετίζονται με την κυκλοφοριακή συμφόρηση, οι τιμές των οποίων θεωρούνται συνήθως ως ακραίες τιμές στην κατανομή του όγκου κυκλοφορίας. Χωρίς αυτή την αυστηρή διαδικασία, τα μοντέλα μηχανικής και βαθιάς μάθησης ενδέχεται να δυσκολευτούν να εντοπίσουν και να μάθουν τα απαραίτητα μοτίβα και τάσεις για την ακριβή αναγνώριση της

κυκλοφοριακής συμφόρησης. Ως εκ τούτου, περαιτέρω έρευνα θα μπορούσε να επικεντρωθεί στην ανάπτυξη ενός συνδυαστικού αλγορίθμου που να συνδυάζει δύο εξειδικευμένα μοντέλα που να μπορούν να χειριστούν διαφορετικές περιοχές κατανομής του όγκου κυκλοφορίας. Το ένα μοντέλο θα μπορούσε να εκπαιδευτεί ώστε να αποδίδει καλά σε μικρές τιμές και γενικά να έχει καλές επιδόσεις σε καθημερινή βάση, ενώ το άλλο μπορεί να υπερέχει στην πρόβλεψη υψηλών τιμών και ακραίων τιμών κατά τη διάρκεια περιόδων διακοπών. Στην παρούσα διατριβή, προτάθηκε ένα συνδυαστικό μοντέλο που χρησιμοποιεί δύο μοντέλα μετασχηματιστών που εκπαιδεύτηκαν σε ολόκληρο το σύνολο δεδομένων και ο τελικός αλγόριθμος ήταν το αποτέλεσμα μιας εμπειρικής μελέτης που ανέδειξε τα πλεονεκτήματα και τους περιορισμούς κάθε μοντέλου.

Για να αναλύσουμε περαιτέρω τα αποτελέσματα της πρόβλεψης, αξίζει να σημειωθεί ότι οι περίοδοι διακοπών, όπως το Πάσχα και οι ελληνικές εθνικές γιορτές, αποτελούν κρίσιμα γεγονότα στην Ελλάδα, τα οποία επηρεάζουν σημαντικά τον όγκο της κυκλοφορίας στους εθνικούς αυτοκινητόδρομους. Ως αποτέλεσμα, οι σταθμοί διοδίων σε αυτούς τους αυτοκινητόδρομους παρουσιάζουν υψηλό όγκο κυκλοφορίας κατά τη διάρκεια αυτών των περιόδων. Οι υπεύθυνοι λειτουργίας των σταθμών διοδίων πρέπει να εξασφαλίσουν επαρκείς πόρους για τη διαχείριση της αυξημένης ροής κυκλοφορίας κατά τις περιόδους αυτές. Είναι επίσης σημαντικό να εξεταστούν οι επιπτώσεις των αποτελεσμάτων της πρόβλεψης για διαφορετικούς σταθμούς διοδίων. Σταθμοί διοδίων όπως οι ELEE και ISTE παρουσιάζουν υψηλή κίνηση τις τελευταίες ημέρες των περιόδων διακοπών ή τις ημέρες πριν από τις εργάσιμες ημέρες, ενώ οι σταθμοί διοδίων ELET και ISTT παρουσιάζουν υψηλή κίνηση τις ημέρες έναρξης των περιόδων διακοπών ή τα Σαββατοκύριακα. Οι παρατηρήσεις αυτές μπορούν να χρησιμοποιηθούν για τον αποτελεσματικό προγραμματισμό των πόρων και την ελαχιστοποίηση της ταλαιπωρίας των ταξιδιωτών κατά τις περιόδους υψηλής κυκλοφορίας.

Γενικά, τα αποτελέσματα της παρούσας μελέτης έχουν σημαντικές επιπτώσεις για τη διαχείριση και τον σχεδιασμό των μεταφορών. Η ακριβής πρόβλεψη του όγκου της κυκλοφορίας μπορεί να βοηθήσει τις υπηρεσίες μεταφορών στη διαχείριση της κυκλοφοριακής ροής και στη μείωση της συμφόρησης. Η ικανότητα πρόβλεψης του μελλοντικού όγκου κυκλοφορίας μπορεί να βοηθήσει τις υπηρεσίες να λαμβάνουν τεκμηριωμένες αποφάσεις σχετικά με την ανάπτυξη πόρων, όπως το προσωπικό και ο εξοπλισμός. Αυτό μπορεί τελικά να οδηγήσει σε πιο αποδοτικά και αποτελεσματικά συστήματα μεταφορών, γεγονός που μπορεί να ωφελήσει τόσο τις υπηρεσίες μεταφορών όσο και το επιβατικό κοινό.

Το συνδυαστικό μοντέλο που χρησιμοποιήθηκε στην παρούσα μελέτη αξιολογήθηκε για διάφορες χρονικές περιόδους, συμπεριλαμβανομένων των καθημερινών και των Σαββατοκύριακων, και υπερέχει σταθερά έναντι των μεμονωμένων μοντέλων μετασχηματιστή για όλους τους σταθμούς διοδίων. Αυτό υποδηλώνει ότι το συνδυαστικό μοντέλο μπορεί να συλλάβει αποτελεσματικά την πολυπλοκότητα των χρονοσειρών του όγκου κυκλοφορίας. Επιπλέον, η μεθοδολογία δεν περιορίζεται στους συγκεκριμένους σταθμούς διοδίων της παρούσας μελέτης, καθιστώντας την ένα πολύτιμο εργαλείο για την πρόβλεψη του όγκου κυκλοφορίας για σταθμούς διοδίων σε διάφορες περιοχές και σε διαφορετικούς τύπους δρόμων, όπως αστικοί δρόμοι ή αυτοκινητόδρομοι σε διάφορες χώρες.

Περαιτέρω έρευνα μπορεί να διεξαχθεί για τη διερεύνηση της απόδοσης των μοντέλων μετασχηματιστή για μεγαλύτερες χρονικές περιόδους, πέρα από την περίοδο πρόβλεψης 3 ημερών που είχε ρυθμιστεί διαμορφωτικά από την ΟΛΥΜΠΙΑ ΟΔΟΣ Α.Ε. στην παρούσα μελέτη. Αυτή η μακροχρόνια πρόβλεψη χρονοσειρών θα μπορούσε να παράσχει πολύτιμες πληροφορίες σχετικά με την ικανότητα των μοντέλων να καταγράφουν μακροχρόνια μοτίβα και τάσεις στον όγκο της κυκλοφορίας. Επιπλέον, η παρούσα μελέτη θα μπορούσε να επεκταθεί ώστε να συγκρίνει την απόδοση διαφορετικών αρχιτεκτονικών μετασχηματιστή και να διερευνήσει την επίδραση διαφορετικών υπερπαραμέτρων στην ακρίβεια των μοντέλων.

Επιπλέον, η διερεύνηση της χρήσης άλλων μοντέλων βαθιάς μάθησης, όπως τα ΣΝΔ ή τα LSTM, για την πρόβλεψη του όγκου κυκλοφορίας θα μπορούσε να προσφέρει πολύτιμες πληροφορίες σχετικά με τις επιδόσεις αυτών των μοντέλων σε σύγκριση με τα μοντέλα μετασχηματιστή που χρησιμοποιήθηκαν στην παρούσα μελέτη. Αυτά τα μοντέλα μπορεί να έχουν διαφορετικά πλεονεκτήματα και αδυναμίες σε σύγκριση με τους μετασχηματιστές και η χρήση τους μπορεί να προσφέρει πολύτιμες πληροφορίες σχετικά με την αποτελεσματικότητα των διαφόρων αρχιτεκτονικών βαθιάς μάθησης για αυτού του είδους τις εργασίες. Επιπλέον, η διερεύνηση διαφορετικών τεχνικών μηχανικής μάθησης, όπως η ενισχυτική μάθηση, μπορεί να είναι επωφελής για την περαιτέρω βελτίωση της ακρίβειας των μοντέλων πρόβλεψης του όγκου κυκλοφορίας. Η ενισχυτική μάθηση μπορεί να επιτρέψει στο μοντέλο να μαθαίνει από τις δικές του ενέργειες και να προσαρμόζει τις προβλέψεις του με βάση την ανατροφοδότηση από το περιβάλλον, γεγονός που μπορεί να οδηγήσει σε πιο ακριβείς και προσαρμοστικές προβλέψεις.

Η παρούσα διατριβή επικεντρώθηκε αποκλειστικά στη μονομεταβλητή πρόβλεψη της κυκλοφορίας και διεξήγαγε μόνο μερικά πειράματα για την πολυμεταβλητή πρόβλεψη, τα οποία δεν παρουσιάστηκαν λόγω της μεγάλης έκτασης της παρούσας μελέτης. Η μελλοντική έρευνα μπορεί να επικεντρωθεί στην πολυμεταβλητή πρόβλεψη χρονοσειρών με το σχεδιασμό ενός ενιαίου μοντέλου και για τους τέσσερις σταθμούς διοδίων αντί για μεμονωμένα μοντέλα όπως στην παρούσα διπλωματική εργασία. Η πολυμεταβλητή ανάλυση είναι ιδιαίτερα σημαντική για την εργασία αυτή, δεδομένου ότι οι σταθμοί διοδίων ELEE και ISTE βρίσκονται στην ίδια κατεύθυνση της Ολυμπίας Οδού, όπως και οι σταθμοί ELET και ISTT, και έχουν παρόμοια κατανομή όγκου κυκλοφορίας, η οποία επηρεάζει η μία την άλλη. Επιπλέον, υπάρχει διασταυρούμενη επίδραση μεταξύ των σταθμών διοδίων διαφορετικών κατευθύνσεων, ιδίως κατά τις περιόδους διακοπών, όταν η υψηλότερη κίνηση είναι στη μία κατεύθυνση στην αρχή και στην αντίθετη κατεύθυνση στο τέλος, όταν οι ταξιδιώτες επιστρέφουν στα σπίτια τους. Το φαινόμενο αυτό είναι ιδιαίτερα συνηθισμένο στην Ελλάδα, όπου υπάρχει μεγάλη κυκλοφοριακή συμφόρηση από την Αθήνα, την πρωτεύουσα της Ελλάδας, στην αρχή μιας περιόδου διακοπών, και υπάρχει αυξημένη κίνηση προς την Αθήνα στο τέλος αυτής της περιόδου. Η συνέχιση της έρευνας στον τομέα αυτό θα μπορούσε να οδηγήσει σε πιο προηγμένες και εξελιγμένες μεθόδους πρόβλεψης του όγκου της κυκλοφορίας, οι οποίες μπορούν να έχουν σημαντικές επιπτώσεις στη διαχείριση και τον σχεδιασμό των μεταφορών και της κυκλοφορίας. Παράλληλα, μπορεί να είναι χρήσιμη και η διερεύνηση των δυνατοτήτων ενσωμάτωσης άλλων εξωτερικών παραγόντων στο μοντέλο πρόβλεψης για την ενίσχυση της ακρίβειάς του. Εκτός από τις καιρικές συνθήκες, τα σημαντικά γεγονότα ή τις αργίες και το κλείσιμο δρόμων

ή τα κατασκευαστικά έργα, θα μπορούσαν να ληφθούν υπόψη και άλλοι παράγοντες, όπως οι οικονομικοί δείκτες, τα δρομολόγια των δημόσιων συγκοινωνιών και οι τάσεις των μέσων κοινωνικής δικτύωσης. Ωστόσο, πρέπει να ληφθεί προσεκτικά υπόψη η συνάφεια αυτών των παραγόντων με το συγκεκριμένο σύνολο δεδομένων που χρησιμοποιείται για την ανάλυση.

Ένας άλλος πολλά υποσχόμενος τομέας για μελλοντική έρευνα είναι η ανάπτυξη ευφυών συστημάτων κυκλοφορίας σε πραγματικό χρόνο που μπορούν να συλλέγουν και να αναλύουν συνεχώς δεδομένα από διάφορες πηγές, όπως αισθητήρες κυκλοφορίας, GPS και κινητές συσκευές. Αξίζει να σημειωθεί ότι τα συστήματα αυτά θα μπορούσαν να παρέχουν επικαιροποιημένες πληροφορίες σχετικά με τον όγκο της κυκλοφορίας και τη συμφόρηση και θα μπορούσαν να χρησιμοποιηθούν μεταξύ άλλων από τους μετακινούμενους, τους σχεδιαστές μεταφορών και κυκλοφορίας, τις υπηρεσίες αντιμετώπισης εκτάκτων αναγκών και τις εταιρείες, για να λαμβάνουν πιο αποτελεσματικές και τεκμηριωμένες αποφάσεις σχετικά με τη δρομολόγηση, την κατανομή των πόρων και άλλους σημαντικούς παράγοντες. Ως εκ τούτου, η διηλεκτική έρευνα και ανάπτυξη σε αυτόν τον τομέα μπορεί να έχει σημαντικό αντίκτυπο σε ένα ευρύ φάσμα βιομηχανιών και κοινοτήτων.

Συνολικά, η παρούσα διατριβή διερεύνησε την εφαρμογή μοντέλων με βάση τους μετασχηματιστές για τη μονομεταβλητή πρόβλεψη του όγκου κυκλοφορίας. Τα αποτελέσματα κατέδειξαν την ικανότητα των μετασχηματιστών να καταγράφουν τα πρότυπα και τις εξαρτήσεις των κυκλοφοριακών δεδομένων, με αποτέλεσμα να επιτυγχάνεται σημαντική απόδοση τόσο από άποψη ακρίβειας όσο και από άποψη αποδοτικότητας. Ωστόσο, εξακολουθούν να υπάρχουν αρκετοί τομείς για περαιτέρω έρευνα και ανάπτυξη στον τομέα αυτό. Η πολυμεταβλητή πρόβλεψη, η ενσωμάτωση εξωτερικών παραγόντων και τα ΕΣΜ σε πραγματικό χρόνο αποτελούν πολλά υποσχόμενες κατευθύνσεις για τη βελτίωση της πρόβλεψης του όγκου της κυκλοφορίας και της διαχείρισης των μεταφορών. Τελικά, η συνεχής εξέλιξη αυτών των μεθόδων μπορεί να έχει σημαντικές επιπτώσεις στη ροή της κυκλοφορίας, την ασφάλεια και την αποτελεσματικότητα, καθιστώντας τα συστήματα κυκλοφορίας πιο αξιόπιστα και βιώσιμα για τις κοινότητες σε όλο τον κόσμο.




# Παράρτημα Α΄


## Παράρτημα

### Α΄.1 Απώλεια εκπαίδευσης και επικύρωσης


Σε αυτό την Ενότητα, οι απώλειες εκπαίδευσης και επικύρωσης για τους υπόλοιπους σταθμούς διοδίων (ISTT και ISTE) απεικονίζονται στο Σχήμα Α.1




(a) Απώλεια εκπαίδευσης στο ISTE



(b) Απώλεια επικύρωσης στο ISTE



(c) Απώλεια εκπαίδευσης στο ISTT

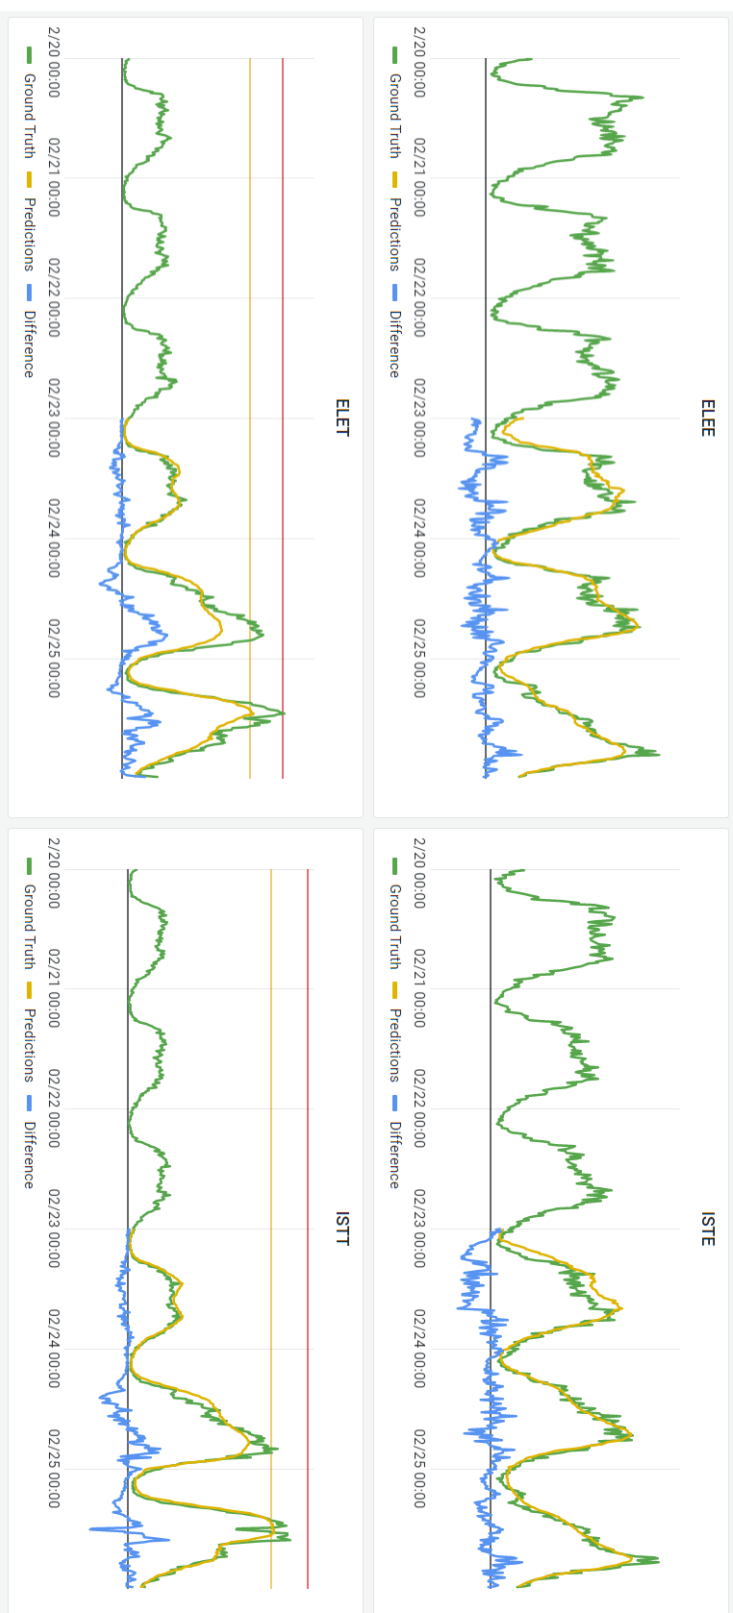


(d) Απώλεια επικύρωσης στο ISTT


Figure A.1: Απώλειες εκπαίδευσης και επικύρωσης για τους σταθμούς διοδίων ΙΣΤΕ και ΙΣΤΤ για κάθε μοντέλο του Πίνακα 7.6

### Α΄.2 Προβλέψεις κυκλοφορίας


Σε αυτή την Ενότητα παρουσιάζονται τα αποτελέσματα της πρόβλεψης της κυκλοφορίας για όλους τους σταθμούς διοδίων για συγκεκριμένες περιόδους διακοπών (Καθαρά Δευτέρα και 25<sup>η</sup> Μαρτίου) στα Σχήματα Α΄.2-Α΄.11.



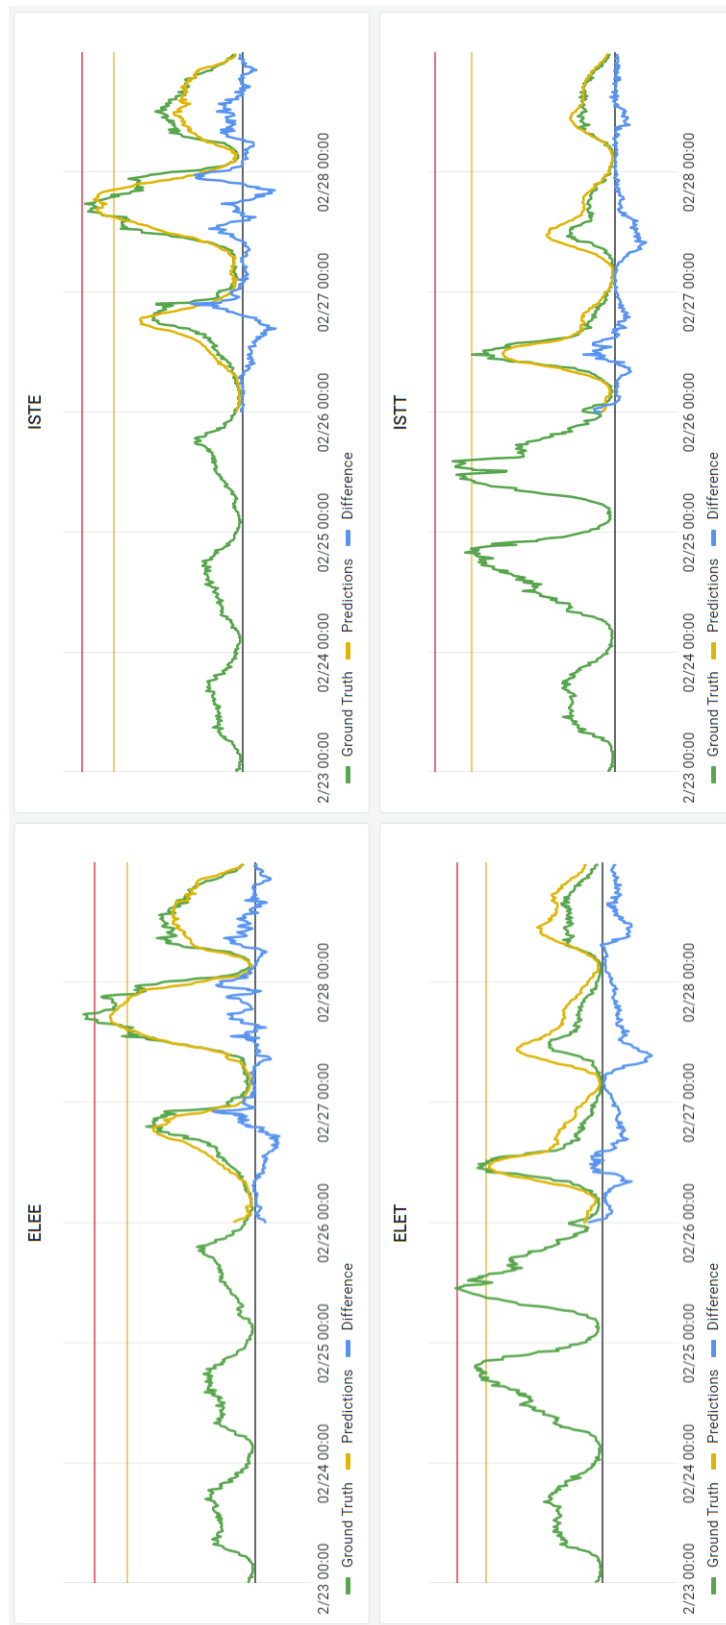
Σχήμα Α'.2: Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διόδων. Το παράθυρο αναδρομής είναι από 20/02/2023 00:00 έως 22/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 23/02/2023 00:00 έως 25/02/2023 00:00.




Σχήμα Α.3: Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 21/02/2023 00:00 έως 23/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 24/02/2023 00:00 έως 26/02/2023 00:00.



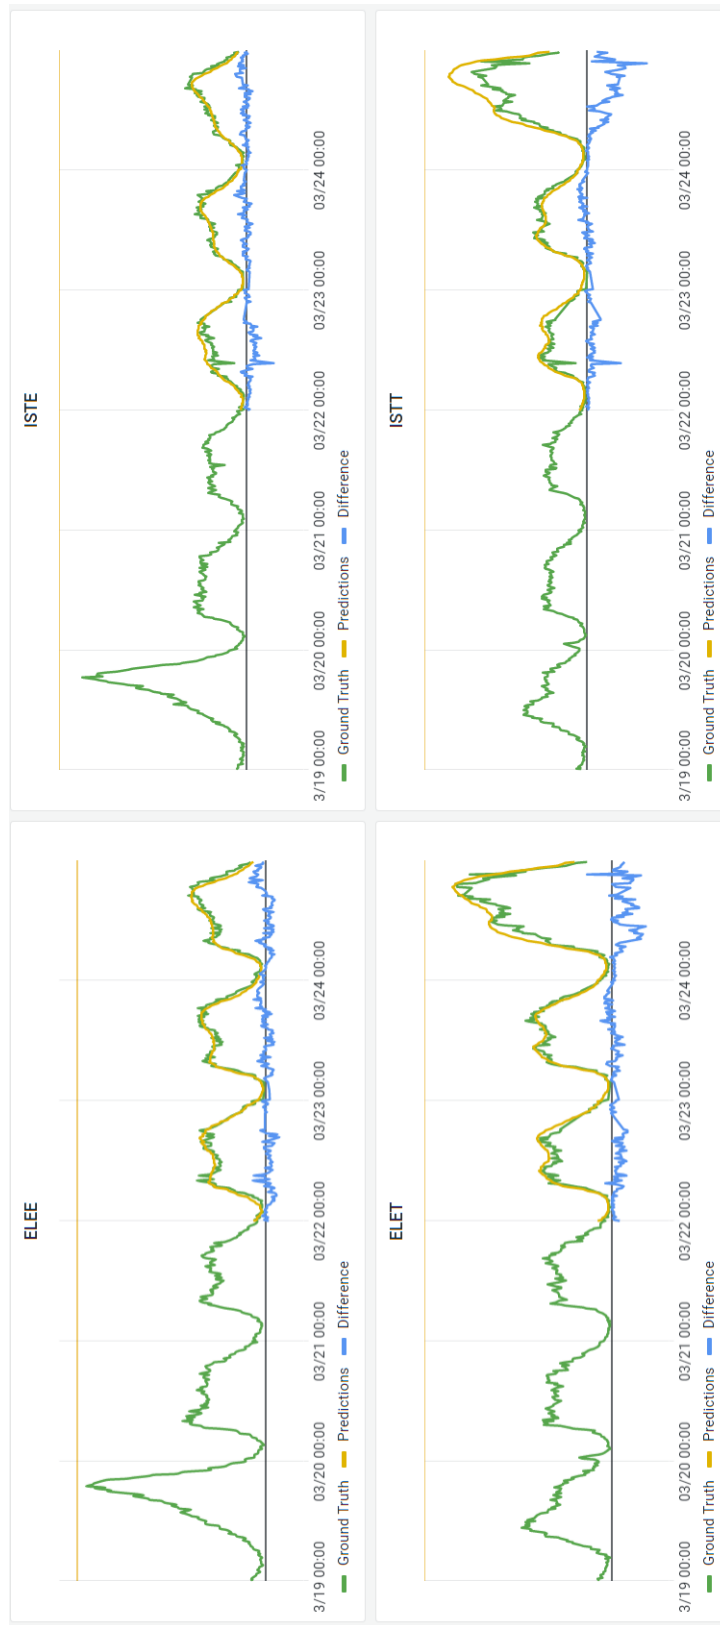
Σχήμα Α'.4: Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διόδων. Το παράθυρο αναδρομής είναι από 22/02/2023 00:00 έως 24/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 25/02/2023 00:00 έως 27/02/2023 00:00.



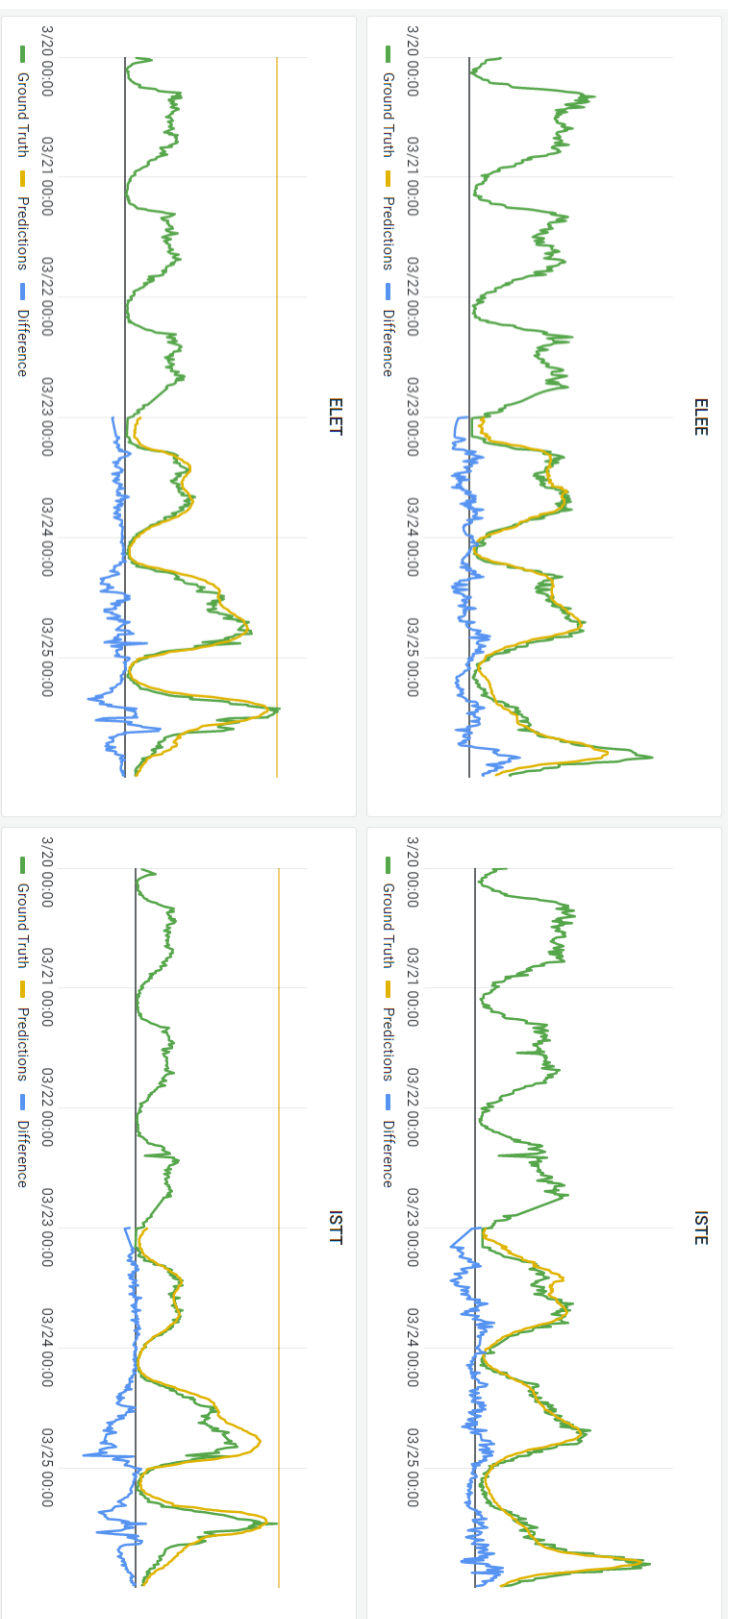
Σχήμα Α.5: Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 23/02/2023 00:00 έως 25/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 26/02/2023 00:00 έως 28/02/2023 00:00.



Σχήμα Α.6: Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διόδων. Το παράθυρο αναδρομής είναι από 24/02/2023 00:00 έως 26/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 27/02/2023 00:00 έως 29/02/2023 00:00.

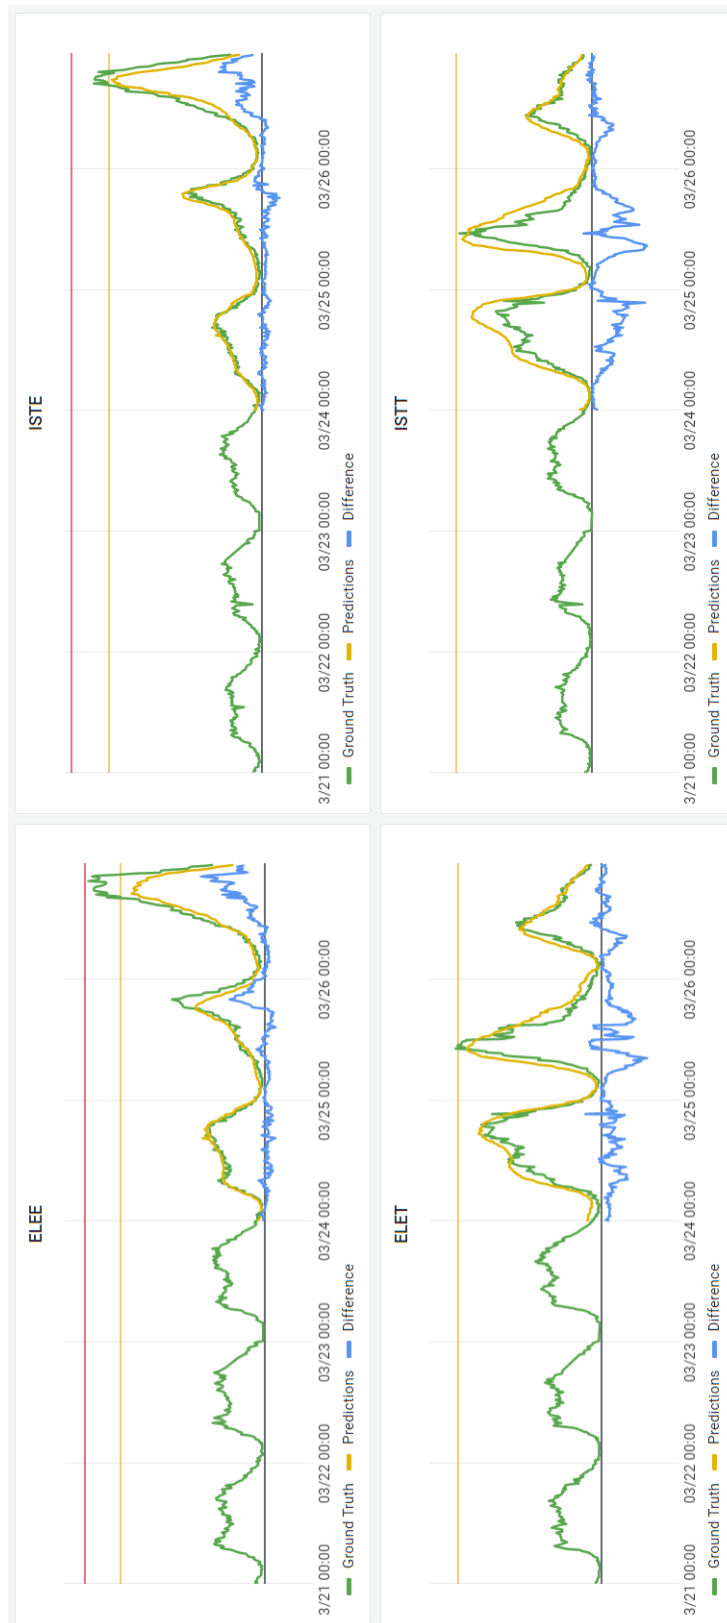


Σχήμα A.7: Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 19/03/2023 00:00 έως 21/03/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 22/03/2023 00:00 έως 24/03/2023 00:00.

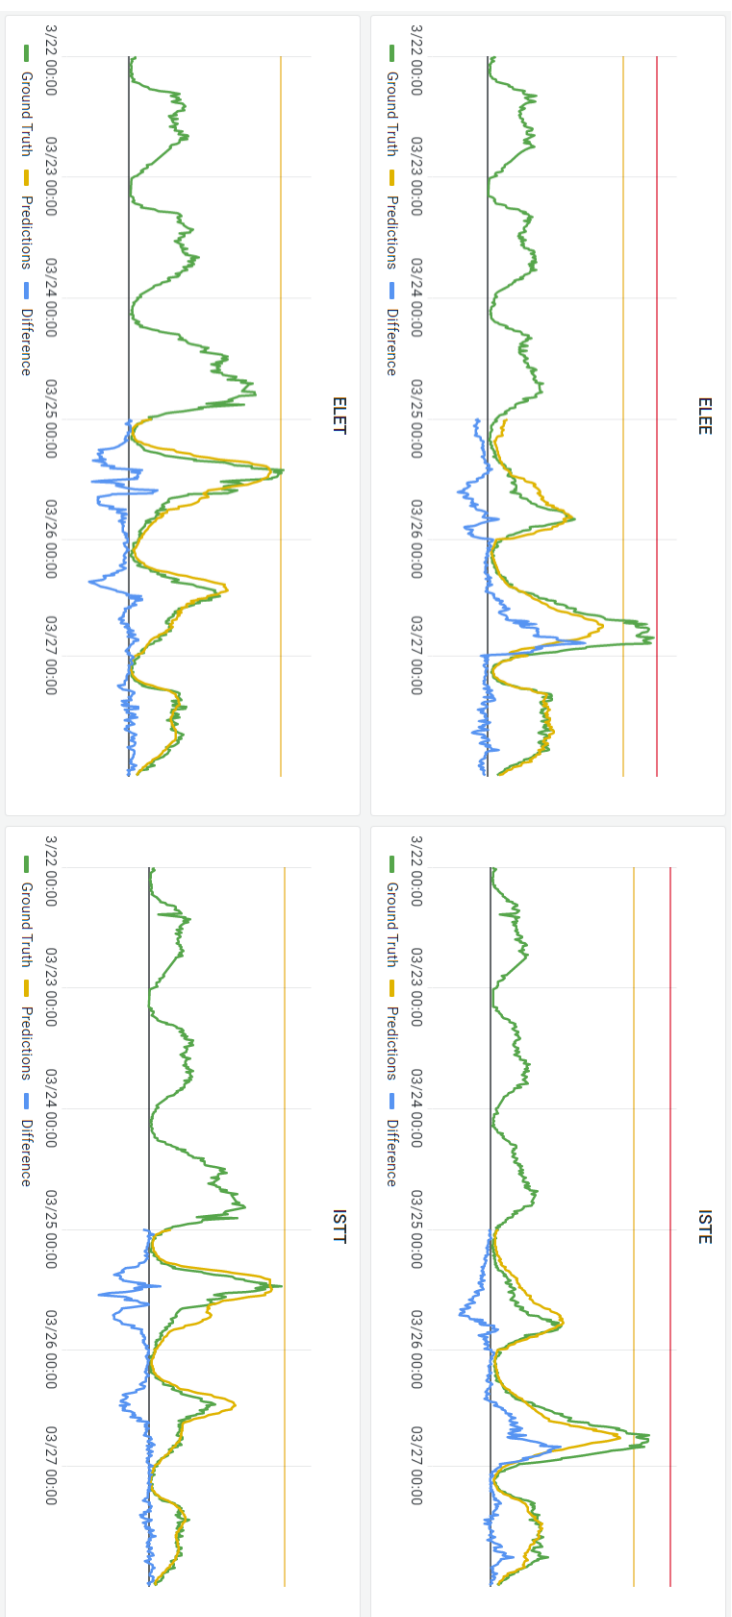


Σχήμα Α'.8: Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διόδων. Το παράθυρο αναφοράς είναι από 20/03/2023 00:00 έως 22/03/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 23/03/2023 00:00 έως 25/03/2023 00:00.






Σχήμα A.9: Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 21/03/2023 00:00 έως 23/03/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 24/03/2023 00:00 έως 26/03/2023 00:00.



Σχήμα Α'.10: Πρόβλεψη των συνδυαστικών μοντέλων για όλους τους σταθμούς διόδων. Το παράθυρο αναδρομής είναι από 22/03/2023 00:00 έως 24/03/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 25/03/2023 00:00 έως 27/03/2023 00:00.



Σχήμα A'11: Προβλέψεις των συνδυαστικών μοντέλων για όλους τους σταθμούς διοδίων. Το παράθυρο αναδρομής είναι από 23/02/2023 00:00 έως 25/02/2023 23:45, και ο ορίζοντας πρόβλεψης είναι από 26/03/2023 00:00 έως 28/03/2023 00:00.



# Βιβλιογραφία

- [1] Md Aftabuzzaman. Measuring traffic congestion- a critical review. *30th Australasian Transport Research Forum*, 2007.
- [2] Abhishek Agrawal, Vikas Kumar, Ashish Pandey και Imran Khan. An application of time series analysis for weather forecasting. 2012.
- [3] Nesreen K. Ahmed, Amir F. Atiya, Neamat El Gayar και Hisham El-Shishiny. An empirical comparison of machine learning models for time series forecasting. *Econometric Reviews*, 29(5-6):594–621, 2010.
- [4] Ethem Alpaydin. *Introduction to Machine Learning*. The MIT Press, 2η έκδοση, 2010.
- [5] Dzmitry Bahdanau, Kyunghyun Cho και Yoshua Bengio. Neural machine translation by jointly learning to align and translate, 2014.
- [6] Asma Belhadi, Youcef Djenouri, Djamel Djenouri και Chun Wei Lin. A recurrent neural network for urban long-term traffic flow forecasting. *Applied Intelligence*, 50, 2020.
- [7] Gedas Bertasius, Heng Wang και Lorenzo Torresani. Is space-time attention all you need for video understanding?, 2021.
- [8] Anastasia Borovykh, Sander Bohte και Cornelis Oosterlee. Dilated convolutional neural networks for time series forecasting. *Journal of Computational Finance*, 2017.
- [9] George.E.P. Box και Gwilym M. Jenkins. *Time Series Analysis: Forecasting and Control*. Holden-Day, 1976.
- [10] D. Brockmann, Lars Hufnagel και Theo Geisel. The scaling laws of human travel. *Nature*, 439:462–5, 2006.
- [11] P.J. Brockwell και R.A. Davis. *Introduction to Time Series and Forecasting*. Springer Texts in Statistics. Springer International Publishing, 2016.
- [12] Tom B. Brown, Benjamin Mann, Nick Ryder, Melanie Subbiah, Jared Kaplan, Prafulla Dhariwal, Arvind Neelakantan, Pranav Shyam, Girish Sastry, Amanda Askell,

- Sandhini Agarwal, Ariel Herbert-Voss, Gretchen Krueger, Tom Henighan, Rewon Child, Aditya Ramesh, Daniel M. Ziegler, Jeffrey Wu, Clemens Winter, Christopher Hesse, Mark Chen, Eric Sigler, Mateusz Litwin, Scott Gray, Benjamin Chess, Jack Clark, Christopher Berner, Sam McCandlish, Alec Radford, Ilya Sutskever και Dario Amodei. Language models are few-shot learners, 2020.
- [13] Lijuan Cao. Support vector machines experts for time series forecasting. *Neurocomputing*, 51:321–339, 2003.
- [14] Nicolas Carion, Francisco Massa, Gabriel Synnaeve, Nicolas Usunier, Alexander Kirillov και Sergey Zagoruyko. End-to-end object detection with transformers, 2020.
- [15] Mainak Chakraborty και Ajit Pratap Kundan. Grafana. Στο *Monitoring Cloud-Native Applications: Lead Agile Operations Confidently Using Open Source Software*, σελίδες 187–240. Springer, 2021.
- [16] N.H. Chan. *Time Series: Applications to Finance with R and S-Plus*. CourseSmart. Wiley, 2011.
- [17] C. Chatfield. *The Analysis of Time Series: An Introduction, Sixth Edition*. Chapman & Hall/CRC Texts in Statistical Science. CRC Press, 2016.
- [18] Zhikai Cheng, Min Seok Pang και Paul A. Pavlou. Mitigating traffic congestion: The role of intelligent transportation systems. *Inf. Syst. Res.*, 31:653–674, 2020.
- [19] Mark Chen, Alec Radford, Rewon Child, Jeffrey Wu, Heewoo Jun, David Luan και Ilya Sutskever. Generative pretraining from pixels. Στο *Proceedings of the 37th International Conference on Machine Learning* Hal Daumé III και Aarti Singh, επιμελητές, τόμος 119 στο *Proceedings of Machine Learning Research*, σελίδες 1691–1703. PMLR, 2020.
- [20] Thao Tsen Chen και Shie Jue Lee. A weighted ls-svm based learning system for time series forecasting. *Information Sciences*, 299, 2015.
- [21] Weiqi Chen, Wenwei Wang, Bingqing Peng, Qingsong Wen, Tian Zhou και Liang Sun. Learning to rotate: Quaternion transformer for complicated periodical time series forecasting. KDD '22, σελίδα 146–156, New York, NY, USA, 2022. Association for Computing Machinery.
- [22] Benoit Chesneau. Unicorn documentation, 2017.
- [23] Zhengping Che, Sanjay Purushotham, Kyunghyun Cho, David Sontag και Yan Liu. Recurrent neural networks for multivariate time series with missing values, 2016.
- [24] Estela Dagum και Silvia Bianconcini. *Seasonal Adjustment Methods and Real Time Trend-Cycle Estimation*. 2016.

- [25] Zihang Dai, Zhilin Yang, Yiming Yang, Jaime Carbonell, Quoc V. Le και Ruslan Salakhutdinov. Transformer-xl: Attentive language models beyond a fixed-length context, 2019.
- [26] Jacob Devlin, Ming Wei Chang, Kenton Lee και Kristina Toutanova. Bert: Pre-training of deep bidirectional transformers for language understanding, 2019.
- [27] Django Software Foundation. Django, χ.χ.
- [28] Alexey Dosovitskiy, Lucas Beyer, Alexander Kolesnikov, Dirk Weissenborn, Xiaohua Zhai, Thomas Unterthiner, Mostafa Dehghani, Matthias Minderer, Georg Heigold, Sylvain Gelly, Jakob Uszkoreit και Neil Houlsby. An image is worth 16x16 words: Transformers for image recognition at scale, 2021.
- [29] Volkan Ş. Ediger και Sertaç Akar. Arima forecasting of primary energy demand by fuel in turkey. *Energy Policy*, 35(3):1701–1708, 2007.
- [30] Peter Fader, Bruce Hardie και Ka Lee. “counting your customers” the easy way: An alternative to the pareto/nbd model. *Marketing Science*, 24:275–284, 2005.
- [31] Everette S. Gardner. Exponential smoothing: The state of the art. *Journal of Forecasting*, 4:1–28, 1985.
- [32] Everette S. Gardner. Exponential smoothing: The state of the art—part ii. *International Journal of Forecasting*, 22(4):637–666, 2006.
- [33] James Gardner. The web server gateway interface (wsgi). *The Definitive Guide to Pylons*, σελίδες 369–388, 2009.
- [34] Daniel Gedon, Niklas Wahlström, Thomas B. Schön και Lennart Ljung. Deep state space models for nonlinear system identification, 2021.
- [35] Jonas Gehring, Michael Auli, David Grangier, Denis Yarats και Yann N. Dauphin. Convolutional sequence to sequence learning, 2017.
- [36] Amir Ghaderi, Borhan M. Sanandaji και Faezeh Ghaderi. Deep forecast: Deep learning-based spatio-temporal forecasting, 2017.
- [37] Bidisha Ghosh, Biswajit Basu και Margaret O’Mahony. Time series modelling for forecasting vehicular traffic flow in dublin. 2005.
- [38] Ian Goodfellow, Yoshua Bengio και Aaron Courville. *Deep Learning*. MIT Press, 2016.
- [39] Jie Hao, Xing Wang, Baosong Yang, Longyue Wang, Jinfeng Zhang και Zhaopeng Tu. Modeling recurrence for transformer, 2019.

- [40] Geoffrey Hinton, Li Deng, Dong Yu, George Dahl, Abdelrahman Mohamed, Navdeep Jaitly, Andrew Senior, Vincent Vanhoucke, Patrick Nguyen, Tara Sainath και Brian Kingsbury. Deep neural networks for acoustic modeling in speech recognition. *Signal Processing Magazine*, 2012.
- [41] Charles Holt. Forecasting seasonals and trends by exponential weighted moving averages. *International Journal of Forecasting*, 20:5–10, 2004.
- [42] Weiwei Jiang και Jiayun Luo. Big data for traffic estimation and prediction: A survey of data and tools. *Applied System Innovation*, 5(1):23, 2022.
- [43] Weiwei Jiang και Lin Zhang. Geospatial data to images: A deep-learning framework for traffic forecasting. *Tsinghua Science and Technology*, 24:52–64, 2019.
- [44] Jonath Jose. Introduction to time series analysis and its applications. 2022.
- [45] Nal Kalchbrenner και Phil Blunsom. Recurrent continuous translation models. Στο *Conference on Empirical Methods in Natural Language Processing*, 2013.
- [46] Salman Khan, Muzammal Naseer, Munawar Hayat, Syed Waqas Zamir, Fahad Shahbaz Khan και Mubarak Shah. Transformers in vision: A survey. *ACM Computing Surveys*, 54(10ς):1–41, 2022.
- [47] Diederik P. Kingma και Jimmy Ba. Adam: A method for stochastic optimization, 2017.
- [48] KPIT. Smart transportation: A key building block for a smart city. online, χ.χ.
- [49] Siddique Latif, Aun Zaidi, Heriberto Cuayahuitl, Fahad Shamshad, Moazzam Shoukat και Junaid Qadir. Transformers in speech processing: A survey, 2023.
- [50] Bryan Lim και Stefan Zohren. Time-series forecasting with deep learning: a survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379(2194):20200209, 2021.
- [51] Tianyang Lin, Yuxin Wang, Xiangyang Liu και Xipeng Qiu. A survey of transformers, 2021.
- [52] Shiyang Li, Xiaoyong Jin, Yao Xuan, Xiyu Zhou, Wenhui Chen, Yu Xiang Wang και Xifeng Yan. Enhancing the locality and breaking the memory bottleneck of transformer on time series forecasting, 2020.
- [53] Shizhan Liu, Hang Yu, Cong Liao, Jianguo Li, Weiyao Lin, Alex X. Liu και Schahram Dustdar. Pyraformer: Low-complexity pyramidal attention for long-range time series modeling and forecasting. OpenReview.net, 2022.



- [54] Jamie Marquez. Time series analysis : James D. Hamilton, 1994, (Princeton University Press, Princeton, NJ), 799 pp., ISBN 0-691-04289-6. *International Journal of Forecasting*, 11(3):494–495, 1995.
- [55] Boris Medina-Salgado, Eddy Sánchez-DelaCruz, Pilar Pozos-Parra και Javier E. Sierra. Urban traffic flow prediction techniques: A review. *Sustainable Computing: Informatics and Systems*, 35:100739, 2022.
- [56] Ross Mistry και Stacia Misner. *Introducing Microsoft SQL Server 2014*. Microsoft Press, 2014.
- [57] Tom M Mitchell. *Machine learning*, τόμος 1. McGraw-hill New York, 1997.
- [58] D.C. Montgomery, C.L. Jennings και M. Kulahci. *Introduction to Time Series Analysis and Forecasting*. Wiley Series in Probability and Statistics. Wiley, 2015.
- [59] Manfred Mudelsee. Trend analysis of climate time series: A review of methods. *Earth-Science Reviews*, 190, 2018.
- [60] Attila M. Nagy και Vilmos Simon. Survey on traffic prediction in smart cities. *Pervasive and Mobile Computing*, 50:148–163, 2018.
- [61] Hongzhan Nie, Guohui Liu, Xiaoman Liu και Yong Wang. Hybrid of arima and svms for short-term load forecasting. *Energy Procedia*, 16:1455–1460, 2012.
- [62] Judith Oginga Martins και Ayyoob Sharifi. *World Cities Report 2022: Envisaging the Future of Cities*. 2022.
- [63] Adam Paszke, Sam Gross, Francisco Massa, Adam Lerer, James Bradbury, Gregory Chanan, Trevor Killeen, Zeming Lin, Natalia Gimelshein, Luca Antiga, Alban Desmaison, Andreas Köpf, Edward Yang, Zach DeVito, Martin Raison, Alykhan Tejani, Sasank Chilamkurthy, Benoit Steiner, Lu Fang, Junjie Bai και Soumith Chintala. Pytorch: An imperative style, high-performance deep learning library, 2019.
- [64] Bob Pishue. 2022 inrix global traffic scorecard, 2023.
- [65] Kashif Qureshi και Hanan Abdullah. A survey on intelligent transportation systems. *Middle-East Journal of Scientific Research*, 15:629–642, 2013.
- [66] Will Reese. Nginx: The high-performance web server and reverse proxy. *Linux J.*, 2008(173), 2008.
- [67] Robert Richards και Robert Richards. Representational state transfer (rest). *Pro PHP XML and web services*, σελίδες 633–672, 2006.
- [68] Ignacio Rojas, Olga Valenzuela, Fernando Ruiz, Alberto Guillén, Luis Herrera, Hector Pomares, Luisa Marquez και Miguel Pasadas. Soft-computing techniques and arma model for time series prediction. *Neurocomputing*, 71:519–537, 2008.

- [69] David E. Rumelhart, Geoffrey E. Hinton και Ronald J. Williams. Learning representations by back-propagating errors. *Nature*, 323:533–536, 1986.
- [70] David Salinas, Valentin Flunkert και Jan Gasthaus. Deepar: Probabilistic forecasting with autoregressive recurrent networks, 2019.
- [71] Rajat Sen, Hsiang Fu Yu και Inderjit S Dhillon. Think globally, act locally: A deep neural network approach to high-dimensional time series forecasting. Στο *Advances in Neural Information Processing Systems* H. Wallach, H. Larochelle, A. Beygelzimer, F.d' Alché-Buc, E. Fox και R. Garnett, επιμελητές, τόμος 32. Curran Associates, Inc., 2019.
- [72] John Shahid. Influxdb documentation, 2019.
- [73] Ismail Shah, Izhar Muhammad, Sajid Ali, Saira Ahmed, Mohammed Almazah και A Al-Rezami. Forecasting day-ahead traffic flow using functional time series approach. 2022.
- [74] Li Shen και Yangzhu Wang. Tcct: Tightly-coupled convolutional transformer on time series forecasting. *Neurocomputing*, 480:131–145, 2022.
- [75] Jimeng Shi, Mahek Jain και Giri Narasimhan. Time series forecasting (tsf) using various deep learning models, 2022.
- [76] Jimeng Shi, Mahek Jain και Giri Narasimhan. Time series forecasting using various deep learning models. *International Journal of Computer and Systems Engineering*, 16(6):224 – 232, 2022.
- [77] R.H. Shumway και D.S. Stoffer. *Time Series Analysis and Its Applications: With R Examples*. Springer Texts in Statistics. Springer International Publishing, 2017.
- [78] Huan Song, Deepta Rajan, Jayaraman J. Thiagarajan και Andreas Spanias. Attend and diagnose: Clinical time series analysis using attention models, 2017.
- [79] Ilya Sutskever, Oriol Vinyals και Quoc V. Le. Sequence to sequence learning with neural networks. Στο *Proceedings of the 27th International Conference on Neural Information Processing Systems - Volume 2*, NIPS'14, σελίδα 3104–3112, Cambridge, MA, USA, 2014. MIT Press.
- [80] M. Swarnamugi και R. Chinnaiyan. Iot hybrid computing model for intelligent transportation system (its). Στο *2018 Second International Conference on Computing Methodologies and Communication (ICCMC)*, σελίδες 802–806, 2018.
- [81] Amine Tadjer, Aojie Hong και Reidar B Bratvold. Machine learning based decline curve analysis for short-term oil production forecast. *Energy Exploration & Exploitation*, 39(5):1747–1769, 2021.

- [82] Souhaib Ben Taieb. Machine learning strategies for multi-step-ahead time series forecasting, 2014.
- [83] Ruey Tay και Rong Chen. Nonlinear time series analysis. *Nonlinear Time Series Analysis*, 2018.
- [84] Traianos Ioannis Theodorou, Athanasios Salamanis, Dionysios Kehagias, Dimitrios Tzovaras και Christos Tjortjis. Short-term traffic prediction under both typical and atypical traffic conditions using a pattern transition model. σελίδες 79–89, 2017.
- [85] Eric Topol. High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25, 2019.
- [86] R.S. Tsay και R. Chen. *Nonlinear Time Series Analysis*. Wiley Series in Probability and Statistics. Wiley, 2018.
- [87] Nicola Uras, Lodovica Marchesi, Michele Marchesi και Roberto Tonelli. Forecasting bitcoin closing price series using linear regression and neural networks models. 2020.
- [88] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser και Illia Polosukhin. Attention is all you need, 2017.
- [89] David C Vogelsang και Bradley J Erickson. Magician’s corner: 6. tensorflow and tensorboard, 2020.
- [90] Renzhuo Wan, Chengde Tian, Wei Zhang, Wendi Deng και Fan Yang. A multivariate temporal convolutional attention network for time-series forecasting. *Electronics*, 11:1516, 2022.
- [91] W.W.S. Wei. *Time Series Analysis: Univariate and Multivariate Methods*. Time Series Analysis: Univariate and Multivariate Methods. Pearson Addison Wesley, 2006.
- [92] Qingsong Wen, Tian Zhou, Chaoli Zhang, Weiqi Chen, Ziqing Ma, Junchi Yan και Liang Sun. Transformers in time series: A survey, 2023.
- [93] Michael Widenius και David Axmark. *MySQL reference manual: documentation from the source.* ” O’Reilly Media, Inc.”, 2002.
- [94] Daniel S. Wilks. *Statistical methods in the atmospheric sciences*. Elsevier Academic Press, Amsterdam; Boston, 2011.
- [95] Granville Tunnicliffe Wilson. Time Series Analysis: Forecasting and Control, 5th Edition , by George E. P. Box , Gwilym M. Jenkins , Gregory C. Reinsel and Greta M. Ljung , 2015 . Published by John Wiley and Sons Inc. , Hoboken, N. *Journal of Time Series Analysis*, 37(5):709–711, 2016.

- 
- [96] Gerald Woo, Chenghao Liu, Doyen Sahoo, Akshat Kumar και Steven Hoi. Etsformer: Exponential smoothing transformers for time-series forecasting, 2022.
- [97] Haixu Wu, Jiehui Xu, Jianmin Wang και Mingsheng Long. Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting, 2022.
- [98] Haitao Yuan και Guoliang Li. A survey of traffic prediction: from spatio-temporal data to intelligent transportation. *Data Science and Engineering*, 6, 2021.
- [99] Abdelhafid Zeroual, Fouzi Harrou και Ying Sun. Road traffic density estimation and congestion detection with a hybrid observer-based strategy. *Sustainable Cities and Society*, 46:101411, 2019.
- [100] G.Peter Zhang. Time series forecasting using a hybrid arima and neural network model. *Neurocomputing*, 50:159–175, 2003.
- [101] L. Zhang. Time series analysis of indoor millimetre wave distributed antenna systems, 2021.
- [102] Weibin Zhang, Yong Qi, Ying Yan, Jinjun Tang και Yinhai Wang. A method of emission and traveller behavior analysis under multimodal traffic condition. *Transportation Research Part D: Transport and Environment*, 52:139–155, 2017.
- [103] Yuanchang Zhong, Lili Sun και Chenhao Ge. Key technologies and development status of smart city. *Journal of Physics: Conference Series*, 1754:012102, 2021.
- [104] Haoyi Zhou, Shanghang Zhang, Jieqi Peng, Shuai Zhang, Jianxin Li, Hui Xiong και Wancai Zhang. Informer: Beyond efficient transformer for long sequence time-series forecasting, 2021.
- [105] Tian Zhou, Ziqing Ma, Qingsong Wen, Xue Wang, Liang Sun και Rong Jin. Fedformer: Frequency enhanced decomposed transformer for long-term series forecasting, 2022.

# Συντομεύσεις - Αρκτικόλεξα

ΑΝΔ	Αναδρομικά Νευρωνικά Δίκτυα
ΒΝΔ	Βαθιά Νευρωνικά Δίκτυα
ΕΕ	Εκθετική Εξομάλυνση
ΕΣΜ	Ευφυή Συστήματα Μεταφορών
ΗΣΔ	Ηλεκτρονικής Συλλογή Διοδίων
ΜΔΥ	Μηχανές Διανυσμάτων Υποστήριξης
ΠΤ	Πρόσθια Τροφοδότηση
ΣΑΟ	Σύστημα Ανίχνευσης Οχημάτων
ΣΔΑ	Σύστημα Διαχείρισης Αυτοκινητόδρομων
ΣΔΔ	Σύστημα Διαχείρισης Διαμετακόμισης
ΣΔΠ	Σύστημα Διαχείρισης Πληροφοριών
ΣΝΔ	Συνελικτικά Νευρωνικά Δίκτυα
ΤΝΔ	Τεχνητά Νευρωνικά Δίκτυα
ΧΣΔ	Χειροκίνητη Συλλογή Διοδίων
AR	Autoregressive Model
ARCH	Autoregressive Conditional Heteroskedasticity
ARIMA	Autoregressive Integrated Moving Average
ARMA	Autoregressive Moving Average
DRF	Django REST Framework
ESA	Exponential Smoothing Attention
ETL	Extract, Transform and Load
ETS	Error Trend Seasonality Model
FA	Frequency Attention
IoT	Internet of Things
LSTM	Long Short-term Memory
MA	Moving Average
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MSE	Mean Square Error
MSPE	Mean Square Percentage Error
PE	Positional Encoding
QKV	Query-Key-Value

RMSE	Root Mean Square Error
REST	REpresentational State Transfer
WSGI	Web Server Gateway Interface

