

Διδακτορική Διατριβή

Αξιόπιστη Βραχυπρόθεσμη Πρόβλεψη Κυκλοφορίας σε Αστικά Δίκτυα με Χωροχρονικά και Πολυτροπικά Μοντέλα Βαθιάς Μάθησης Εμπνευσμένα από τη Θεωρία της Κυκλοφοριακής Ροής

Παναγιώτης Φαφουτέλλης

Εκτενής Περίληψη

Εισαγωγή

Η άνοδος των δεικτών ιδιοκτησίας οχημάτων και, γενικότερα, της ζήτησης για μεταφορές τις τελευταίες δεκαετίες, ως αποτέλεσμα της αύξησης του πληθυσμού και της αστικοποίησης, έχει εντείνει σε σημαντικό βαθμό την πίεση που ασκείται στα αστικά συστήματα μεταφορών. Ως αποτέλεσμα των παραπάνω, η συχνότητα εμφάνισης, καθώς και η ένταση, φαινομένων κυκλοφοριακής συμφόρησης έχει αυξηθεί, με σημαντικές άμεσες και έμμεσες συνέπειες στην υγεία των πολιτών, την οικονομία, την οδική ασφάλεια και το περιβάλλον. Σε αυτό το πλαίσιο, η άμβλυνση των φαινομένων συμφόρησης έχει καταστεί μία απαιτητική και πολύπλοκη αποστολή. Τα τελευταία 20 χρόνια, η ανάπτυξη έξυπνων συστημάτων μεταφορών (Intelligent Transportation Systems – ITS) έχει αναδειχθεί ως το πιο αποτελεσματικό εργαλείο προς αυτή την κατεύθυνση. Η δε πρόοδος της Τεχνητής Νοημοσύνης, των υπολογιστικών συστημάτων και των τηλεπικοινωνιών προσφέρει νέες προοπτικές στην αποδοτική διαχείριση της κυκλοφορίας.

Η ακριβής βραχυπρόθεσμη πρόβλεψη της κυκλοφορίας θεωρείται καθοριστική για την αποτελεσματική εφαρμογή των ITS, δεδομένου ότι επιτρέπει την έγκαιρη αντίδραση στις αναμενόμενες συνθήκες κυκλοφορίας, όπως η εφαρμογή κατάλληλων στρατηγικών αποτροπής της εμφάνισης κυκλοφοριακής συμφόρησης. Η αυξημένη ζήτηση για ακριβείς προβλέψεις σε συστήματα διαχείρισης κυκλοφορίας έχει αυξήσει το ενδιαφέρον στην ερευνητική περιοχή της πρόβλεψης των κυκλοφοριακών συνθηκών. Μάλιστα, η άνευ προηγουμένου διαθεσιμότητα κυκλοφοριακών δεδομένων, ως αποτέλεσμα της ραγδαίας ανάπτυξης της τεχνολογίας και των τηλεπικοινωνιών στις μέρες μας, έστρεψε την προσοχή των ερευνητών προς μεθόδους οδηγούμενες από τα δεδομένα και, κυρίως, την Βαθιά Μηχανική Μάθηση (Deep Learning). Τα μοντέλα πρόβλεψης που ανήκουν σε αυτή την κατηγορία θεωρούνται ως αυτά με την μεγαλύτερη ακρίβεια καθώς μπορούν να προσομοιώσουν με ακρίβεια οποιαδήποτε μαθηματική σχέση, ανεξαρτήτως της πολυπλοκότητάς της, όπως οι χωροχρονικές συσχετίσεις μεταξύ των κυκλοφοριακών συνθηκών των θέσεων ενός οδικού δικτύου και μάλιστα χωρίς να απαιτείται ιδιαίτερη προσπάθεια από τον χρήστη.

Από την άλλη μεριά, τα συγκεκριμένα μοντέλα απαιτούν μεγάλο όγκο δεδομένων και αυξημένη υπολογιστική ισχύ για να εκπαιδευτούν αποτελεσματικά, ενώ είναι δυσχερές η κατανόηση του μηχανισμού των προβλέψεων και η ερμηνεία των αποτελεσμάτων τους, γεγονός που μειώνει την αξιοπιστία και τη διαφάνειά τους. Οι παραπάνω λόγοι περιορίζουν σε μεγάλο βαθμό τη χρησιμοποίηση αυτών των μοντέλων για τους σκοπούς της διαχείρισης κυκλοφορίας σε πραγματικές συνθήκες, η οποία παραμένει αντιστρόφως ανάλογη του μεγάλου ερευνητικού ενδιαφέροντος και του όγκου των δημοσιεύσεων στην συγκεκριμένη ερευνητική περιοχή. Προκύπτει συνεπώς η ανάγκη για επαναπροσδιορισμό των κριτηρίων αξιολόγησης των μοντέλων πρόβλεψης, βάζοντας σε κεντρικό ρόλο όχι μόνο την ακρίβεια των προβλέψεων αλλά και την αξιοπιστία, την αιτιότητα, την επεξηγησιμότητα και την αποδοτικότητα, ο συνδυασμός των οποίων καθορίζει την εφαρμοσιμότητα ενός μοντέλου.

Στόχοι

Ο κύριος στόχος της παρούσας διατριβής είναι η ανάπτυξη ενός εφαρμόσιμου πλαισίου πρόβλεψης της κυκλοφορίας πολλαπλών χρονικών και χωρικών κλιμάκων για την προγνωστική διαχείριση της κυκλοφορίας, το οποίο εκπαιδεύεται σε πολυτροπικά περιβάλλοντα (λαμβάνοντας υπόψη περισσότερα του ενός μέσα μετακίνησης), αξιοποιώντας αιτιώδεις χωροχρονικές σχέσεις και πτυχές της θεωρίας της Κυκλοφοριακής Ροής.

Για τον σκοπό αυτό, προτείνεται μια εργαλειοθήκη λειτουργικών μονάδων, καθεμία από τις οποίες μπορεί να αξιοποιηθεί από τις αρχές διαχείρισης της κυκλοφορίας υπό διαφορετικές συνθήκες για την πραγματοποίηση πολλαπλών εργασιών πρόβλεψης από διαφορετικές οπτικές γωνίες, π.χ. πρόβλεψη πολλαπλών μεταβλητών εξόδου, πολυτροπικών ή μεμονωμένων εργασιών, πρόβλεψη σε όλο το δίκτυο ή σημειακά και βραχυπρόθεσμες ή μακροπρόθεσμες προβλέψεις (με χρήση δεδομένων υψηλής ή χαμηλής ανάλυσης, αντίστοιχα).

Προς την κατεύθυνση αυτή, η διατριβή θέτει τους παρακάτω επιμέρους στόχους:

1. Προσδιορισμός χωρικών συσχετίσεων στα οδικά δίκτυα, με τη χρήση σύγχρονων μεθόδων από την εφαρμοσμένη στατιστική και τη θεωρία της πληροφορίας, και αξιολόγηση της επίδρασής τους στην ακρίβεια της πρόβλεψης.
2. Διερεύνηση πιθανών σημαντικών αλληλεπιδράσεων μεταξύ των συνθηκών οδικής κυκλοφορίας και της ζήτησης για άλλους τρόπους μετακίνησης και αξιοποίησή τους για την παραγωγή πολυτροπικών προβλέψεων.
3. Αξιοποίηση μιας εύστοχης και ουσιαστικής αναπαράστασης του οδικού δικτύου για την αποτελεσματική μοντελοποίηση, τόσο των χωρικών, όσο και των χρονικών σχέσεων του συστήματος μεταφορών (ζήτηση για διαφορετικά μέσα).
4. Ανίχνευση σημαντικών αιτιωδών σχέσεων μεταξύ των κυκλοφοριακών συνθηκών σε διάφορες θέσεις του οδικού δικτύου και των κυκλοφοριακών μοτίβων που αναδεικνύουν σε επίπεδο πόλης, τόσο βραχυπρόθεσμα όσο και μακροπρόθεσμα.
5. Διερεύνηση της επίδρασης των αιτιωδών σχέσεων στην ενίσχυση της προβλεψιμότητας των κυκλοφοριακών συνθηκών σε επίπεδο δικτύου, καθώς και την αξιοπιστία των προβλέψεων.
6. Εισαγωγή στοιχείων από τη θεωρία της Κυκλοφοριακής Ροής στο στάδιο εκπαίδευσης του μοντέλου με την ανάπτυξη μιας συνάρτησης απωλειών συμβατής με τη φύση της κυκλοφοριακής ροής και της εξέλιξής της σε χώρο και χρόνο. Διερεύνηση της επίδρασής της στην απόδοση και την αξιοπιστία του πλαισίου πρόβλεψης.

7. Αξιολόγηση της επίδρασης της προσέγγισης που καθοδηγείται από τη θεωρία όσον αφορά στη δυνατότητα αξιοποίησης του πλαισίου σε πραγματικές συνθήκες (απόδοση, αποδοτικότητα και αξιοπιστία).

Προκλήσεις για την ανάπτυξη εφαρμόσιμων μοντέλων

Σε αυτή την ενότητα, παρουσιάζονται οι σημαντικότερες προκλήσεις που σχετίζονται με τη δυνατότητα αξιοποίησης μοντέλων Βαθιάς Μάθησης στην προγνωστική διαχείριση της κυκλοφορίας, σύμφωνα με την πρόσφατη βιβλιογραφία, καθώς και τα ερευνητικά ερωτήματα στα οποία επιχειρεί να απαντήσει η παρούσα διατριβή.

Πρόκληση 1: Περιορισμοί της Βαθιάς Μάθησης

Παρά την αδιαμφισβήτητη αποτελεσματικότητα της Βαθιάς Μάθησης στην ακριβή πρόβλεψη των μελλοντικών συνθηκών, υπάρχουν ορισμένα εμπόδια για την εφαρμογή των σχετικών μοντέλων σε πραγματικές συνθήκες:

- Απαίτηση μεγάλου όγκου δεδομένων, με επαρκή γεωγραφική κάλυψη του οδικού δικτύου, καθώς και αντιπροσωπευτικότητας των δεδομένων αυτών.
- Χρονοβόρα διαδικασία εκπαίδευσης καθώς και βαθμονόμησης της δομής και των υπερπαραμέτρων των μοντέλων.
- Απαιτείται υψηλή υπολογιστική ισχύς για την εκπαίδευση και συντήρηση του μοντέλου, καθώς και για την αποθήκευση και χρήση των αντίστοιχων βάσεων δεδομένων.
- Χαμηλή δυνατότητα ερμηνείας των αποτελεσμάτων, η οποία είναι απαραίτητη προκειμένου να δικαιολογηθεί η διαδικασία λήψης αποφάσεων και να αυξηθεί η αξιοπιστία του συγκεκριμένου μοντέλου.
- Περιορισμένη δυνατότητα μεταφοράς και γενίκευσης των μοντέλων σε άλλα δίκτυα ή σε άλλα σημεία του ίδιου δικτύου.

Πρόκληση 2: Αναπαράσταση του οδικού δικτύου και των δεδομένων εισόδου

Η εύστοχη αναπαράσταση του οδικού δικτύου και των χωροχρονικών συσχετίσεων μεταξύ των περιοχών του δύναται να ενισχύσει την απόδοση του μοντέλου, καθώς και την ευχέρεια ερμηνείας του. Επίσης, σε αντίθεση με την πιο συνηθισμένη πρακτική της βιβλιογραφίας, όπου το μοντέλο τροφοδοτείται με όλες τις διαθέσιμες ακατέργαστες πληροφορίες χωρίς καμία προηγούμενη ανάλυση ή επιλογή των πιο σχετικών χαρακτηριστικών, η ακριβής αναπαράσταση των συσχετίσεων μεταξύ των δεδομένων εισόδου μειώνει την πολυπλοκότητα και τη διαστατικότητα του χώρου εισόδου του μοντέλου. Οι πιο διαδεδομένες αναπαραστάσεις είναι οι εξής:

- Στοιβα διανυσμάτων (Stacked Vector): Οι χρονοσειρές των κυκλοφοριακών μετρήσεων από τις διάφορες περιοχές του δικτύου (που μπορούν να θεωρηθούν ως διανύσματα) στοιβάζονται σε ένα διάνυσμα διανυσμάτων. Αυτή είναι η πιο απλή μέθοδος αναπαράστασης, ωστόσο είναι κατάλληλη, κατά κύριο λόγο, για απλά οδικά δίκτυα με λίγες θέσεις μέτρησης.
- Εικόνα ή πλέγμα (Image or Grid): Ορίζεται ένα τετραγωνικό πλέγμα με το μέγεθος του οδικού δικτύου και σε κάθε εικονοστοιχείο (πίξελ) του πλέγματος αποδίδεται μια τιμή που αντιπροσωπεύει τις συνθήκες κυκλοφορίας στο εσωτερικό του, το οποίο είναι ακριβώς ανάλογη με μια εικόνα σε κλίμακα του γκρι. Το μειονέκτημα αυτής της μεθόδου είναι ότι, συνήθως, το οδικό δίκτυο καλύπτει ένα μικρό μέρος του πλέγματος, αφήνοντας κενά τα

περισσότερα εικονοστοιχεία. Συνεπώς, το μοντέλο τροφοδοτείται με έναν σχετικά μεγάλο χώρο εισόδου, ο οποίος όμως περιέχει περιορισμένη πληροφορία.

- **Γράφος:** Οι γράφοι μπορούν να χρησιμοποιηθούν για να εκφράσουν πιο σύνθετες σχέσεις μεταξύ των δεδομένων εισόδου από διαφορετικές θέσεις του οδικού δικτύου, οι οποίες απορρέουν από τη συνδεσιμότητα των τμημάτων του οδικού δικτύου, την επίδραση των διασταυρώσεων και των φωτεινών σηματοδοτών και τα μοτίβα κυκλοφορίας/συμμόρφησης μεταξύ μη-γειτονικών θέσεων. Αυτού του είδους οι συσχετίσεις εκφράζονται μέσω της συνδεσιμότητας των κόμβων του γράφου και ενός συντελεστή βαρύτητας που αντιστοιχεί σε κάθε σύνδεση. Υπάρχουν τρεις βασικοί τύποι συντελεστών βαρύτητας: αυτοί που εκφράζουν την πραγματική (γεωγραφική) συνδεσιμότητα των κόμβων, αυτοί που είναι ανάλογοι της απόστασης των κόμβων και αυτοί που εκφράζουν την ύπαρξη στατιστικής συσχέτισης μεταξύ των κυκλοφοριακών συνθηκών των αντίστοιχων κόμβων.

Πρόκληση 3: Συσχέτιση και Αιτιότητα

Στον επιστημονικό κλάδο της πρόβλεψης της κυκλοφορίας, παρά το γεγονός ότι οι περισσότεροι ερευνητές συμφωνούν σχετικά με την ύπαρξη σημαντικών αιτιωδών σχέσεων μεταξύ διαφορετικών θέσεων ενός οδικού δικτύου, συνήθως βασίζονται σε μοντέλα βαθιάς μάθησης για εντοπισμό συσχετίσεων μεταξύ του μεγάλου όγκου των δεδομένων εισόδου. Ωστόσο, οι συγκεκριμένες συσχετίσεις δεν είναι συνήθως διαφανείς και κατανοητές για τους χρήστες, ενώ δεν είναι εγγυημένο ότι είναι αιτιώδεις. Κατά τη μοντελοποίηση οποιουδήποτε φαινομένου, οι αιτιώδεις σχέσεις μεταξύ των μεταβλητών εισόδου και εξόδου παίζουν πολύ σημαντικό ρόλο. Σε αντίθεση με τη στατιστική συσχέτιση που μπορεί να παρατηρηθεί σε ένα συγκεκριμένο σύνολο δεδομένων, η έννοια της αιτιότητας αναφέρεται σε πιο σημαντικές σχέσεις μεταξύ των μεταβλητών, με την έννοια ότι, π.χ., η τιμή μιας ή περισσότερων μεταβλητών εισόδου θα "προκαλέσει" την έξοδο να λάβει μια συγκεκριμένη τιμή. Πιο συγκεκριμένα, η μελέτη των αιτιωδών σχέσεων είναι πολύ σημαντική για τρεις βασικούς λόγους:

- Χρήση μεταβλητών εισόδου που σχετίζονται αιτιωδώς με το αναμενόμενο αποτέλεσμα και των οποίων ο αντίκτυπος σε αυτό παραμένει σταθερός και είναι ανεξάρτητος από τις μεταβολές των τιμών των μεταβλητών.
- Συνήθως, ο χώρος εισόδου περιλαμβάνει τόσο αιτιώδεις όσο και μη αιτιώδεις μεταβλητές και, κατά τη χρήση τεχνικών επεξήγησης των αποτελεσμάτων, δεν μπορούν να διαχωριστούν, γεγονός που οδηγεί σε αναξιόπιστες επεξηγήσεις.
- Όταν χρησιμοποιούνται τόσο αιτιώδη όσο και μη αιτιώδη χαρακτηριστικά στην πρόβλεψη, η διαστατικότητα του χώρου εισόδου αυξάνεται σημαντικά, υπονομεύοντας την απόδοση του μοντέλου, ενώ η χρήση μόνο αιτιωδών χαρακτηριστικών θα ήταν επαρκής.

Όταν πρόκειται για δεδομένα χρονοσειρών, η πιο κατάλληλη και δημοφιλής μέθοδος για την ανίχνευση αιτιωδών σχέσεων είναι ο έλεγχος αιτιότητας κατά Granger. Με απλά λόγια, λέμε ότι μια χρονοσειρά "x" προκαλεί κατά Granger τη χρονοσειρά "y", όταν η "y" προβλέπεται με μεγαλύτερη ακρίβεια από ένα μοντέλο, εάν προηγούμενες τιμές της "x" περιλαμβάνονται στο χώρο εισόδου. Στην κλασική αιτιότητα κατά Granger, το μοντέλο που χρησιμοποιείται για την αξιολόγηση της ύπαρξης αιτιωδών σχέσεων είναι το Διανυσματικό Αυτοπαλινδρόμο μοντέλο (Vector Autoregressive - VAR). Γίνεται δηλαδή η παραδοχή ότι υπάρχουν μόνο γραμμικές σχέσεις μεταξύ των δεδομένων, κάτι που μπορεί να είναι υπεραπλουστευμένο για συστήματα του πραγματικού κόσμου, π.χ. για δεδομένα κυκλοφορίας

Το σημαντικότερο πλεονέκτημα της αιτιότητας Granger, ωστόσο, είναι ότι πρόκειται για μια πολυμεταβλητή μέθοδο, δηλαδή αξιολογεί την ύπαρξη αιτιώδους σχέσης μεταξύ δύο μεταβλητών λαμβάνοντας υπόψη και την επίδραση όλων των άλλων μεταβλητών εισόδου, σε αντίθεση με τις περισσότερες άλλες μεθόδους που εξετάζουν μόνο τις σχέσεις ανά ζεύγη. Σύμφωνα με το πρότυπο VAR, η μεταβλητή εξόδου y_t είναι ένας γραμμικός συνδυασμός των προηγούμενων χρονικών βημάτων των μεταβλητών εισόδου $x_{i,t-l}$:

$$y_t = \sum_{l=1}^T a_{1,l}x_{1,t-l} + \sum_{l=1}^T a_{2,l}x_{2,t-l} + \dots + \sum_{l=1}^T a_{n,l}x_{n,t-l} \quad (I)$$

όπου T είναι ο μέγιστος αριθμός χρονικών υστερήσεων που λαμβάνονται υπόψη, n είναι ο συνολικός αριθμός των χρονοσειρών εισόδου και $a_{i,l}$ είναι ο συντελεστής της i -οστής χρονοσειράς που σχετίζεται με το χρονικό βήμα $t-l$. Οι τιμές των συντελεστών προσδιορίζονται έτσι ώστε να ελαχιστοποιείται η ακόλουθη ποσότητα:

$$\frac{1}{N} \left(\sum_{t=1}^N y_t - \sum_{i=1}^n \sum_{l=1}^T a_{i,l}x_{i,t-l} \right) + \lambda \sum_{i=1}^n \sum_{l=1}^T |a_{i,l}| \quad (II)$$

όπου N είναι ο συνολικός αριθμός των παρατηρήσεων.

Πρόκληση 4: Επεξηγησιμότητα και χωροχρονική ανάλυση

Η ερμηνευσιμότητα ή επεξηγησιμότητα αναφέρονται στη διαφάνεια ενός μοντέλου, η οποία συνεπάγεται ότι τα δεδομένα ή ο αλγόριθμος και ο μηχανισμός που παρέχει τις προβλέψεις είναι προσβάσιμα σε κάποιο βαθμό από τον χρήστη, χωρίς να απαιτείται πλήρης κατανόηση της δομής του μοντέλου και του μαθηματικού του υποβάθρου από την πλευρά του.

Η επεξηγησιμότητα και ο εντοπισμός των χωρικών και χρονικών σχέσεων μεταξύ των θέσεων του οδικού δικτύου, με σαφήνεια και διαφάνεια, είναι πολύ σημαντικές για τους σκοπούς της διαχείρισης της κυκλοφορίας, προκειμένου:

- Να δικαιολογείται η διαδικασία λήψης αποφάσεων και να αυξάνεται η εμπιστοσύνη στο συγκεκριμένο μοντέλο, πράγμα απαραίτητο για τη συμμόρφωση των χρηστών του δικτύου.
- Να εξαχθεί νέα επιστημονική γνώση σχετικά με τη μηχανική του δικτύου.
- Να βελτιωθεί η απόδοση του μοντέλου πρόβλεψης και η μεταφερσιμότητά του.

Η εξαγωγή των χωροχρονικών σχέσεων και η ερμηνεία των αποτελεσμάτων των μοντέλων Βαθιάς Μάθησης γίνεται με μεθόδους οι οποίες δεν έχουν ισχυρό μαθηματικό υπόβαθρο και εξαρτώνται εξ ολοκλήρου από τα διαθέσιμα δεδομένα - κατά συνέπεια, είναι πολύ ευάλωτες σε θορυβώδη σύνολα δεδομένων και ενδέχεται να παρέχουν αναξιόπιστα αποτελέσματα. Επιπλέον, υποδηλώνουν μόνο στατιστικές και όχι αιτιώδεις σχέσεις. Για την αντιμετώπιση αυτού του ζητήματος, οι ερευνητές θα πρέπει να λάβουν υπόψη τους αφενός τη γνώση που προέρχεται από τη θεωρία της Κυκλοφοριακής Ροής σχετικά με τη χωροχρονική διάδοση και των δυναμικών της κυκλοφορίας και της συμφόρησης και αφετέρου μεθόδους για την εξέταση και την ποσοτικοποίηση των αιτιωδών σχέσεων στα διαθέσιμα δεδομένα.

Πρόκληση 5: Μάθηση πολλαπλών διεργασιών: Η ανάγκη για πολυμεταβλητές προβλέψεις

Η έννοια των μοντέλων πολλαπλών διεργασιών ή πολυμεταβλητών προβλέψεων αναφέρεται στην ανάπτυξη ενός μοντέλου που μπορεί να προβλέψει περισσότερα του ενός μεγέθη

(διεργασίες) ταυτόχρονα, δηλαδή έχει πολλές μεταβλητές εξόδου. Στον τομέα της πρόβλεψης της κυκλοφορίας, ένα μοντέλο πολλαπλών διεργασιών μπορεί να χρησιμοποιηθεί για την πρόβλεψη περισσότερων του ενός κυκλοφοριακών μεγεθών (φόρτος, ταχύτητα, πυκνότητα ή κατάληψη). Το βασικό πλεονέκτημα αυτής της μεθόδου σε σχέση με τη χρήση μοντέλων για την πρόβλεψη μίας μεταβλητής είναι ότι, σύμφωνα με τις θεμελιώδεις σχέσεις της Κυκλοφοριακής Τεχνικής, χρειάζονται τουλάχιστον δύο μεταβλητές για τον χαρακτηρισμό των κυκλοφοριακών συνθηκών ως συμφορημένες ή μη. Για παράδειγμα, μία τιμή του φόρτου αντιστοιχεί σε δύο πιθανές καταστάσεις. Παρέχοντας στο μοντέλο την τιμή μιας επιπλέον μεταβλητής, αυτό δύναται να διαχωρίζει τις δύο καταστάσεις και τις διαφορετικές δυναμικές που αντιστοιχούν στην καθεμιά.

Μία διαφορετική προσέγγιση πολυμεταβλητών προβλέψεων στην πρόβλεψη της κυκλοφορίας είναι οι πολυτροπικές προβλέψεις, δηλαδή η πρόβλεψη της κυκλοφορίας στο οδικό δίκτυο σε συνδυασμό με τη ζήτηση για άλλα μέσα μεταφοράς, π.χ. Μέσα Μαζικής Μεταφοράς. Ένα σχετικό παράδειγμα παρουσιάζεται στο Κεφάλαιο 5 της παρούσας διατριβής. Πρέπει να τονιστεί ότι, ιδιαίτερα σε αυτή την περίπτωση, εκτός από τον εκτεταμένο χώρο εξόδου, αυξάνεται σημαντικά και η πολυπλοκότητα του χώρου εισόδου. Συνεπώς, αυτή η προσέγγιση πρέπει να επιλέγεται όταν υπάρχει σημαντική συσχέτιση των μεταβλητών εξόδου και αναμένεται να αυξηθεί η συνολική ακρίβεια πρόβλεψης για όλες.

Πρόκληση 6: Ενισχυμένη αξιοπιστία με Νευρωνικά Δίκτυα Βασισμένα Στη Φυσική

Η πρόσφατη βιβλιογραφία στην πρόβλεψη της κυκλοφορίας βασίζεται κυρίως στην Βαθιά Μάθηση, παραβλέποντας την επιστημονική γνώση που προέρχεται από τη θεωρία της Κυκλοφοριακής Τεχνικής. Το γεγονός αυτό μειώνει περεταίρω την αξιοπιστία των μοντέλων και, σε συνδυασμό με τους περιορισμούς που αναφέρθηκαν νωρίτερα, μειώνει και τις προοπτικές αξιοποίησής τους σε πραγματικές συνθήκες. Από την άλλη μεριά, τα αναλυτικά (ή στατιστικά) κυκλοφοριακά μοντέλα οδηγούν σε ανακριβείς εκτιμήσεις για τέσσερις κύριους λόγους: μπορούν να αποτυπώσουν μόνο ένα περιορισμένο υποσύνολο των πιθανών συνθηκών κυκλοφορίας και της δυναμικής τους, αναφέρονται σε ιδανικές συνθήκες, περιλαμβάνουν αρκετές παραμέτρους που πρέπει να καθοριστούν από τον χρήστη και είναι ευάλωτα σε θορυβώδη δεδομένα. Ωστόσο, αυτού του είδους τα μοντέλα είναι ερμηνεύσιμα και δεν απαιτούν μεγάλες ποσότητες δεδομένων.

Ο συνδυασμός των παραπάνω προσεγγίσεων υιοθετείται από τα Νευρωνικά Δίκτυα Βασισμένα στη Φυσική (Physics-Informed Neural Networks) που είναι πολύ αποδοτικά όσον αφορά τις απαιτήσεις δεδομένων, επιτυγχάνοντας παρόμοιες ή και καλύτερες επιδόσεις από τα κλασικά μοντέλα Βαθιάς Μάθησης. Μάλιστα η εισαγωγή στοιχείων από τη θεωρία αναμένεται να μειώσει την πολυπλοκότητα του μοντέλου, να βελτιώσει την απόδοση και την αξιοπιστία και, κυρίως, να οδηγήσει σε έγκυρες προβλέψεις και ορθολογική λήψη αποφάσεων. Η έννοια της Ενημερωμένης από τη Θεωρία Βαθιάς Μάθησης στοχεύει στο να συνδυάσει τα πλεονεκτήματα των δύο παραπάνω προσεγγίσεων μοντελοποίησης. Συγκεκριμένα, εφαρμόζεται όταν ένα μοντέλο οδηγούμενο από τα δεδομένα περιλαμβάνει, ως είσοδο ή έξοδο, μία ή περισσότερες μεταβλητές για τις οποίες είναι γνωστή μια αναλυτική/μαθηματική σχέση από το αντίστοιχο επιστημονικό πεδίο. Η σχέση αυτή συνήθως ενσωματώνεται στη συνάρτηση απωλειών του μοντέλου ή χρησιμοποιείται σε μια ανεξάρτητη οντότητα και αποσκοπεί στην προσαρμογή ιδιαίτερα λανθασμένων, παράλογων προβλέψεων του μοντέλου, προς τις "θεωρητικά" αναμενόμενες.

Πρόκληση 7: Προβλέψεις σε επίπεδο δικτύου

Η ανάπτυξη ενός πλαισίου μοντελοποίησης που θα παρέχει προβλέψεις για ένα ολόκληρο οδικό δίκτυο ταυτόχρονα, παραμένει ανεπαρκώς διερευνημένη, αν και μπορεί να αυξήσει σημαντικά τη δυνατότητα αξιοποίησης οποιουδήποτε μοντέλου. Στην πρόσφατη βιβλιογραφία, τα περισσότερα μοντέλα παρέχουν έξοδο για μία μόνο θέση και όχι για όλες ταυτόχρονα, που συνήθως αναφέρεται ως θέση-στόχος, και εκμεταλλεύονται μόνο ένα σχετικά μικρό τμήμα του οδικού δικτύου ως είσοδο. Οι λόγοι που συμβαίνει αυτό περιλαμβάνουν την ανεπαρκή διαθεσιμότητα και ποιότητα δεδομένων, τις υψηλές υπολογιστικές απαιτήσεις και την πολυπλοκότητα ενός τέτοιου μοντέλου.

Για την αντιμετώπιση των παραπάνω περιορισμών, οι ερευνητές στρέφονται κυρίως σε αλγόριθμους και μεθόδους της Υπολογιστικής Επιστήμης που εμφανίστηκαν σχετικά πρόσφατα. Η πιο σημαντική από αυτές είναι η Υπολογιστική Παρυφών (Edge Computing), στην οποία οι υπολογιστικές εργασίες εκτελούνται στις παρυφές του δικτύου, δηλαδή εκεί που συλλέγονται τα δεδομένα, και όχι σε ένα κεντρικό υπολογιστικό νέφος ή κέντρο δεδομένων. Για παράδειγμα, η Υπολογιστική Παρυφών μπορεί να χρησιμοποιηθεί για την επεξεργασία μεγάλων ποσοτήτων δεδομένων κυκλοφορίας που παράγονται από αισθητήρες, κάμερες, συσκευές GPS και άλλες πηγές τοπικά, προκειμένου να παρέχονται προβλέψεις των συνθηκών κυκλοφορίας σχεδόν σε πραγματικό χρόνο.

Βασισμένο στις αρχές της Υπολογιστικής Παρυφών, η Ομοσπονδιακή Μάθηση (Federated Learning), είναι ένα πρότυπο μηχανικής μάθησης που επιτρέπει σε πολλαπλούς συμμετέχοντες, όπως συσκευές ή κόμβους ακμών, να μαθαίνουν συνεργατικά ένα μοντέλο χωρίς να μοιράζονται τα ακατέργαστα δεδομένα τους με μια κεντρική οντότητα. Αντ' αυτού, ανταλλάσσουν μεταξύ τους ενημερώσεις του μοντέλου με αποκεντρωμένο τρόπο, επιτρέποντας τη βελτίωση του συνολικού μοντέλου μέσω των συλλογικών συνεισφορών όλων των συμμετεχόντων. Αυτή η προσέγγιση έχει τα πλεονεκτήματα της δυνατότητας κλιμάκωσης, δηλαδή το φορτίο του υπολογιστικού έργου κατανέμεται στις συμμετέχουσες συσκευές, επιτρέποντας την κλιμάκωση σε προβλήματα που θα ήταν ανέφικτο να επιλυθούν με μια κεντρική προσέγγιση, και της ανθεκτικότητας, καθώς το σύστημα θα είναι σε θέση να συνεχίσει να λειτουργεί, ακόμη και αν κάποιοι συμμετέχοντες παρουσιάσουν οποιουδήποτε είδους αστοχία.

Προς το παρόν, η αξιοποίηση των παραπάνω μεθόδων στην πρόβλεψη της κυκλοφορίας, καθώς και γενικότερα της πρόβλεψης σε επίπεδο δικτύου, βρίσκεται σε πολύ πρώιμο στάδιο.

Πρόκληση 8: Αποδοτικότητα και επεκτασιμότητα σε πολυτροπικά περιβάλλοντα

Η πρόβλεψη της ζήτησης των μέσων μαζικής μεταφοράς, καθώς και άλλων τρόπων μεταφοράς (π.χ. ταξί, υπηρεσίες μετακίνησης, ποδήλατα κ.λπ.), αποτελούν παραλλαγές του προβλήματος της πρόβλεψης της κυκλοφορίας, που επίσης μπορούν να αντιμετωπιστούν με παρόμοιο τρόπο. Μια ολοκληρωμένη προσέγγιση, που θα λαμβάνει υπόψη όλα τα μέσα μεταφοράς, θα έφερνε επανάσταση στη διαχείριση της κυκλοφορίας και στη λήψη αποφάσεων σε επίπεδο πόλης και θα παρείχε στις αρχές ένα εργαλείο που θα επέτρεπε τη βελτιστοποίηση των συνθηκών κυκλοφορίας σε ολόκληρο το οδικό δίκτυο. Τα παραπάνω είναι δυνατά με την επέκταση της έννοιας της πρόβλεψης πολλαπλών διεργασιών στην πρόβλεψη πολυτροπικής κυκλοφορίας.

Εάν αυξηθεί η διαθεσιμότητα δεδομένων πολλαπλών πηγών, αναμένεται να αυξηθεί και η δημοτικότητα της πολυτροπικής πρόβλεψης κυκλοφορίας. Προκειμένου να αναπτυχθεί ένα μοντέλο ικανοποιητικά χαμηλής πολυπλοκότητας που θα είναι αποδοτικό, παρά το γεγονός ότι

έχει έναν τόσο μεγάλο χώρο εισόδου, είναι απαραίτητη μια ακριβής αναπαράσταση των χώρων εισόδου και των μεταξύ τους σχέσεων.

Ερευνητικά Ερωτήματα

Σύμφωνα με τα ευρήματα της βιβλιογραφικής ανασκόπησης και τις προκλήσεις που εντοπίστηκαν, και όσον αφορά στους στόχους της παρούσας διατριβής, μπορούν να διατυπωθούν τα ακόλουθα ερευνητικά ερωτήματα:

E1: Μπορούν να εντοπιστούν σημαντικά χωροχρονικά μοτίβα κυκλοφορίας σε ένα οδικό δίκτυο; Πόσο ευαίσθητα είναι αυτά στη διαδικασία εξαγωγής; Ποιος είναι ο αντίκτυπος αυτών των μοτίβων στη βραχυπρόθεσμη δυνατότητα πρόβλεψης της κυκλοφορίας;

E2: Πώς μπορούν να επεκταθούν οι τυπικές αναπαραστάσεις του οδικού δικτύου και των χωροχρονικών συσχετίσεων ώστε να συμπεριλάβουν πληροφορίες από πολλαπλούς τρόπους μετακίνησης και ποιος θα είναι ο αντίκτυπος στην προβλεψιμότητα της κυκλοφορίας;

E3: Ποια θα ήταν η κατάλληλη διατύπωση του προβλήματος και η δομή μοντελοποίησης πολλαπλών εργασιών ώστε να καταστεί δυνατή η αποτελεσματική και ακριβής πρόβλεψη της κυκλοφορίας σε επίπεδο δικτύου;

E4: Μπορεί να καταρτιστεί ένα πλαίσιο αιτιώδους πρόβλεψης που θα οδηγήσει στην ανίχνευση σημαντικών προτύπων κυκλοφορίας, ενισχύοντας παράλληλα την αξιοπιστία και την ακρίβεια των προβλέψεων;

E5: Πώς θα μπορούσαν να ενσωματωθούν πτυχές της μοντελοποίησης με επίγνωση της θεωρίας στη διαδικασία πρόβλεψης για να βελτιώσουν την αξιοπιστία και τη εφαρμοσιμότητα των μοντέλων πρόβλεψης;

Εξόρυξη Γραμμικών και Μη Γραμμικών Χωροχρονικών Χαρακτηριστικών σε Αστικά Δίκτυα

Σύμφωνα με όσα έχουν ήδη συζητηθεί, ένα προφανές πρώτο βήμα προς την ανάπτυξη ενός εφαρμόσιμου μοντέλου πρόβλεψης είναι να εξεταστεί κατά πόσον υπάρχουν χωρικές εξαρτήσεις μεταξύ των κυκλοφοριακών συνθηκών στις διάφορες θέσεις ενός οδικού δικτύου και ποιες είναι οι επιπτώσεις τους στη βραχυπρόθεσμη πρόβλεψη της κυκλοφορίας. Για το σκοπό αυτό, εφαρμόζονται τρεις μέθοδοι για τον εντοπισμό τους: Συσχέτιση κατά Pearson, Αμοιβαία Πληροφορία (Mutual Information) και Δυναμική Χρονική Παραμόρφωση (Dynamic Time Warping). Η προτεινόμενη μεθοδολογική προσέγγιση εφαρμόζεται στο οδικό δίκτυο της πόλης Xi'an της Κίνας, χρησιμοποιώντας δεδομένα τροχιάς που παρέχονται από την Didi Chuxing Technology Co, μια κινεζική εταιρεία παροχής υπηρεσιών ταξί κινητικότητας, τα οποία αξιοποιήθηκαν για την εκτίμηση της χρονοσειράς της μέσης ταχύτητας για κάθε τμήμα του οδικού δικτύου. Πιο συγκεκριμένα, πραγματοποιείται εντοπισμός των 20 πιο συσχετισμένων θέσεων με τη θέση-στόχο σύμφωνα με κάθε μέθοδο συσχέτισης και συγκρίνονται οι ακρίβειες πρόβλεψης όταν χρησιμοποιούνται αποκλειστικά οι προαναφερθείσες θέσεις ως είσοδος σε ένα μοντέλο κατηγοριοποίησης Μπεϋζιανού δικτύου.

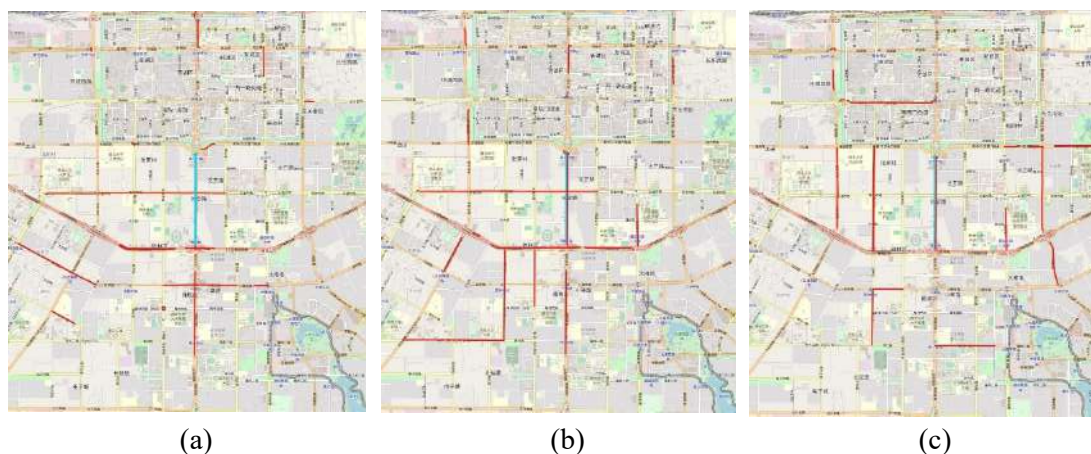
Προεπεξεργασία δεδομένων

Τα δεδομένα που χρησιμοποιούνται σε αυτή την ενότητα αποτελούνται από 3,2 εκατομμύρια διαδρομές GPS των οχημάτων της Didi στο οδικό δίκτυο της Xi'an, που πραγματοποιήθηκαν

μεταξύ 2 και 30 Νοεμβρίου 2016. Κάθε τροχιά αντιστοιχεί στην ακριβή θέση του οχήματος κάθε 2 έως 4 δευτερόλεπτα, καθώς και την ταχύτητά του, που είναι και η μεταβλητή που χρησιμοποιήθηκε για την πρόβλεψη. Στη συνέχεια, εφαρμόστηκε ένας αλγόριθμος αντιστοίχισης των σημείων στα οδικά τμήματα του δικτύου και, ομαδοποιώντας τα δεδομένα κάθε τμήματος ανά μία ώρα, προέκυψαν οι ωριαίες χρονοσειρές μέσης ταχύτητας των τμημάτων.

Εντοπισμός χωρικών συσχετίσεων

Χρησιμοποιώντας τις τρεις προαναφερθείσες μεθόδους, υπολογίζεται η συσχέτιση όλων των οδικών τμημάτων με το τμήμα-στόχος. Ως τμήμα-στόχος επιλέχθηκε ένα από τα πιο πολυσύχναστα τμήματα που βρίσκεται στο κέντρο της Χί'αν. Παρατηρώντας τα αποτελέσματα, φαίνεται ότι οι τρεις προσεγγίσεις αποτυπώνουν διαφορετικά χωρικά μοτίβα στο ίδιο σύνολο δεδομένων. Πιο συγκεκριμένα, σύμφωνα με τους υπολογισμούς της αμοιβαίας πληροφορίας και της συσχέτισης Pearson, τα κοντινά κάθετα οδικά τμήματα συσχετίζονται περισσότερο με το επιλεγμένο, καθώς και ορισμένα ανάντη και κατόντη οδικά τμήματα. Επιπλέον, για την αμοιβαία πληροφορία, εντοπίζονται ορισμένα παράλληλα τμήματα. Αντίθετα, με την DTW, δεν ανιχνεύεται κανένα κάθετο οδικό τμήμα, αλλά αντίθετα κάποια γειτονικά παράλληλα (τα οποία δεν ανιχνεύονται από τις άλλες μεθόδους). Ο αντίκτυπος αυτών των διαφορών θα πρέπει να διερευνηθεί περαιτέρω όσον αφορά την ακρίβεια πρόβλεψης. Το τμήμα-στόχος καθώς και τα 20 πιο συσχετισμένα με αυτό τμήματα, σύμφωνα με κάθε μέθοδο, παρουσιάζονται στην **Εικόνα 1**.



Εικόνα 1. Τα 20 πιο συσχετισμένα οδικά τμήματα (κόκκινο) με το επιλεγμένο τμήμα (μπλε), από την άποψη (α) της Συσχέτισης Pearson, (β) της Αμοιβαίας Πληροφορίας και (γ) της Δυναμικής Χρονικής Παραμόρφωσης.

Αποτελέσματα πρόβλεψης και σύγκριση μεθόδων

Προκειμένου να συγκριθούν τα αποτελέσματα των μεθόδων, αναπτύσσονται μοντέλα πρόβλεψης της ταχύτητας του οδικού τμήματος-στόχου. Τα μοντέλα είναι Μπειζιανοί ταξινομητές που προβλέπουν την ταχύτητα του τμήματος σε τρεις ισορροπημένες κλάσεις: <20, 20-26, >26 km/h. Συνολικά αναπτύχθηκαν τρία μοντέλα: τα δύο πρώτα δέχονται σαν είσοδο τις τιμές της ταχύτητας στα 20 πιο συσχετισμένα τμήματα σύμφωνα με τις μεθόδους της Αμοιβαίας Πληροφορίας και της Δυναμικής Χρονικής Παραμόρφωσης, αντίστοιχα, ενώ το τρίτο από όλα τα τμήματα. Η ακρίβεια των τριών μοντέλων παρουσιάζεται στον **Πίνακα 1**.

Πίνακας 1. Μετρικές ταξινόμησης των τριών μοντέλων

Metrics	Model 1 (Mutual Info)	Model 2 (DTW)	Model 3 (all locations)
Accuracy	89%	86%	84%
Recall (Sensitivity)	89%	86%	84%
Precision	89%	86%	85%
F1 - score	89%	86%	85%

Από τον παραπάνω πίνακα μπορεί κανείς να συμπεράνει ότι η χρήση της αμοιβαίας πληροφορίας είναι η πιο κατάλληλη επιλογή για την περιγραφή των χωρικών συσχετίσεων, τουλάχιστον για την συγκεκριμένη εφαρμογή. Αφετέρου, τα δύο πρώτα μοντέλα έχουν σαφώς καλύτερη απόδοση από το τρίτο. Το αποτέλεσμα αυτό αναδεικνύει τη χρησιμότητα της εκτέλεσης ακόμη και μιας απλής χωροχρονικής ανάλυσης για την επιλογή των πιο κατάλληλων δεδομένων εισόδου. Επιπλέον, η παραπάνω διαδικασία μειώνει τη διαστατικότητα του προβλήματος, η οποία είναι ένα πολύ συνηθισμένο ζήτημα κατά τη χρήση αλγορίθμων μηχανικής μάθησης. Στην παρούσα περίπτωση, ήταν διαθέσιμες 283 μεταβλητές (οδικά τμήματα), που είναι μια υψηλή τιμή, αλλά εν τέλει ήταν απαραίτητα μόνο 20, μειώνοντας και τους απαιτούμενους υπολογιστικούς πόρους, κάτι που είναι εξίσου σημαντικό.

Πρόβλεψη Κυκλοφορίας με Χρήση Πληροφοριών Πολλαπλής Χρονικής Ανάλυσης με Δεδομένων Τροχιάς Οχημάτων Σε Επίπεδο Δικτύου


Η ανάλυση που παρουσιάστηκε στο προηγούμενο κεφάλαιο κατέδειξε ότι, πράγματι, υπάρχουν σημαντικές χωρικές σχέσεις μεταξύ των κυκλοφοριακών συνθηκών ενός οδικού δικτύου, οι οποίες μπορούν να εντοπιστούν με τη χρήση κατάλληλων μεθόδων από τη στατιστική και τη θεωρία της πληροφορίας. Επιπλέον, προέκυψε ότι η επίδρασή τους στην ακρίβεια της πρόβλεψης είναι αξιοσημείωτη. Στην παρούσα ενότητα, δίνεται έμφαση στις χρονικές σχέσεις, χρησιμοποιώντας μια πιο κατάλληλη δομή μοντελοποίησης, δηλαδή ένα μοντέλο Βαθιάς Μάθησης, του οποίου ο χώρος εισόδου αποτελείται από χρονοσειρές. Επιπλέον, τα δεδομένα συγκεντρώνονται σε υψηλότερη χρονική ανάλυση και, σε αντίθεση με την προηγούμενη ενότητα, παρέχονται βραχυπρόθεσμες προβλέψεις, κάτι που αποτελεί πιο δύσκολο εγχείρημα.

Μοντελοποίηση σύνθετων χρονικών μοτίβων

Η πολυπλοκότητα του οδικού περιβάλλοντος, των μηχανισμών ελέγχου, καθώς και το πλήθος των οδηγικών συμπεριφορών και των μη επαναλαμβανόμενων συνθηκών, οδηγούν σε συνεχώς μεταβαλλόμενες χρονικές δυναμικές που καθιστούν εξαιρετικά δύσκολη την μοντελοποίησή τους από μια απλή δομή. Για παράδειγμα, στα Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks), που θεωρούνται τα πιο κατάλληλα και ακριβή μοντέλα στην ανάλυση χρονοσειρών, δεν προβλέπεται η χρήση δεδομένων εισόδου με μεταβλητή χρονική συχνότητα.

Σε αυτή την ενότητα, επιχειρείται η αποτύπωση των βραχυπρόθεσμων και μακροπρόθεσμων επιδράσεων που παρατηρούνται στην κυκλοφορία, η εσωτερίκευση του ζητήματος των χρονικά μεταβαλλόμενων χρονικών εξαρτήσεων που παρατηρούνται στη ροή κυκλοφορίας στη διαδικασία μάθησης και η βελτίωση της ικανότητας πρόβλεψης σε σχέση με τα κλασικά

Αναδρομικά Νευρωνικά Δίκτυα, με την εφαρμογή προηγμένων χρονικά μεταβαλλόμενων επαναλαμβανόμενων νευρωνικών δομών. Συγκεκριμένα, η αρχιτεκτονική των Διαστελλόμενων Αναδρομικών Δικτύων (Dilated Neural Networks) είναι μια πολυεπίπεδη αρχιτεκτονική νευρωνικού δικτύου που είναι πολύ απλή στην κατανόησή της, αλλά αποτελεσματική και αποδοτική και βασίζεται στα απλά Αναδρομικά δίκτυα. Χαρακτηρίζεται επίσης από τις διασταλμένες επαναλαμβανόμενες συνδέσεις παράλειψης και τη χρήση εκθετικά αυξανόμενης διαστολής, η οποία απεικονίζεται στην **Εικόνα 2**.



Εικόνα 2. Η αρχιτεκτονική των Διαστελλόμενων Αναδρομικών Δικτύων (Dilated Neural Networks)

Προετοιμασία δεδομένων

Τα δεδομένα που χρησιμοποιούνται σε αυτή την ενότητα είναι αυτά των μέσων ταχυτήτων του οδικού δικτύου της Χι'αν που χρησιμοποιήθηκε και στην προηγούμενη ενότητα, με τη διαφορά ότι οι χρονοσειρές ομαδοποιούνται ανά πεντάλεπτο. Ο χώρος εισόδου περιλαμβάνει τις χρονοσειρές όλων των οδικών τμημάτων (497 συνολικά), για 12 χρονικά βήματα (μία ώρα) ανά παρατήρηση, οι οποίες χρησιμοποιούνται για την πρόβλεψη της ταχύτητας του τμήματος-στόχου 5 λεπτά μετά.

Αποφασίστηκε ότι οι ταχύτητες του τμήματος-στόχου θα πρέπει να ταξινομηθούν σε δύο κατηγορίες, οπότε, και πάλι, έχουμε ένα πρόβλημα ταξινόμησης. Οι δύο κατηγορίες είναι λιγότερο από 33 km/h και περισσότερο από 33 km/h, που είναι η διάμεσος των ταχυτήτων του τμήματος για τις 29 ημέρες των δεδομένων. Με αυτόν τον τρόπο, υποθέτουμε κακές έως μέτριες συνθήκες κυκλοφορίας όταν η κατηγορία ταχύτητας είναι η πρώτη και μέτριες έως καλές συνθήκες όταν είναι η δεύτερη.

Αποτελέσματα

Για την πρόβλεψη των ταχυτήτων χρησιμοποιείται ένα Διαστελλόμενο δίκτυο που βασίζεται συγκεκριμένα στην αρχιτεκτονική του Δικτύου Μακράς Βραχυπρόθεσμης Μνήμης (Long Short-Term Memory – LSTM). Στον **Πίνακα 2** παρουσιάζονται οι μετρικές κατηγοριοποίησης για το προαναφερθέν διαστελλόμενο δίκτυο σε σύγκριση με ένα απλό δίκτυο ίδιου τύπου.

Τα αποτελέσματα της σύγκρισης μεταξύ ενός Διαστελλόμενου δικτύου LSTM και ενός κλασικού στην πρόβλεψη μελλοντικών συνθηκών κυκλοφορίας με χρήση δεδομένων από όλο το δίκτυο έδειξαν ότι το διαστελλόμενο μπορεί να βελτιώσει την ακρίβεια πρόβλεψης, χωρίς να εισάγει υπερβολική πολυπλοκότητα στη διαδικασία. Η αρχιτεκτονική του προτεινόμενου δικτύου είναι αρκετά απλή και επίσης εύκολα αντιληπτή. Το κύριο πλεονέκτημα της

προτεινόμενης αρχιτεκτονικής σε σύγκριση με το απλό LSTM είναι ότι αποτυπώνει και εκμεταλλεύεται τις μακροπρόθεσμες συσχετίσεις που μπορεί να επηρεάσουν τις μελλοντικές συνθήκες κυκλοφορίας πιο καθοριστικά σε σύγκριση με τις βραχυπρόθεσμες

Πίνακας 2. Σύγκριση αποτελεσμάτων Διαστελλόμενου και κλασσικού Αναδρομικού δικτύου

	Dilated LSTM	Simple LSTM
Precision	0.85	0.83
Recall	0.85	0.82
F1 score	0.85	0.82
Accuracy	0.85	0.819

Πολυτροπική Πρόβλεψη σε Επίπεδο Δικτύου

Προχωρώντας ένα βήμα παρακάτω από την απλή επιλογή μεταβλητών εισόδου και την μοντελοποίηση των χωροχρονικών συσχετίσεων με βάση κάποια μετρική, σε αυτή την ενότητα προτείνεται η υιοθέτηση του Πολυεπίπεδου Δικτύου (Multiplex Network) από την ερευνητική περιοχή της Ανάλυσης Κοινωνικών Δικτύων για την αναπαράσταση του μεταφορικού δικτύου της Αθήνας και των αντίστοιχων συσχετίσεων. Επίσης, χρησιμοποιείται ένας αλγόριθμος Εντοπισμού Κοινοτήτων στο Πολυεπίπεδο Δίκτυο για τον προσδιορισμό των πιο σχετικών στοιχείων του χώρου εισόδου για τα μοντέλα πρόβλεψης που αναπτύσσονται στη συνέχεια.

Μάλιστα, σε αυτή την εφαρμογή, ακολουθείται μια προσέγγιση πολυτροπικών και πολλαπλών πηγών δεδομένων, καθώς, όχι μόνο προβλέπεται ο μελλοντικός φόρτος κυκλοφορίας και η μελλοντική ζήτηση του μετρό, αλλά αξιοποιούνται επίσης ως χαρακτηριστικά εισόδου για την πρόβλεψη του ενός από το άλλο. Αυτή η προσέγγιση ενός πολυτροπικού πλαισίου, το οποίο εντοπίζει σημαντικές συσχετίσεις μεταξύ των διαφόρων μέσων μεταφοράς (και μπορεί επίσης να επεκταθεί σε περισσότερα από δύο μέσα), θα έχει πολύ σημαντικές προεκτάσεις σε ένα ολιστικό σύστημα διαχείρισης της κυκλοφορίας.

Πολυεπίπεδα δίκτυα

Τα Πολυεπίπεδα Δίκτυα είναι πολύπλοκες δομές γράφων που διαθέτουν στρώματα εκτός από κόμβους και ακμές, τα οποία διαθέτουν οι απλοί γράφοι. Ένα πολυεπίπεδο δίκτυο αποτελείται από δύο ή περισσότερους διασυνδεδεμένους απλούς γράφους που βρίσκονται σε διαφορετικά στρώματα. Κάθε στρώμα έχει διαφορετική δομή συνδεσιμότητας εντός του. Αυτό το είδος δικτύου επιτρέπει μια πιο ρεαλιστική προσέγγιση στη μελέτη της αλληλεπίδρασης ατόμων/πρακτόρων, τα οποία μπορούν να επικοινωνούν μέσω διαφορετικών τύπων καναλιών. Η παρούσα εργασία υιοθετεί τον ορισμό ενός πολυεπίπεδου δικτύου ως ένα δίκτυο που αποτελείται από πολλά στρώματα, όπου ένας κόμβος δεν συνδέεται με κόμβους που βρίσκονται σε διαφορετικό στρώμα, αλλά μόνο εντός του ίδιου στρώματος.

Εντοπισμός κοινοτήτων

Τα πραγματικά δίκτυα παρουσιάζουν μεγάλες ανομοιογένειες, δηλαδή κορυφές με χαμηλό βαθμό συνδεσιμότητας (λίγες συνδέσεις) συνυπάρχουν με κάποιες κορυφές με υψηλό βαθμό. Έτσι, η κατανομή των ακμών είναι συνολικά και τοπικά ανομοιογενής. Δομικές διαφορές μπορούν να παρατηρηθούν εντός συγκεκριμένων ομάδων κορυφών, όπως υψηλές ή χαμηλές

συγκεντρώσεις ακμών μεταξύ αυτών των ομάδων. Αυτό το χαρακτηριστικό των πραγματικών δικτύων ονομάζεται δομή κοινότητας ή ομαδοποίηση. Έτσι, οι κοινότητες, οι οποίες αποκαλούνται επίσης συστάδες ή ενότητες, είναι ομάδες κορυφών που μοιράζονται κοινές ιδιότητες και/ή παίζουν παρόμοιο ρόλο μέσα στον γράφο.

Για τους σκοπούς της παρούσας εργασίας, χρησιμοποιείται ο αλγόριθμος Louvain. Ο αλγόριθμος ανίχνευσης κοινοτήτων Louvain βασίζεται στη βελτιστοποίηση της αρθρωσιμότητας (modularity) κατά την πρόοδο του αλγορίθμου. Η αρθρωσιμότητα είναι μια τιμή κλίμακας μεταξύ -0,5 (μη αρθρωτή ομαδοποίηση) και 1 (πλήρως αρθρωτή ομαδοποίηση) που μετρά τη σχετική πυκνότητα των ακμών εντός κοινοτήτων σε σχέση με τις ακμές εκτός κοινοτήτων και η βελτιστοποίηση αυτής της τιμής οδηγεί στην καλύτερη δυνατή ομαδοποίηση των κόμβων ενός συγκεκριμένου δικτύου.

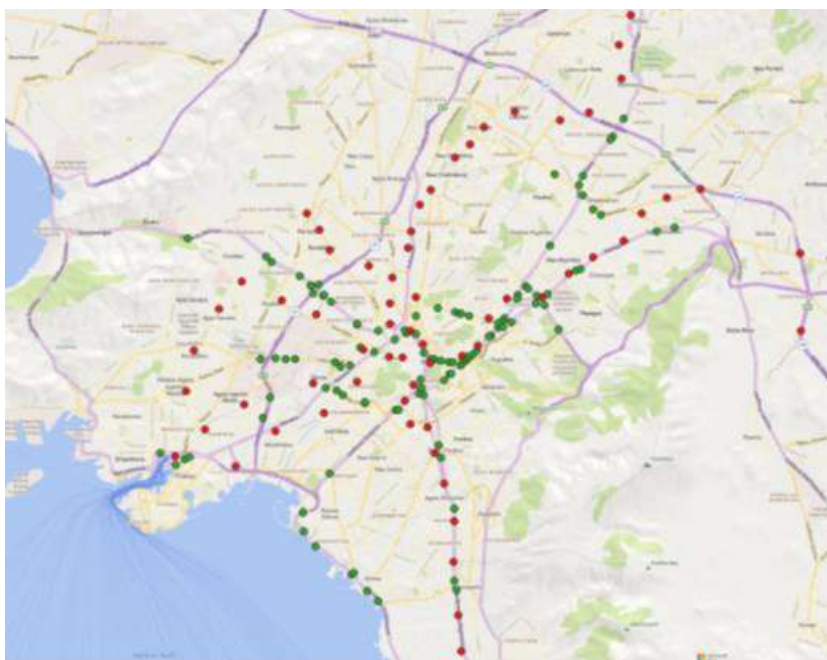
Για Πολυεπίπεδα Δίκτυα, η αρθρωσιμότητα δίνεται από την παρακάτω σχέση:

$$Q_m = \frac{1}{2\mu} \sum_{i,j} \sum_{sr} \left[\left(a_{ijs} - \frac{k_{is}k_{js}}{2m_s} \right) \delta(s,r) + \omega \delta(i,j) \right] \delta(\gamma_{is}, \gamma_{jr}) \quad (III)$$

όπου i, j είναι οι πράκτορες, s, r είναι τα στρώματα, a_{ijs} είναι 1 αν i, j είναι γειτονικά στο στρώμα s , k_{js} είναι ο βαθμός του πράκτορα j στο στρώμα s , μ είναι ο αριθμός των ζευγών κορυφών που είτε είναι γειτονικές στο στρώμα s είτε αντιστοιχούν στον ίδιο πράκτορα, m_s είναι ο αριθμός των ακμών στο στρώμα s , γ_{is} είναι η κοινότητα στην οποία έχει ανατεθεί ο πράκτορας i στο στρώμα s , δ είναι το δέλτα Kronecker και ω είναι ένα βάρος: όταν ο ίδιος πράκτορας ανήκει στην ίδια κοινότητα σε δύο διαφορετικά στρώματα, τότε το Q_m αυξάνεται κατά ω . Το ω είναι μια παράμετρος που παίρνει τιμές από 0 έως 1. Ο καθορισμός υψηλότερων τιμών του ω θα έχει ως αποτέλεσμα κοινότητες που θα εκτείνονται σε πολλαπλά στρώματα και θα αποτελούνται από τους ίδιους πράκτορες, αφού με αυτόν τον τρόπο αυξάνεται η τιμή της αρθρωσιμότητας. Από την άλλη πλευρά, αν το ω οριστεί ίσο με 0, η ύπαρξη των ίδιων πρακτόρων σε διαφορετικά στρώματα στην ίδια κοινότητα δεν συμβάλλει στην αρθρωσιμότητα.

Διαθέσιμα δεδομένα

Για την ανάπτυξη του μοντέλου πρόβλεψης της κυκλοφορίας χρησιμοποιήθηκαν δεδομένα κυκλοφοριακής ροής και ζήτησης του μετρό, τα οποία αντιστοιχούν στον αριθμό των διερχόμενων οχημάτων και των επιβατών, αντίστοιχα, από διάφορα σημεία του οδικού δικτύου για περίοδο μιας ώρας. Συγκεκριμένα, χρησιμοποιήθηκαν δεδομένα 10 μηνών (Ιανουάριος έως Οκτώβριος του 2021) από 113 από ανιχνευτές βρόχου που βρίσκονται γύρω από το κέντρο της πόλης της Αθήνας, καθώς και η ζήτηση όλων των 63 σταθμών του μετρό. Στην **Εικόνα 3** φαίνεται η ακριβής θέση των ανιχνευτών βρόχου με πράσινο χρώμα και των σταθμών του μετρό με κόκκινο χρώμα.



Εικόνα 3. Γεωγραφική κατανομή ανιχνευτών (πράσινο) και σταθμών του μετρό (κόκκινο)

Το δίκτυο της Αθήνας ως Πολυεπίπεδος Γράφος και εντοπισμός κοινοτήτων

Το συγκοινωνιακό δίκτυο της Αθήνας (ανιχνευτές και σταθμοί μετρό) μπορεί να αναπαρασταθεί ως ένα πολυεπίπεδο γράφημα των χωροχρονικών σχέσεων των κόμβων, προκειμένου να ανιχνευθούν κοινότητες και να αντληθούν πολύτιμες πληροφορίες για τις χωρικές και χρονικές σχέσεις που το διέπουν. Η κατασκευή του γραφήματος βασίστηκε στην ιδέα ότι κάθε επίπεδο θα αντιστοιχεί σε κάθε ώρα της ημέρας, οπότε το γράφημα αποτελείται από 24 επίπεδα. Κάθε στρώμα αποτελείται από 176 κόμβους, καθένας από τους οποίους αντιπροσωπεύει έναν ανιχνευτή βρόχου ή έναν σταθμό του μετρό. Στη συνέχεια, για να καθοριστούν οι ακμές κάθε στρώματος, σχηματίστηκε η χρονοσειρά της ζήτησης κάθε κόμβου την αντίστοιχη ώρα κάθε ημέρας (π.χ. κάθε μέρα στις 9 π.μ. για το 9ο στρώμα) και στη συνέχεια υπολογίστηκε η αμοιβαία πληροφορία μεταξύ των χρονοσειρών όλων των κόμβων για την ίδια ώρα. Εάν η αμοιβαία πληροφορία μεταξύ δύο κόμβων είναι μεγαλύτερη από 0,5, γεγονός που υποδηλώνει σημαντική συσχέτιση, δημιουργείται μια ακμή μεταξύ τους. Με αυτόν τον τρόπο μοντελοποιήθηκε η χωροχρονική συσχέτιση μεταξύ των κόμβων. Χρησιμοποιήθηκε η παραπάνω τεχνική για να δημιουργηθούν οι ακμές των γραφημάτων, αντί για τις πραγματικές συνδέσεις, επειδή, σε επίπεδο δικτύου, δεν είναι ιδιαίτερα ευχερής ο προσδιορισμός της συνδεσιμότητας των κόμβων, ιδίως μεταξύ ετερογενών κόμβων (σταθμοί του μετρό και ανιχνευτές βρόχων) και, κυρίως, η μέθοδος αυτή οδηγεί σε ξεχωριστή δομή γραφημάτων σε κάθε επίπεδο, η οποία αντικατοπτρίζει τη δυναμική φύση των χωρικών σχέσεων.

Μετά την κατασκευή του πολυεπίπεδου γραφήματος ακολουθεί η ανίχνευση κοινοτήτων χωροχρονικά συσχετισμένων κόμβων. Εφαρμόζοντας τον αλγόριθμο ανίχνευσης κοινοτήτων του Louvain, εντοπίζονται 7 κοινότητες, όπου οι κόμβοι διαφορετικών στρωμάτων αντιστοιχίζονται στην ίδια κοινότητα εάν διαδραματίζουν τον ίδιο ρόλο, ο καθένας στο αντίστοιχο στρώμα και, δεδομένου ότι οι κόμβοι αντιπροσωπεύουν χρονοσειρές και οι συνδέσεις τους αντιστοιχούν σε στατιστικές σχέσεις, οι κόμβοι που ανήκουν στην ίδια κοινότητα έχουν παρόμοια πρότυπα κυκλοφορίας και ζήτησης. Επιπλέον, λόγω της ύπαρξης

κόμβων από διαφορετικά στρώματα στις ίδιες κοινότητες, μπορεί κανείς να υποθέσει ότι αναδεικνύονται όχι μόνο χωρικές, αλλά και χρονικές σχέσεις και πιο συγκεκριμένα, υποδεικνύεται η ύπαρξη σημαντικής στατιστικής συσχέτισης μεταξύ των κόμβων σε διαφορετικές ώρες της ημέρας, η οποία μπορεί να αποδοθεί σε παρόμοια πρότυπα κυκλοφορίας που εμφανίζονται στους συγκεκριμένους κόμβους κατά τις διαφορετικές ώρες της ημέρας, όπως η εμφάνιση συνθηκών συμφόρησης.

Ανάπτυξη μοντέλων πρόβλεψης και αποτελέσματα

Για την πραγματοποίηση προβλέψεων, αναπτύσσεται ένα μοντέλο για κάθε κόμβο και για κάθε ώρα της ημέρας για την πρόβλεψη της ζήτησης στον αντίστοιχο ανιχνευτή ή σταθμό, χρησιμοποιώντας ως χαρακτηριστικά εισόδου τις τελευταίες τιμές της ζήτησης των υπόλοιπων κόμβων που ανήκουν στην ίδια κοινότητα. Έτσι, ο αριθμός των χαρακτηριστικών εισόδου κάθε μοντέλου είναι ίσος με το μέγεθος της κοινότητας στην οποία ανήκει το ζητούμενο ζεύγος (κόμβος, ώρα) και η τιμή κάθε χαρακτηριστικού αντιστοιχεί στις μετρήσεις των προηγούμενων 24 ωρών. Τα παραπάνω δεδομένα αξιοποιούνται για την πρόβλεψη των κυκλοφοριακών συνθηκών ή της ζήτησης (για τους κόμβους των σταθμών του μετρό) με ορίζοντα πρόβλεψης 1 ώρα. Σε αυτό το κεφάλαιο, οι τιμές των μεταβλητών-στόχων δεν κατηγοριοποιούνται, αλλά προβλέπεται η ακριβής τιμή τους.

Στη συνέχεια, για κάθε ζεύγος κόμβου-χρόνου, ένα μοντέλο παλινδρόμησης Gradient Boosting αναπτύσσεται, το οποίο είναι ένα μοντέλο Μηχανικής Μάθησης με σημαντικά μικρότερη πολυπλοκότητα σε σχέση με τα Βαθιά Νευρωνικά Δίκτυα. Τα αποτελέσματα συγκρίνονται με ένα μοντέλο LSTM για κάθε ανιχνευτή και σταθμό μετρό, το οποίο εφαρμόζεται στα αρχικά δεδομένα, χωρίς να λαμβάνεται υπόψη η δομή του πολυεπίπεδου γράφου και ο εντοπισμός των κοινοτήτων.

Ο μέσος όρος των σφαλμάτων των μοντέλων που αναπτύχθηκαν με τις δύο παραπάνω στρατηγικές παρουσιάζεται στον **Πίνακα 3**. Παρατηρούμε ότι για το προτεινόμενο μοντέλο, επιτυγχάνεται μία ικανοποιητικά μικρή τιμή του Μέσου Απόλυτου Ποσοστιαίου Σφάλματος (MAPE) 9,5%, ενώ οι κόμβοι ανιχνευτών βρόχου προβλέπονται με μεγαλύτερη ακρίβεια σε σχέση με τους σταθμούς του μετρό. Επιπλέον, η προτεινόμενη αναπαράσταση και επιλογή των πιο σχετικών μεταβλητών εισόδου σε συνδυασμό με ένα απλούστερο μοντέλο οδηγούν σε σημαντικά καλύτερη απόδοση ως προς το σφάλμα πρόβλεψης σε σχέση με ένα μοντέλο υψηλότερων δυνατοτήτων και, θεωρητικά, πιο κατάλληλο για τη συγκεκριμένη εργασία.

Πίνακας 3. Σύγκριση μετρικών σφαλμάτων των μοντέλων

Metrics	Multiplex-Gradient Boosting		LSTM	
	Traffic	Transit	Traffic	Transit
MAE	91.28	30.81	133.14	52.02
MAPE	9.0%	11.3%	16.8%	23.0%
Overall MAPE	9.5%		18.8%	

Πρόβλεψη σε Επίπεδο Δικτύου

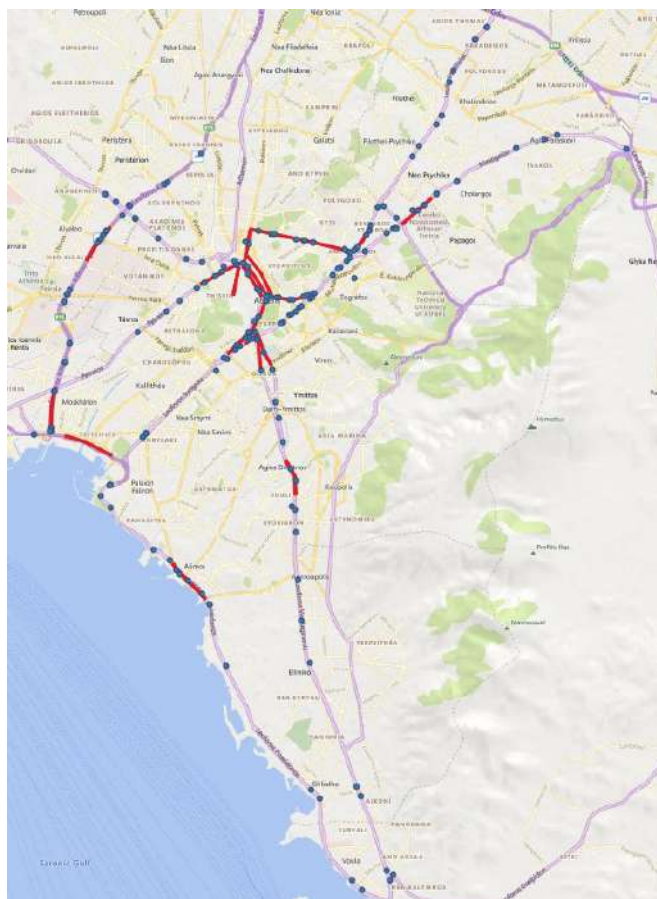
Τα μοντέλα που έχουν παρουσιαστεί μέχρι στιγμής, χρησιμοποιούν μεταβλητές εισόδου από θέσεις σε όλο το δίκτυο. Εκμεταλλευόμενα τις χωροχρονικές σχέσεις τους, παρέχουν προβλέψεις των μελλοντικών συνθηκών κυκλοφορίας σε συγκεκριμένες θέσεις-στόχους. Για κάθε θέση-στόχο απαιτείται ένα ξεχωριστό μοντέλο, με τις αντίστοιχες μεταβλητές εισόδου και τιμές υπερπαραμέτρων. Ένα μοντέλο πρόβλεψης που θα είναι σε θέση να παρέχει προβλέψεις για όλο το δίκτυο σε περιβάλλον πολλαπλών διεργασιών, δηλαδή να προβλέπει τις συνθήκες κυκλοφορίας σε όλες τις εξεταζόμενες θέσεις ταυτόχρονα, χρησιμοποιώντας μία ενιαία δομή και αξιοποιώντας περισσότερες από μία πηγές δεδομένων, που αντιστοιχούν σε κάθε θέση θα είχε πολύ σημαντικές επιπτώσεις στη διαχείριση της κυκλοφορίας, καθώς θα παρείχε όλες τις απαραίτητες πληροφορίες. Επιπλέον, για να είναι εφαρμόσιμο, το μοντέλο αυτό θα πρέπει να είναι ακριβές και ταυτόχρονα αποδοτικό, όσον αφορά τον χρόνο εκπαίδευσης και τις απαιτήσεις σε υπολογιστική ισχύ και δεδομένα, κάτι που δεν μπορεί να εξασφαλιστεί ακόμη ούτε για μοντέλα μίας θέσης.

Σε αυτήν την ενότητα, παρουσιάζεται μια από τις πρώτες προσπάθειες στη βιβλιογραφία για την ταυτόχρονη πρόβλεψη των χρόνων διαδρομής για τη διέλευση 30 σημαντικών οδικών τμημάτων γύρω από το κέντρο της Αθήνας, χρησιμοποιώντας ως δεδομένα εισόδου δεδομένα κυκλοφοριακού φόρτου από ανιχνευτές βρόχου. Για την αξιολόγηση των αποτελεσμάτων της πρόβλεψης, εκτός από τις κλασικές μετρικές σφάλματος, παρέχονται επεξηγήσεις των αποτελεσμάτων, με βάση την εκτίμηση των τιμών Shapley (ή SHAP).

Διαθέσιμα δεδομένα και Εφαρμογή

Για την ανάπτυξη του μοντέλου πρόβλεψης, συνδυάζονται τα δεδομένα κυκλοφοριακού φόρτου των ανιχνευτών βρόχου από την πόλη της Αθήνας με δεδομένα χρόνου ταξιδιού που ανακτήθηκαν από τη δημοφιλή υπηρεσία χαρτών και πλοήγησης Google Maps. Οι χρόνοι ταξιδιού αναφέρονται στο χρόνο (σε δευτερόλεπτα) για τη διέλευση 30 από τα πιο πολυσύχναστα και κρίσιμα οδικά τμήματα κατά τις πρωινές και απογευματινές ώρες αιχμής, δηλαδή από τις 8 π.μ. έως τις 10 π.μ. και από τις 12 μ.μ. έως τις 7 μ.μ., για κάθε ημέρα μεταξύ Ιουνίου και Δεκεμβρίου του 2021. Ο συνολικός αριθμός των καταγραφών είναι 1110. Οι φωρατές και οι διαδρομές που λήφθηκαν υπόψη φαίνονται στην **Εικόνα 4**.

Το μοντέλο πρόβλεψης που αξιοποιείται είναι ένα σχετικά ρηχό Νευρωνικό Δίκτυο με 3 κρυφά στρώματα. Η είσοδος του μοντέλου είναι οι ωριαίες μετρήσεις των επιλεγμένων ανιχνευτών βρόχων (μία μέτρηση ανά ανιχνευτή), ενώ η έξοδος περιλαμβάνει και τους 30 χρόνους διαδρομής που αντιστοιχούν στην επόμενη ώρα από αυτή των δεδομένων εισόδου. Παρόλο που το μοντέλο που χρησιμοποιείται είναι απλό σε σύγκριση με την πολυπλοκότητα του χώρου εξόδου, εκπαιδεύεται αποτελεσματικά και αναμένεται να έχει αρκετά καλές επιδόσεις. Εξάλλου, επιλέχθηκε να χρησιμοποιείται ως είσοδος μόνο η τελευταία μέτρηση κάθε ανιχνευτή βρόχου και όχι χρονοσειρές μετρήσεων, οι οποίες θα αύξαναν, χωρίς να είναι απαραίτητο, την πολυπλοκότητα.




Εικόνα 4. Τοποθεσίες φωρατών και διαδρομών

Το μοντέλο αποδίδει σε γενικές γραμμές ικανοποιητικά, επιτυγχάνοντας ένα μέσο Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (MAPE) 12,3%, ενώ υπάρχει ένας σημαντικός αριθμός διαδρομών των οποίων οι χρόνοι ταξιδιού προβλέπονται με MAPE μικρότερο από 9% (τεταρτημόριο 25%). Επιπλέον, οι υψηλότερες παρατηρούμενες τιμές MAPE είναι 20,4% και 19,4%, ενώ το τεταρτημόριο 75% του MAPE είναι 15,8%, το οποίο θεωρείται αποδεκτό. Η μέση τιμή του μέσου απόλυτου σφάλματος είναι 23,1 s/km. Τα σφάλματα πρόβλεψης για όλες τις διαδρομές παρουσιάζονται αναλυτικά στον **Πίνακα 4**.

Επιπλέον, από τον υπολογισμό των τιμών SHAP, παρατηρείται ένα σταθερό μοτίβο για τη σχέση μεταξύ των χρόνων διαδρομής και των φόρτων που καταγράφηκαν στους φωρατές: όταν παρατηρείται χαμηλή τιμή του κυκλοφοριακού φόρτου, η οποία υποδηλώνει συνθήκες συμφόρησης, η τιμή SHAP του χρόνου διαδρομής αυξάνεται σημαντικά, δηλαδή αναμένονται υψηλότεροι χρόνοι διαδρομής. Ειδικότερα για τις διαδρομές που βρίσκονται πιο κοντά στο κέντρο της πόλης (π.χ. Σταδίου και Βασ. Σοφίας) παρατηρούνται επίσης υψηλότερες τιμές SHAP γενικά, οι οποίες είναι επίσης ενδεικτικές της μεγαλύτερης διακύμανσης των χρόνων διαδρομής τους και της σημαντικότητας της επίδρασης της εμφάνισης συμφόρησης. Δύο ενδεικτικά παραδείγματα παρουσιάζονται στην **Εικόνα 5**.

Πίνακας 4. Αποτελέσματα πρόβλεψης χρόνων διαδρομών

Διαδρομή	MAPE	MAE
Panepistimiou (Vas. Sofias - Patision)	9.8%	19.8
Akadimias (Patision - Vas. Sofias)	11.3%	26.4
Stadiou (Aiolou - Vas. Georgiou)	15.9%	53.5
Athinas (Ermou - Stadiou)	9.4%	25.2
Athinas (Stadiou - Ermou)	8.6%	21.8
Vas. Sofias (Vas. Konstantinou - Panepistimiou)	19.4%	56.4
Vas. Amalias (Ath. Diakou - Panepistimiou)	17.0%	44.7
Patision (Alexandras - Stadiou)	8.3%	16.6
Pireos (Kolokinthous - Omonoia Sq.)	15.8%	51.3
Syngrou Av. (Vas. Amalias - Frantzi)	6.3%	9.1
Pireos (Kolokinthous - Iera Odo)	17.3%	41.5
Syngrou Av. (Frantzi - Vas. Amalias)	20.4%	44.8
Alexandras (Kifisias - Patision)	11.1%	21.7
Kallirois (Petmeza - Arditou)	10.3%	32.0
Patision (Ioulianiou - Chalkokondili)	9.2%	13.0
Patision (Stournari - Ioulianiou)	10.4%	22.9
Kifisias (Alexandras - Panormou)	16.0%	24.5
Kifisias (Panormou - Alexandras)	13.4%	21.7
Mesogion (Katechaki - Kiprou)	13.9%	16.1
Vouliagmenis (Arditou - Ilia Iliou)	12.9%	15.1
Vouliagmenis (Ag. Konstantinou - Pirronos)	4.9%	1.9
Vouliagmenis (Pirronos - Ag. Konstantinou)	5.8%	1.7
Ilioupoleos (Ilia Iliou - Arditou)	15.2%	32.2
Cephissus (Posidonos - Pireos)	15.0%	11.7
Cephissus (Pireos - Posidonos)	13.7%	6.3
Cephissus (Athinon - Moudrou)	8.0%	1.3
Cephissus (Moudrou - Athinon)	17.3%	24.7
Posidonos (Niarchos - Cephissus)	5.7%	0.4
Posidonos (Amfitheas - Alimou)	13.8%	14.4
Posidonos (Alimou - Amfitheas)	14.0%	21.0
Μέσος όρος	12.3	23.1



Εικόνα 5. Τιμές SHAP ενδεικτικών διαδρομών.

Λαμβάνοντας υπόψη την αυξημένη αποδοτικότητα ενός μοντέλου που μπορεί να παρέχει έγκυρες προβλέψεις σε όλο το δίκτυο, η σημασία του στην προγνωστική διαχείριση της κυκλοφορίας και στη λήψη αποφάσεων είναι μεγάλη και η έλλειψη παρόμοιων προσεγγίσεων είχε προηγουμένως επισημανθεί ως μία από τις κύριες ανοικτές προκλήσεις για την ανάπτυξη μοντέλων που μπορούν να χρησιμοποιηθούν σε πραγματικές συνθήκες. Τα αποτελέσματα δείχνουν επίσης ότι υπάρχουν σημαντικές βραχυπρόθεσμες και μακροπρόθεσμες σχέσεις μεταξύ των κυκλοφοριακών συνθηκών και των χρόνων διαδρομής των επιλεγμένων διαδρομών- έτσι, μια προσέγγιση μάθησης πολλαπλών διεργασιών, όπως αυτή που παρουσιάζεται, μπορεί να τις εκμεταλλευτεί αποτελεσματικά και αποδοτικά.

Αιτιώδης Βαθιά Μάθηση για Βραχυπρόθεσμη Πρόβλεψη της Κυκλοφορίας

Η μέθοδος της θεωρίας της πληροφορίας (αμοιβαία πληροφορία), καθώς και οι άλλες στατιστικές μέθοδοι που χρησιμοποιήθηκαν σε προηγούμενες ενότητες για την ανίχνευση χωροχρονικών σχέσεων μεταξύ των θέσεων του οδικού δικτύου, παρουσιάζουν ένα σοβαρό μειονέκτημα: υπονοούν την ύπαρξη μιας στατιστικής σχέσης, η οποία μπορεί να είναι σημαντική, αλλά δεν εγγυάται την αιτιότητα. Κατά συνέπεια, οι σχέσεις που ανιχνεύονται μπορεί να αφορούν αποκλειστικά το συγκεκριμένο σύνολο δεδομένων, δηλαδή δεν είναι γενικεύσιμες και πιθανόν να μην ισχύουν για ακραίες συνθήκες ή/και μελλοντικά δεδομένα. Ως εκ τούτου, περιορίζουν την αξιοπιστία και την επεξηγησιμότητα του μοντέλου.

Στην παρούσα ενότητα, παρουσιάζεται ένα πλαίσιο για τον προσδιορισμό της αιτιώδους δομής ενός συνόλου κυκλοφοριακών δεδομένων που αποτελείται από μετρήσεις σε διαφορετικές θέσεις του οδικού δικτύου, το οποίο μπορεί επίσης να εφαρμοστεί σε άλλα προβλήματα χρονοσειρών, με βάση το νευρωνικό μοντέλο Granger (Neural Granger). Αξιοποιούνται δεδομένα κυκλοφοριακού φόρτου από περισσότερους από 300 φωρατές που είναι εγκατεστημένοι στο οδικό δίκτυο της Αθήνας και το προτεινόμενο πλαίσιο εφαρμόζεται τόσο για την εξήγηση των αποτελεσμάτων του μοντέλου όσο και για την επιλογή χαρακτηριστικών. Στη συνέχεια, αναπτύσσεται ένα μάλλον απλό μοντέλο Νευρωνικού Δικτύου Μακράς Βραχυπρόθεσμης Μνήμης (LSTM) για την πρόβλεψη των κυκλοφοριακών συνθηκών σε πολλές σημαντικές τοποθεσίες και, αξιοποιώντας τα αποτελέσματα του πλαισίου, επιτυγχάνει πολύ ικανοποιητικές επιδόσεις.

Νευρωνικό Μοντέλο Αιτιότητας Granger

Προκειμένου να ξεπεραστούν οι αδυναμίες της κλασικής προσέγγισης και κυρίως η παραδοχή της γραμμικής σχέσης, αναπτύσσουμε ένα νευρωνικό δίκτυο και συγκεκριμένα ένα LSTM για την προσομοίωση της σχέσης μεταξύ των μεταβλητών εισόδου και εξόδου, με βάση τις αρχές του Νευρωνικού Μοντέλου Granger.

Το μοντέλο εκπαιδεύεται με την ακόλουθη συνάρτηση απωλειών:

$$\frac{1}{N} \sum (x_t - h(x_{i,<t}))^2 + \lambda \sum_{i=1}^n \|W_i^1\| \quad (IV)$$

Ο πρώτος όρος είναι το μέσο τετραγωνικό σφάλμα της εκτίμησης του Granger LSTM, ενώ ο δεύτερος είναι το άθροισμα των βαρών εισόδου (βάρος του στρώματος εισόδου) που συνδέονται με κάθε χρονοσειρά του χώρου εισόδου. Η παράμετρος λ παίζει τον ίδιο ρόλο όπως

και στην κλασική, γραμμική προσέγγιση, δηλαδή ελέγχει τη σημαντικότητα του δεύτερου όρου. Αντίστοιχα, όταν μια χρονοσειρά δεν έχει σημαντική συνεισφορά στον πρώτο όρο (δηλαδή δεν μειώνει σημαντικά το σφάλμα εκτίμησης), το βάρος εισόδου της συρρικνώνεται στο μηδέν (δεύτερος όρος) και δεν εισέρχεται στο μοντέλο. Στο τέλος της διαδικασίας εκπαίδευσης, οι χρονοσειρές με μη μηδενικά βάρη εισόδου θεωρείται ότι προκαλούν κατά Granger την έξοδο.

Υλοποίηση

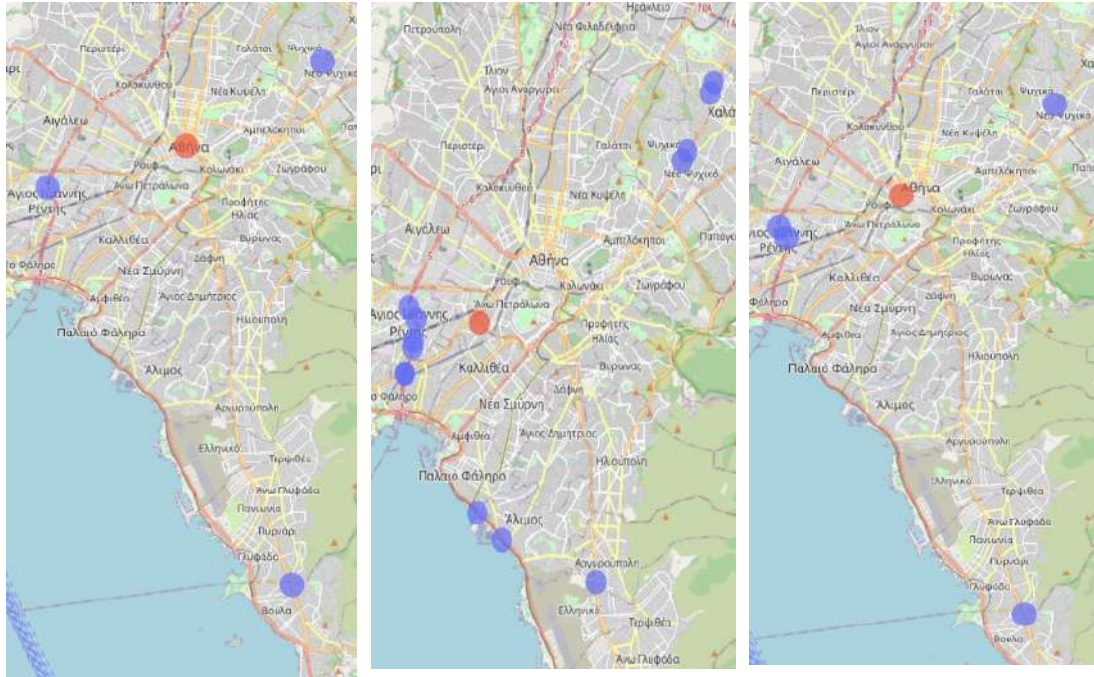
Στην προτεινόμενη προσέγγισή, αρχικά αξιοποιείται το νευρωνικό μοντέλο αιτιότητας Granger για να κατασκευαστεί ο γράφος αιτιότητας του οδικού δικτύου της Αθήνας, ο οποίος αποτελείται από περισσότερες από 330 θέσεις/φωρατές που είναι εγκατεστημένοι σε ολόκληρο το οδικό δίκτυο. Το Neural Granger, υλοποιημένο ως δίκτυο LSTM, επιλέχθηκε ως η καταλληλότερη μέθοδος για να χειριστεί ένα τόσο μεγάλο δίκτυο με πολύπλοκες εξαρτήσεις μεταξύ των θέσεων. Κατά συνέπεια, αναπτύσσεται ένα μικρότερο και απλούστερο δίκτυο LSTM για την εκτέλεση του έργου πρόβλεψης, το οποίο αναφέρεται επίσης ως "Αραιό LSTM", καθώς ο χώρος εισόδου του περιλαμβάνει μόνο τις χρονοσειρές που βρέθηκαν να προκαλούν κατά Granger τη χρονοσειρά-στόχο κατά το πρώτο βήμα του προτεινόμενου πλαισίου. Θα πρέπει να καταστεί σαφές ότι για κάθε θέση-στόχο θα πρέπει να αναπτυχθούν ένα Granger LSTM και ένα Sparse LSTM. Η βάση δεδομένων που χρησιμοποιήθηκε είναι αυτή με χρονική ανάλυση μίας ώρας που παρουσιάστηκε και σε προηγούμενα κεφάλαια.

Εντοπισμός αιτιωδών σχέσεων

Η εκπαίδευση του Neural Granger LSTM καταλήγει στον αιτιώδη γράφο του οδικού δικτύου, δηλαδή σε ένα σύνολο εντοπισμένων αιτιωδών σχέσεων. Κατά μέσο όρο, ένα μικρό τμήμα του οδικού δικτύου, περίπου το 7,3% των χρονοσειρών (περίπου 25 θέσεις), βρέθηκε να προκαλεί κατά Granger κάθε χρονοσειρά-στόχο. Το παραπάνω εύρημα δείχνει ότι σε ένα τόσο μεγάλο οδικό δίκτυο, θα πρέπει να καταβληθεί σοβαρή προσπάθεια στην επιλογή χαρακτηριστικών, καθώς οι πραγματικές αιτιώδεις σχέσεις είναι πολύ λίγες και η διαστατικότητα του χώρου εισόδου μπορεί να μειωθεί δραματικά, χωρίς να θυσιαστεί η απόδοση πρόβλεψης του μοντέλου.

Στην **Εικόνα 6** παρουσιάζονται ενδεικτικά οι περιοχές του δικτύου που βρέθηκε ότι προκαλούν κατά Granger κάποια σημεία στο κέντρο της πόλης.

Ενδιαφέρον παρουσιάζει το γεγονός ότι παρατηρούμε ένα πολύ ισχυρό, κοινό μοτίβο για όλες τις θέσεις-στόχους: οι ανιχνευτές βρόχων που βρίσκονται στο κέντρο της πόλης προκαλούνται κατά Granger από ανιχνευτές που βρίσκονται σε σημαντικά τμήματα του οδικού δικτύου στην περίμετρο της πόλης της Αθήνας, που λειτουργούν ως εισοδοί στο κέντρο της πόλης και, ως επί το πλείστον, όχι πολύ κοντά στο κέντρο της πόλης. Επιπλέον, ένα άλλο σημαντικό εύρημα είναι ότι υπάρχουν λίγοι (3 ή 4) συγκεκριμένοι ανιχνευτές βρόχων που προκαλούν κατά Granger σχεδόν όλους τους ανιχνευτές βρόχων του κέντρου της πόλης- αποδεικνύεται ότι οι τελευταίοι ανιχνευτές μπορούν να παρέχουν ζωτικής σημασίας πληροφορίες σχετικά με τις μελλοντικές κυκλοφοριακές συνθήκες στο κέντρο της πόλης, οπότε οι αρχές διαχείρισης της κυκλοφορίας και άλλοι επαγγελματίες θα πρέπει πάντα να λαμβάνουν υπόψη τις μετρήσεις τους για σκοπούς πρόβλεψης και λήψης αποφάσεων. Τέλος, μπορεί κανείς να παρατηρήσει ότι οι αιτιώδεις σχέσεις που εντοπίστηκαν είναι μεταξύ των ανιχνευτών βρόχων-στόχων και άλλων ανιχνευτών που δεν βρίσκονται πολύ κοντά σε αυτούς.



Εικόνα 6. Περιοχές που προκαλούν κατά Granger τις περιοχές-στόχους

Αποτελέσματα πρόβλεψης

Για την αξιολόγηση της ακρίβειας του προτεινόμενου Αραιού LSTM για κάθε τοποθεσία, πραγματοποιούνται συγκρίσεις με βάση ένα δίκτυο LSTM που λαμβάνει ως είσοδο τη χρονοσειρά μόνο από την τοποθεσία-στόχο (Single-point LSTM) και ένα δίκτυο LSTM που λαμβάνει είσοδο από όλες τις τοποθεσίες (Inclusive LSTM), όσον αφορά την ακρίβεια πρόβλεψης και την υπολογιστική αποδοτικότητα. Πιο συγκεκριμένα, για κάθε ένα από τα 334 μοντέλα μετρήθηκαν οι τιμές MAPE και ο χρόνος εκπαίδευσης.

Όπως φαίνεται ξεκάθαρα στον **Πίνακα 5**, τα προτεινόμενα αραιά μοντέλα, εκμεταλλευόμενα τη στρατηγική επιλογής χαρακτηριστικών που εφαρμόζεται με βάση την ανίχνευση αιτιώδους δομής, επιτυγχάνουν καλύτερη επίδοση πρόβλεψης από τα δύο άλλα, ενώ είναι σημαντικά πιο αποδοτικά από το Inclusive μοντέλο, καθώς η αρχιτεκτονική τους είναι πιο απλή, λόγω της μειωμένης διαστατικότητας του χώρου εισόδου.

Πίνακας 5. Αξιολόγηση μοντέλων πρόβλεψης (μέση τιμή όλων των τοποθεσιών)

Model	Average MAPE (and deviation)	Efficiency (time to train per model)
Inclusive LSTM	12.6% ± 3.1%	104s
Single-point LSTM	13.3% ± 3.7%	27s
Sparse LSTM	9.1% ± 1.8%	46s

Ένα θεωρητικά ενημερωμένο, πολυμεταβλητό, αιτιώδες πλαίσιο για βραχυπρόθεσμες προβλέψεις κυκλοφορίας

Σε αυτή την ενότητα, ενσωματώνονται πρόσθετες πτυχές που σχετίζονται με τη θεωρία της ροής της κυκλοφορίας και προτείνεται μια ολιστική προσέγγιση (από την προεπεξεργασία των δεδομένων έως την εκπαίδευση και την αξιολόγηση των μοντέλων) για ένα πλαίσιο πρόβλεψης της κυκλοφορίας που βασίζεται στη θεωρία, είναι αιτιώδες και πολυμεταβλητό, με στόχο να είναι επίσης εφαρμόσιμο. Στον πυρήνα της προτεινόμενης μεθοδολογίας, υπάρχει ένα καινοτόμο νευρωνικό δίκτυο πολλαπλών διεργασιών που βασίζεται στη θεωρία της κυκλοφοριακής ροής, το οποίο χρησιμοποιείται για την από κοινού βραχυπρόθεσμη πρόβλεψη δύο μεταβλητών της κυκλοφορίας (κυκλοφοριακός φόρτος και ταχύτητα), οι οποίες συνιστούν μια κατάσταση κυκλοφορίας. Για την εκπαίδευση του μοντέλου, προτείνεται μια προσαρμοσμένη συνάρτηση απωλειών, η οποία ενσωματώνει την απόσταση της προκύπτουσας πολυμεταβλητής πρόβλεψης (ζεύγη κυκλοφοριακών μεταβλητών) από το πραγματικό θεμελιώδες διάγραμμα της αντίστοιχης θέσης. Για να ενισχυθεί η απόδοση και η ερμηνευσιμότητα του μοντέλου, επιλέγονται πληροφορίες εισόδου κυκλοφορίας σε επίπεδο δικτύου από τις πιο σχετικές θέσεις, χρησιμοποιώντας το νευρωνικό μοντέλο Granger. Για τα πειράματα που παρουσιάζονται στην παρούσα εργασία, αναπτύσσεται ένα δίκτυο Μακράς Βραχυπρόθεσμης Μνήμης (LSTM), ωστόσο, ολόκληρη η μεθοδολογία (συμπεριλαμβανομένης της συνάρτησης απωλειών) είναι συμβατή με οποιαδήποτε δομή βαθιάς μάθησης. Ολόκληρη η μεθοδολογία εφαρμόζεται σε δεδομένα υψηλής ανάλυσης που προέρχονται από το οδικό δίκτυο της Αθήνας.

Συνάρτηση απωλειών με βάση τη θεωρία ροής κυκλοφορίας

Η εκπαίδευση ενός μοντέλου βαθιάς μάθησης είναι ένα πρόβλημα βελτιστοποίησης που αποσκοπεί στον προσδιορισμό των βέλτιστων τιμών των βαρών του για την ελαχιστοποίηση μιας συνάρτησης απωλειών, όπως το μέσο τετραγωνικό σφάλμα (MSE) ή το μέσο τετραγωνικό σφάλμα (RMSE). Λαμβάνοντας υπόψη την περίπτωση της κοινής πρόβλεψης κυκλοφοριακού φόρτου και ταχύτητας, σε μια διάταξη μοντελοποίησης πολλαπλών διεργασιών, η πιο δημοφιλής προσέγγιση θα ήταν η εκτίμηση μιας τιμής απώλειας (μετρική σφάλματος) για κάθε μία από τις προβλέψεις φόρτου και ταχύτητας σε κάθε εποχή εκπαίδευσης. Όσο χαμηλότερη είναι η απώλεια τόσο καλύτερες είναι οι επιμέρους προβλέψεις. Ωστόσο, εκτός από μια χαμηλή τιμή σφάλματος, θα πρέπει να περιμένουμε ότι όλα τα προβλεπόμενα ζεύγη τιμών θα πρέπει να βρίσκονται κοντά στην αντίστοιχη θεμελιώδη καμπύλη ταχύτητας-φόρτου. Το τελευταίο δεν εξασφαλίζεται από μια χαμηλή τιμή σφάλματος- στην πραγματικότητα, μια αξιοπρεπής ατομική μέση τιμή σφάλματος για κάθε μεταβλητή μπορεί να καλύπτει ζητήματα όπως τα προαναφερθέντα.

Για να ληφθούν υπόψη οι παραπάνω προκλήσεις, προτείνεται η συνάρτηση απώλειας με βάση τη θεωρία ροής κυκλοφορίας (Traffic flow theory-informed loss function - TFTI loss), η οποία συνδυάζει το MSE των δύο επιμέρους μεταβλητών με την απόσταση της πρόβλεψης από το πλησιέστερο σημείο στο εκτιμώμενο θεμελιώδες διάγραμμα. Το τελευταίο ορίζεται για κάθε θέση/τμήμα του οδικού δικτύου που παρακολουθείται και μπορεί να έχει συγκεκριμένη συναρτησιακή μορφή. Έστω $\hat{y}_i = (\hat{v}_i, \hat{s}_i)$ η πρόβλεψη για ένα πραγματικό ζεύγος $y_i = (v_i, s_i)$ και $g_j = (v_j^e, s_j^e)$ το πλησιέστερο σημείο στο εκτιμώμενο θεμελιώδες διάγραμμα που χαρακτηρίζει τη θέση ενδιαφέροντος, η απώλεια TFTI ορίζεται ως εξής:

$$TFTI\ loss = a * \frac{1}{2} \sqrt{[MSE_v + MSE_s]} + (1 - a) * d(\hat{y}_i, g_j) \quad (V)$$

όπου MSE_v , MSE_s είναι το μέσο τετραγωνικό σφάλμα των προβλέψεων του όγκου και της ταχύτητας αντίστοιχα, $d(\hat{y}_i, g_j)$ είναι η ευκλείδεια απόσταση των προβλεπόμενων ζευγών και του πλησιέστερου σημείου του θεμελιώδους διαγράμματος στην αντίστοιχη πραγματική τιμή. Ο παράγοντας a ελέγχει τη σημασία του δεύτερου παράγοντα έναντι του πρώτου, $a \in [0,1]$.

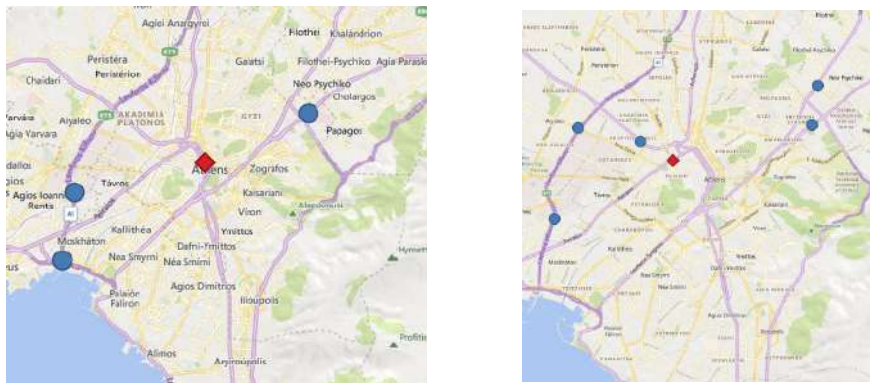
Διαθέσιμα δεδομένα και διάταξη μοντελοποίησης

Για τους σκοπούς της παρούσας εργασίας, τέθηκαν στη διάθεσή μας μετρήσεις από 420 φωρατές του δικτύου της Αθήνας, οι οποίες αποτελούνται από τον κυκλοφοριακό φόρτο (οχήματα/ώρα), τη μέση ταχύτητα (km/h) και την κατάληψη (%). Η χρονική ανάλυση των δεδομένων είναι 6 λεπτά, δηλαδή τα δεδομένα που ανιχνεύονται συναθροίζονται σε διαστήματα των 6 λεπτών, συνεπώς είναι κατάλληλα για βραχυπρόθεσμες προβλέψεις. Τα δεδομένα αφορούν 40 ημέρες μετρήσεων, μεταξύ 20 Μαρτίου και 30 Απριλίου 2023.

Είναι σημαντικό να τονιστεί ότι η συνάρτηση απωλειών που βασίζεται στη θεωρία της κυκλοφοριακής ροής, καθώς και ολόκληρο το πλαίσιο που παρουσιάζεται σε αυτή την ενότητα, είναι συμβατά με οποιοδήποτε μοντέλο βαθιάς μάθησης. Στην παρούσα εργασία, προτιμήθηκε να χρησιμοποιηθεί μια μάλλον απλή αρχιτεκτονική, δηλαδή ένα δίκτυο LSTM, για να τονιστεί ότι το προτεινόμενο πλαίσιο μπορεί να επιτύχει κορυφαίες επιδόσεις ακόμη και όταν χρησιμοποιείται μια απλούστερη δομή. Οι δύο προσεγγίσεις που συγκρίνονται είναι η εκπαίδευση του μοντέλου με (i) απλό σφάλμα MSE και (ii) την προτεινόμενη συνάρτηση απωλειών TFTI, με παράμετρο $a=0,7$. Εκτός από τη συνάρτηση απωλειών, τα δύο μοντέλα είναι απολύτως όμοια μεταξύ τους.

Εντοπισμός αιτιωδών συσχετίσεων

Μετά την εφαρμογή της μεθόδου νευρωνικού Granger στο διαθέσιμο σύνολο δεδομένων, προέκυψαν οι τοποθεσίες που προκαλούν κατά Granger τις τοποθεσίες-στόχους. Ο μέσος αριθμός των εντοπισμένων θέσεων ήταν 6,6 από τις 420 θέσεις, γεγονός που δείχνει ότι η διαστατικότητα του χώρου εισόδου για κάθε μοντέλο πρόβλεψης μπορεί να μειωθεί κατά πολύ, χωρίς ωστόσο να χαθούν σημαντικές πληροφορίες. Οι τοποθεσίες που βρέθηκαν να προκαλούν κατά Granger κάποιες ενδεικτικές τοποθεσίες-στόχους παρουσιάζονται στην **Εικόνα 7**.



Εικόνα 7. Θέσεις (μπλε) που προκαλούν κατά Granger τις θέσεις-στόχους (κόκκινο)

Αποτελέσματα και Ανάλυση Αξιοπιστίας

Στον Πίνακα 6 παρουσιάζονται το μέσο απόλυτο σφάλμα (MAE) και το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE) των προβλέψεων για τις δύο συναρτήσεις απωλειών συνολικά και για κάθε μεταβλητή ξεχωριστά για ορισμένες ενδεικτικές θέσεις στόχων.

Πίνακας 6. Σύγκριση αποτελεσμάτων πρόβλεψης

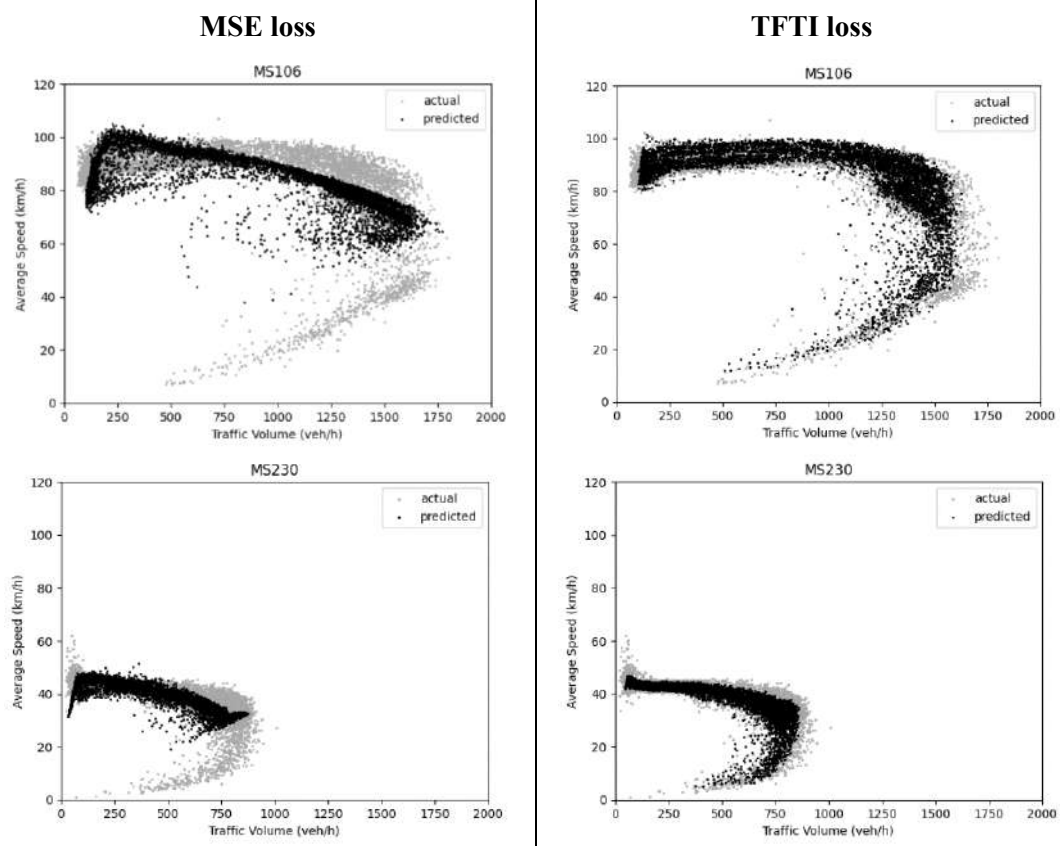
	<i>MSE</i> <i>loss</i>	<i>TFTI</i> <i>loss</i>	<i>MSE</i> <i>loss</i>	<i>TFTI</i> <i>loss</i>
<i>Location</i>	MS106		MS230	
<i>Volume MAE</i>	40.6	62.3	35.4	39.5
<i>Volume MAPE</i>	6.8%	9.1%	9.2%	10.5%
<i>Speed MAE</i>	8.0	3.3	3.9	2.1
<i>Speed MAPE</i>	17.3%	6.4%	23.0%	9.4%
<i>Overall MAPE</i>	12.0%	7.8%	15.6%	9.9%
<i>Location</i>	MS443		MS634	
<i>Volume MAE</i>	40.4	49.2	29.5	31.0
<i>Volume MAPE</i>	9.6%	13.0%	8.6%	9.7%
<i>Speed MAE</i>	4.3	2.8	3.2	1.8
<i>Speed MAPE</i>	17.0%	9.3%	11.1%	6.7%
<i>Overall MAPE</i>	13.3%	11.1%	9.8%	8.2%

Όπως μπορεί κανείς να παρατηρήσει, η TFTI συνάρτηση απωλειών βοηθά το μοντέλο να επιτύχει χαμηλότερο συνολικό σφάλμα για τις εξεταζόμενες τοποθεσίες. Το μέσο MAPE για την απώλεια TFTI είναι 10,9%, έναντι 13,0% για την απώλεια MSE για τις 12 θέσεις-στόχους. Το τελευταίο οφείλεται κυρίως στο γεγονός ότι το μοντέλο με την απώλεια MSE αποτυγχάνει σχεδόν σε όλες τις περιπτώσεις να προβλέψει με ακρίβεια τις τιμές της ταχύτητας, αν και αποδίδει ικανοποιητικά στην πρόβλεψη του φόρτου κυκλοφορίας. Μια πιθανή εξήγηση γι' αυτό είναι ότι το σύνολο δεδομένων είναι ιδιαίτερα ανισοβαρές, δηλαδή τα περισσότερα σημεία ανήκουν στον κλάδο χωρίς κυκλοφοριακή συμφόρηση, γεγονός που προσθέτει μεροληψία στο μοντέλο ως προς την πρόβλεψη υψηλότερων τιμών ταχύτητας. Από την άλλη πλευρά, η TFTI loss ενσωματώνει την πληροφορία σχετικά με τον κλάδο στον οποίο θα έπρεπε να ανήκει το σημείο (δηλαδή την απόσταση από το θεμελιώδες διάγραμμα) και διατηρεί μια αξιοπρεπή απόδοση και για τον συμφορημένο κλάδο.

Ένας απλός, αλλά ακριβής ορισμός ενός αξιόπιστου μοντέλου είναι ότι πρόκειται για ένα μοντέλο που διατηρεί μια σωστή συμπεριφορά που συνάδει με τα δεδομένα εκπαίδευσης και, γενικά, με την κατανόηση των ειδικών του αντικειμένου για τους παράγοντες που επηρεάζουν

το αποτέλεσμα των προβλέψεων. Ως εκ τούτου, καθίσταται σαφές ότι ένα ακριβές μοντέλο δεν είναι πάντα αξιόπιστο.

Για να εξετάσουμε την αξιοπιστία του μοντέλου, παραθέτουμε τα θεμελιώδη διαγράμματα που προκύπτουν από τις προβλέψεις σε σύγκριση με το πραγματικό διάγραμμα ενδεικτικών θέσεων στην **Εικόνα 8**. Τα γραφήματα δείχνουν ότι οι προβλέψεις που γίνονται από τα μοντέλα που εκπαιδεύονται με την TFTI loss είναι πιο αξιόπιστες, καθώς η κατανομή των σημείων πρόβλεψης είναι πιο κοντά στην πραγματική και στο αντίστοιχο θεμελιώδες διάγραμμα, ενώ τα μοντέλα με την MSE αποτυγχάνουν συστηματικά να προβλέψουν τον κλάδο συμφόρησης. Επιπλέον, η TFTI είναι λιγότερο ευάλωτη σε θορυβώδη δεδομένα και ακραίες τιμές, π.χ. σημεία που βρίσκονται μεταξύ των δύο κλάδων του αναμενόμενου θεμελιώδους διαγράμματος.



Εικόνα 8. Προβλεπόμενα θεμελιώδη διαγράμματα σε σχέση με τα πραγματικά για την MSE (αριστερά) και την TFTI (δεξιά)

Τέλος, γίνεται εκτίμηση της ακρίβειας των μοντέλων στην πρόβλεψη της σωστής κατηγορίας συνθηκών, ανεξάρτητα από τις ακριβείς τιμές των μεταβλητών. Δεδομένου ότι οι συνθήκες συμφόρησης αντιπροσωπεύουν περίπου το 11% του συνόλου δεδομένων, ο αντίκτυπος των λανθασμένα ταξινομημένων συνθηκών συμφόρησης δεν είναι τόσο σημαντικός στη συνολική ακρίβεια. Έτσι, εκτιμούμε επιπλέον το συνολικό F1-score και το F1-score της κλάσης με συμφόρηση. Οι αντίστοιχες μέσες τιμές για όλες τις θέσεις-στόχους είναι για την MSE: Ακρίβεια = 0,92, F1-score (συμφορημένη κλάση) = 0,43, Overall F1-score = 0,69, ενώ για την TFTI: Ακρίβεια = 0,96, F1-score (κλάση συμφόρησης) = 0,74, Overall F1-score = 0,86. Εμφανώς, τα μοντέλα που εκπαιδεύονται με την TFTI loss παρέχουν βελτιωμένη απόδοση σε

σύγκριση με εκείνα που εκπαιδεύονται με την MSE. Συγκεκριμένα, όσον αφορά τα αποτελέσματα F1, υπερέχουν σημαντικά, ειδικά για την κλάση συμφόρησης. Λαμβάνοντας υπόψη όλα τα παραπάνω, τα μοντέλα που εκπαιδεύτηκαν με την συνάρτηση απωλειών TFTI φαίνεται να είναι πιο αξιόπιστα, εκτός από πιο ακριβή.

Συμπεράσματα

Γενικά

Στην παρούσα διατριβή, παρουσιάστηκε μια εργαλειοθήκη εφαρμόσιμων μεθόδων και τεχνικών για την εκτέλεση διαφορετικών εργασιών πρόβλεψης, και συγκεκριμένα πολυτροπικές προβλέψεις, προβλέψεις πολλαπλών εργασιών σε όλο το δίκτυο, προβλέψεις με βάση τη θεωρία κυκλοφορίας, ανίχνευση στατιστικών και αιτιωδών σχέσεων, καθώς και ένα πλαίσιο για την αξιολόγηση της αξιοπιστίας των προβλέψεων. Εκτός από τις διαφορετικές χωρικές κλίμακες, οι προτεινόμενες δομές μπορούν να αξιοποιηθούν για διαφορετικούς χρονικούς ορίζοντες πρόβλεψης (βραχυπρόθεσμες και μακροπρόθεσμες προβλέψεις), χρησιμοποιώντας δεδομένα υψηλότερης ή χαμηλότερης ανάλυσης. Επιπλέον, διαπιστώθηκε ότι, χρησιμοποιώντας τις παραπάνω μεθόδους, μπορεί κανείς να επιτύχει κορυφαίες επιδόσεις πρόβλεψης, ακόμη και με σχετικά απλές αρχιτεκτονικές μοντελοποίησης, αν και το όλο πλαίσιο είναι συμβατό με οποιοδήποτε μοντέλο Βαθιάς Μάθησης. Έτσι, μια αρμόδια για τη διαχείριση της κυκλοφορίας αρχή, εξοπλισμένη με την παραπάνω εργαλειοθήκη, θα είναι σε θέση να εφαρμόσει προγνωστική διαχείριση της κυκλοφορίας, προγραμματισμό και λήψη αποφάσεων για τον χειρισμό σχεδόν οποιασδήποτε κατάστασης σε επίπεδο πόλης και υπό οποιεσδήποτε συνθήκες.

Συνεισφορά και καινοτομία

Η κύρια συνεισφορά της παρούσας εργασίας είναι ένα νέο πλαίσιο πολλαπλών διεργασιών που βασίζεται στη θεωρία της κυκλοφοριακής ροής, το οποίο χρησιμοποιείται για την από κοινού βραχυπρόθεσμη πρόβλεψη δύο μεταβλητών κυκλοφορίας. Επιπλέον, προτείνεται μια νέα προσέγγιση για τον συνδυασμό πολυτροπικών δεδομένων (οδικής κυκλοφορίας και ζήτησης δημόσιων μεταφορών), ώστε να αυξηθεί η προβλεψιμότητα των μελλοντικών τιμών και των δύο μέσων και συγκεκριμένα, μια καινοτόμος αναπαράσταση του οδικού δικτύου και των δεδομένων εισόδου για πολυτροπικές διατάξεις, βασισμένη στην έννοια των πολυεπίπεδων δικτύων (Multiplex Networks) από την ερευνητική περιοχή της ανάλυσης κοινωνικών δικτύων, η οποία αξιοποιείται για πρώτη φορά στην πρόβλεψη της κυκλοφορίας.

Ακόμη, παρουσιάστηκε μια από τις πρώτες προσπάθειες για πρόβλεψη σε όλο το δίκτυο, με την έννοια ότι, όχι μόνο η είσοδος του μοντέλου περιλαμβάνει πληροφορίες από πολλές ή όλες τις θέσεις του οδικού δικτύου, αλλά επίσης, και το πιο σημαντικό, η έξοδος του αναφέρεται επίσης σε όλες τις θέσεις, οι οποίες προβλέπονται ταυτόχρονα με τη χρήση ενός ενιαίου μοντέλου, με βάση την έννοια της πολυδιεργασιακής μάθησης (Multitask Learning).

Μια άλλη σημαντική συνεισφορά της παρούσας εργασίας είναι ότι προτείνεται ένα νέο πλαίσιο αξιολόγησης που αξιολογεί την αξιοπιστία και την ανθεκτικότητα του μοντέλου σε θορυβώδη και ανισοβαρή δεδομένα. Τέλος, το πλαίσιο που αναπτύχθηκε είναι σχεδιασμένο ώστε να μην βασίζεται υπερβολικά σε πολύπλοκες δομές Βαθιάς Μάθησης, ενώ παράλληλα επιτυγχάνει ικανοποιητική επίδοση.

Περιορισμοί και μελλοντική έρευνα

Οι σημαντικότεροι περιορισμοί της παρούσας εργασίας σχετίζονται με την σχετικά περιορισμένη διαθεσιμότητα κυκλοφοριακών δεδομένων υψηλής χρονικής συχνότητας, καθώς και δεδομένων χρόνων διαδρομής και ζήτησης Μέσων Μαζικής Μεταφοράς που δεν επέτρεψαν την ανάπτυξη αντίστοιχων μοντέλων βραχυπρόθεσμων προβλέψεων.

Η μελλοντική έρευνα θα περιλαμβάνει τη χρήση πιο σύνθετων αρχιτεκτονικών Βαθιάς Μάθησης, ώστε να εξεταστεί η περεταίρω βελτίωση της ακρίβειας των μοντέλων. Επίσης θα αξιολογηθεί η δυνατότητα μεταφοράς των εκπαιδευμένων μοντέλων σε άλλα δίκτυα ή σε άλλα σημεία του ίδιου δικτύου. Τέλος, θα επιχειρηθεί ο συνδυασμός των σημαντικότερων εργαλείων που αναπτύχθηκαν για τη δημιουργία ενός πολυτροπικού και βασισμένου στη θεωρία πλαισίου που θα παρέχει προβλέψεις για όλο το δίκτυο.