



Εθνικό Μετσόβιο Πολυτεχνείο  
Σχολή Ηλεκτρολόγων Μηχανικών  
και Μηχανικών Υπολογιστών  
Τομέας Τεχνολογίας Πληροφορικής και  
Υπολογιστών

## **Πρόβλεψη κυκλοφοριακής ροής αυτοκινήτων με χρήση επαναληπτικών νευρωνικών δικτύων**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**ΑΓΓΕΛΟΣ Λ. ΚΟΛΑΪΤΗΣ**

**Επιβλέπων :** Ανδρέας-Γεώργιος Σταφυλοπάτης  
Καθηγητής Ε.Μ.Π.

**Συνεπιβλέπων :** Γεώργιος Αλεξανδρίδης  
Εργαστηριακό και Διδακτικό Προσωπικό Ε.Μ.Π.

Αθήνα, Οκτώβριος 2020





Εθνικό Μετσόβιο Πολυτεχνείο  
Σχολή Ηλεκτρολόγων Μηχανικών  
και Μηχανικών Υπολογιστών  
Τομέας Τεχνολογίας Πληροφορικής και  
Υπολογιστών

## Πρόβλεψη κυκλοφοριακής ροής αυτοκινήτων με χρήση επαναληπτικών νευρωνικών δικτύων

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**ΑΓΓΕΛΟΣ Λ. ΚΟΛΑΪΤΗΣ**

**Επιβλέπων :** Ανδρέας-Γεώργιος Σταφυλοπάτης  
Καθηγητής Ε.Μ.Π.

**Συνεπιβλέπων :** Γεώργιος Αλεξανδρίδης  
Εργαστηριακό και Διδακτικό Προσωπικό Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 14η Οκτωβρίου 2020.

.....  
Ανδρέας-Γεώργιος Σταφυλοπάτης  
Καθηγητής Ε.Μ.Π.

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

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

Αθήνα, Οκτώβριος 2020

.....  
**Άγγελος Λ. Κολαΐτης**

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

Copyright © Άγγελος Λ. Κολαΐτης, 2020.  
Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

## Περίληψη

Ο σκοπός της παρούσας διπλωματικής εργασίας είναι η ανάπτυξη ενός ευφυούς συστήματος πρόβλεψης και ελέγχου του όγκου της κίνησης οχημάτων, όπως αυτή παρατηρείται στους διάφορους σταθμούς μέτρησης ενός αυτοκινητόδρομου. Για τις ανάγκες της εργασίας χρησιμοποιήθηκαν δεδομένα κίνησης που συλλέχθηκαν από την εταιρία παραχώρησης αυτοκινητοδρόμων ΟΛΥΜΠΙΑ ΟΔΟΣ Α.Ε. κατά το έτος 2018.

Πιο συγκεκριμένα, η εργασία επικεντρώνεται σε τρεις βασικούς άξονες. Αρχικά, λαμβάνονται τα πρωτογενή δεδομένα κίνησης από τους αισθητήρες μέτρησης και μετατρέπονται σε μία αξιοποιήσιμη συλλογή δεδομένων. Στη συνέχεια, δοκιμάζονται αρχιτεκτονικές μοντέλων μηχανικής μάθησης ικανών να πραγματοποιήσουν αξιόπιστες προβλέψεις του επιπέδου της κίνησης και συγκρίνεται η επιτυχία τους σε άγνωστα δεδομένα κίνησης. Τέλος, αναπτύσσεται ένα σύστημα ανίχνευσης έκτοπων τιμών για την συλλογή δεδομένων που κατασκευάστηκε, και γίνονται δοκιμές για την επιτυχία του σε άγνωστα δεδομένα.

Για την πρόβλεψη της κίνησης, χρησιμοποιούνται αρχιτεκτονικές νευρωνικών δικτύων που βασίζονται σε βαθιά και επαναληπτικά νευρωνικά δίκτυα. Για την ανίχνευση έκτοπων τιμών, χρησιμοποιούνται Isolations Forests και μηχανές διανυσμάτων υποστήριξης μίας κλάσης σε μετασχηματισμούς χρονικού παραθύρου των δεδομένων.

## Λέξεις κλειδιά

Μηχανική Μάθηση, Νευρωνικά Δίκτυα, Επαναληπτικά Νευρωνικά Δίκτυα, Βαθιά Μηχανική Μάθηση, Ευφυή Συστήματα Διαχείρισης Κυκλοφορίας, Ανίχνευση Έκτοπων Τιμών, Μηχανές Διανυσμάτων Υποστήριξης Μίας Κλάσης



## **Abstract**

The objective of the current diploma thesis is the development of an intelligent system for traffic level prediction and management, as measured across monitoring stations of a national road. For the purposes of the project, traffic data collected from the motorway concession company OLYMPIA ODOS S.A. during 2018 were used.

In particular, this thesis is focused on three basic tracks. First, raw traffic data is collected from monitoring sensors and transformed into a usable dataset. Next, architectures of machine learning models capable of reliably predicting traffic load are tested, and their performance score in unseen traffic data is compared. Finally, an outlier detection system is developed and tested on our dataset.

For traffic prediction, machine learning architectures based on deep and recurrent neural networks are employed. For outlier detection, we use a time window transformation on the traffic data and subsequently employ Isolation Forests and One Class Support Vector Machines.

## **Key words**

Machine Learning, Neural Networks, Recurrent Neural Networks, Long Short-Term Memory, Gated Recurrent Units, Deep Learning, Intelligent Traffic Control Systems, Outlier Detection, Isolation Forests, One-class Support Vector Machines





## Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον Καθηγητή Ε.Μ.Π. κ. Σταφυλοπάτη Ανδρέα-Γεώργιο για την εμπιστοσύνη που μου επέδειξε με την ανάθεση της εκπόνησης της παρούσας εργασίας, καθώς και τους κ. Κόλλια Στέφανο, Καθηγητή Ε.Μ.Π. και κ. Στάμου Γεώργιο, Αναπληρωτή Καθηγητή Ε.Μ.Π. για την συμμετοχή τους στην εξεταστική επιτροπή. Επίσης θα ήθελα να ευχαριστήσω τους κ. Αλεξανδρίδη Γεώργιο, Ε.ΔΙ.Π. Ε.Μ.Π. και Σιόλα Γεώργιο, Ε.ΔΙ.Π. Ε.Μ.Π. για τη συνεχή συνεργασία σε όλα τα στάδια εκπόνησης της παρούσας εργασίας.

Ευχαριστώ πολύ επίσης τον κ. Χασάνη Γρηγόριο, Διευθυντή Ηλεκτρομηχανολογικών και Συστημάτων Διοδίων στην εταιρία διαχείρισης αυτοκινητοδρόμων ΟΛΥΜΠΙΑ ΟΔΟΣ Α.Ε., χωρίς την συμβολή του οποίου η εργασία αυτή δεν θα μπορούσε να έχει πραγματοποιηθεί.

Ιδιαίτερη εκτίμηση στους γονείς μου, Λεωνίδα και Λουκία, για την υπομονή, την επιμονή και την αμέριστη στήριξη τους στην έως τώρα πορεία μου, καθώς και τα αδέρφια μου, Βαγγέλη, Παναγιώτη και Μιχαέλα για τις συμβουλές, τις πάμπολες ευχάριστες αναμνήσεις και τις πάντοτε εύστοχες παρατηρήσεις. Ευχαριστώ επίσης τους καθηγητές μου, με ιδιαίτερη αναφορά στον κ. Παναγιώτη Τσανάκα που με τιμάει με την διαρκή εμπιστοσύνη του. Τέλος, ευχαριστώ τους πολύ καλούς μου φίλους Γιώργο, Βασίλη, Χάρη, Αλέξανδρο και Σταμάτη, για την ανοχή, τις συμβουλές, τις αξέχαστες βραδιές, τις ατέλειωτες συζητήσεις και το συνεχές παρόν τους στις ευχάριστες και στις δύσκολες στιγμές.

Άγγελος Λ. Κολαΐτης,  
Αθήνα, 14η Οκτωβρίου 2020



# Περιεχόμενα

<b>Περίληψη</b>	5
<b>Abstract</b>	7
<b>Ευχαριστίες</b>	9
<b>Περιεχόμενα</b>	11
<b>Κατάλογος πινάκων</b>	15
<b>Κατάλογος σχημάτων</b>	17
<b>1. Εισαγωγή</b>	19
1.1 Αυτοκίνηση	19
1.2 Ανάπτυξη και εκσυγχρονισμός οδικών δικτύων	20
1.3 Στόχος της εργασίας	21
1.4 Δομή της εργασίας	21
<b>2. Ευφυή Συστήματα Παρακολούθησης Κίνησης</b>	23
2.1 Οφέλη από την χρήση ευφύων συστημάτων ελέγχου κίνησης	23
2.1.1 Αποτελεσματική αξιοποίηση των δεδομένων πραγματικού χρόνου	23
2.1.2 Ικανότητα διαχείρισης τεράστιου όγκου πληροφορίας	23
2.1.3 Αυτόματη προσαρμογή στα δεδομένα κίνησης	24
2.1.4 Συνεχής προσαρμογή σε μεταβολές του περιβάλλοντος	24
2.1.5 Δυνατότητα προληπτικών προβλέψεων	24
2.2 Εφαρμογές	25
2.2.1 Δυναμική δέσμευση πόρων και κόστος λειτουργίας	25
2.2.2 Αυτόματη ενημέρωση οχήματος βοήθειας σε περίπτωση ανάγκης	26
2.2.3 Δυναμική προσαρμογή λειτουργίας φωτεινού σηματοδότη σε αστικό δίκτυο	26
2.2.4 Αυτόματη ρύθμιση του επιπέδου φωτισμού σε έναν αυτοκινητόδρομο	26
<b>3. Τεχνικές Μηχανικής Μάθησης</b>	29
3.1 Μηχανική μάθηση	29
3.1.1 Επιβλεπόμενη μάθηση	29
3.1.2 Μη επιβλεπόμενη μάθηση	30
3.1.3 Ενισχυτική μάθηση	30
3.2 Τεχνητά νευρωνικά δίκτυα	30
3.2.1 Λειτουργίες τεχνητών νευρωνικών δικτύων	30
3.2.2 Τεχνητοί νευρώνες	31
3.2.3 Συνάρτηση Ενεργοποίησης	32
3.2.4 Νευρωνικά δίκτυα πρόσθιας τροφοδότησης	32
3.2.5 Υπερπαραμέτροι	34

3.2.6	Επαναληπτικά νευρωνικά δίκτυα . . . . .	35
3.2.7	Αρχιτεκτονικές νευρωνικών δικτύων . . . . .	35
3.3	Εκπαίδευση νευρωνικών δικτύων . . . . .	36
3.3.1	Ο αλγόριθμος οπισθοδιάδοσης του σφάλματος . . . . .	36
3.3.2	Παράγοντες που επηρεάζουν την ποιότητα της εκπαίδευσης . . . . .	37
3.4	Προβλήματα κατά την εκπαίδευση ενός νευρωνικού δικτύου . . . . .	39
3.4.1	Υπερπροσαρμογή . . . . .	39
3.4.2	Υποπροσαρμογή . . . . .	40
3.4.3	Εκλειπόμενη και Εκκρύβουσα Κλίση . . . . .	40
3.5	Επαναληπτικά νευρωνικά δίκτυα . . . . .	41
3.5.1	Long short-term memory . . . . .	41
3.5.2	Φραγμένα επαναληπτικά δίκτυα . . . . .	44
3.5.3	Sequence to sequence . . . . .	44
3.5.4	Πρόβλεψη ροής κίνησης με επαναληπτικά νευρωνικά δίκτυα . . . . .	44
3.6	Ανίχνευση έκτοπων τιμών . . . . .	45
3.6.1	Ανίχνευση έκτοπων τιμών σε χρονοσειρές . . . . .	45
3.6.2	Ανίχνευση έκτοπων τιμών και μηχανική μάθηση . . . . .	45
<b>4.</b>	<b>Πρόβλεψη Κυκλοφοριακής Κίνησης . . . . .</b>	<b>47</b>
4.1	Συλλογή δεδομένων . . . . .	47
4.1.1	Συλλογή πρωτογενών δεδομένων . . . . .	47
4.1.2	Κατασκευή της συλλογής δεδομένων . . . . .	48
4.1.3	Τελική μορφή δεδομένων . . . . .	49
4.1.4	Σχολιασμός δεδομένων . . . . .	50
4.2	Πρόβλεψη κίνησης με χρήση επαναληπτικών νευρωνικών δικτύων . . . . .	50
4.2.1	Προεπεξεργασία δεδομένων . . . . .	51
4.2.2	Πρόβλεψη χρονοσειράς κίνησης . . . . .	51
4.2.3	Πρόβλεψη χρονοσειράς κίνησης με είσοδο δεδομένα προηγούμενου σταθμού . . . . .	54
4.2.4	Πρόβλεψη χρονοσειράς κίνησης με αξιοποίηση επιπλέον δεδομένων . . . . .	57
4.2.5	Πρόβλεψη επιπέδου κίνησης . . . . .	60
4.2.6	Σύγκριση ακρίβειας μοντέλου για διαφορετικούς χρονικούς ορίζοντες πρόβλεψης . . . . .	64
4.3	Ανίχνευση έκτοπων τιμών . . . . .	65
4.3.1	Κίνητρο και χρησιμότητα . . . . .	65
4.3.2	Πρόβλημα ανίχνευσης έκτοπων τιμών . . . . .	66
4.3.3	Isolation forests . . . . .	67
4.3.4	Μηχανές διανυσμάτων υποστήριξης μίας κλάσης . . . . .	69
<b>5.</b>	<b>Συμπεράσματα και Μελλοντικές Κατευθύνσεις . . . . .</b>	<b>73</b>
5.1	Συμπεράσματα . . . . .	73
5.2	Πρόταση αρχιτεκτονικής ολοκληρωμένου συστήματος πρόβλεψης κίνησης . . . . .	74
5.2.1	Εκπαίδευση και δοκιμή μοντέλων . . . . .	74
5.2.2	Παρατήρηση και προβλέψεις σε πραγματικό χρόνο . . . . .	74
5.3	Μελλοντικές κατευθύνσεις . . . . .	75
	<b>Βιβλιογραφία . . . . .</b>	<b>77</b>

<b>Παράρτημα</b>	81
<b>A. Ευρετήριο Όρων και Συντμήσεων</b>	81
A.1 Ελληνικοί όροι	81
A.2 Αγγλικοί όροι	81



## Κατάλογος πινάκων

4.1	Μορφή των δεδομένων που προέρχονται από τους αισθητήρες . . . . .	48
4.2	Τιμές υπερπαραμέτρων που δοκιμάστηκαν για το μοντέλο του απλού LSTM .	53
4.3	Αποτελέσματα gridsearch για την απλή αρχιτεκτονική με LSTM . . . . .	53
4.4	Τιμές υπερπαραμέτρων που δοκιμάστηκαν για το μοντέλο του LSTM με επιπλέον χαρακτηριστικό την ημέρα για την οποία γίνεται η πρόβλεψη . . . . .	59
4.5	Αποτελέσματα gridsearch για την αρχιτεκτονική LSTM με χρήση της μέρας ως επιπλέον χαρακτηριστικό . . . . .	59
4.6	Τιμές υπερπαραμέτρων που δοκιμάστηκαν για το μοντέλο πρόβλεψης κλάσεων κίνησης . . . . .	63
4.7	Αποτελέσματα gridsearch για την αρχιτεκτονική πρόβλεψης κλάσεων κίνησης. Για όλα τα μοντέλα είναι $epochs = 30$ και $dropout = 0$ . . . . .	64
4.8	Ποσοστά Επιτυχίας Πρόβλεψης Κλάσης Κίνησης για 1, 2 και 4 ώρες στο μέλλον. . . . .	66





## Κατάλογος σχημάτων

1.1	Αγορά Μηχανοκίνητων Οχημάτων κατά τα έτη 2011-2019 . . . . .	19
1.2	Εξέλιξη της Αγοράς Μηχανοκίνητων Οχημάτων κατά τα έτη 2011-2019 . . .	20
1.3	Επενδύσεις για ανάπτυξη των ελληνικών αυτοκινητοδρόμων για το έτος 2019. . . . . .	21
2.1	Τυπικές εφαρμογές ευφυών συστημάτων παρακολούθησης κίνησης . . . . .	25
3.1	Διαγραμματική απεικόνιση ενός τεχνητού νευρώνα . . . . .	31
3.2	Γραφική Παράσταση Κυριότερων Συναρτήσεων Ενεργοποίησης . . . . .	33
3.3	Παράδειγμα νευρωνικού δικτύου πρόσθιας τροφοδότησης . . . . .	34
3.4	Παράδειγμα υπερπροσαρμογής και υποπροσαρμογής . . . . .	39
3.5	Τυπική δομή ενός κελιού LSTM . . . . .	42
4.1	Πλήρες μήκος Ολυμπίας Οδού . . . . .	47
4.2	Δεδομένα κίνησης πάνω από την έξοδο της Επιδαύρου με κατεύθυνση την Ελευσίνα πριν τον καθαρισμό των δεδομένων. . . . .	49
4.3	Δεδομένα κίνησης πάνω από την έξοδο της Επιδαύρου με κατεύθυνση την Ελευσίνα μετά τον καθαρισμό των δεδομένων. . . . .	50
4.4	Απλή αρχιτεκτονική μοντέλου πρόβλεψης κίνησης βασιζόμενη σε LSTM . . .	51
4.5	Απλή αρχιτεκτονική μοντέλου πρόβλεψης κίνησης, με χρήση δύο stacked LSTMs . . . . .	52
4.6	Καμπύλη εκπαίδευσης του μοντέλου <i>ayivu.pkl</i> . . . . .	55
4.7	Πρόβλεψη για 1 ώρα με χρήση του μοντέλου <i>ayivu.pkl</i> για το σταθμό της Κορίνθου με κατεύθυνση προς Πάτρα. . . . .	55
4.8	Πρόβλεψη για 1 ώρα με χρήση του μοντέλου <i>ayivu.pkl</i> για το σταθμό του Ξυλοκάστρου με κατεύθυνση προς Αθήνα. . . . .	56
4.9	Πρόβλεψη για 1 ώρα με χρήση του μοντέλου <i>xmghz.pkl</i> για το σταθμό της Κορίνθου με κατεύθυνση προς Αθήνα . . . . .	57
4.10	Αρχιτεκτονική μοντέλου πρόβλεψης κίνησης, με χρήση δύο stacked LSTMs, και με επιπλέον είσοδο το είδος της ημέρας για το οποίο γίνεται η πρόβλεψη	58
4.11	Καμπύλη εκπαίδευσης του μοντέλου <i>tvryc.pkl</i> . . . . .	59
4.12	Πρόβλεψη για 1 ώρα με χρήση του μοντέλου <i>tvryc.pkl</i> για το σταθμό της Κορίνθου με κατεύθυνση προς Αθήνα. . . . .	60
4.13	Καμπύλη εκπαίδευσης του μοντέλου <i>uzvjg.pkl</i> . . . . .	61
4.14	Πρόβλεψη για 1 ώρα με χρήση του μοντέλου <i>uzvjg.pkl</i> για το σταθμό της Κορίνθου με κατεύθυνση προς Αθήνα. . . . .	61
4.15	Πρόβλεψη για 1 ώρα με χρήση του μοντέλου <i>ayivu.pkl</i> για το σταθμό του Ξυλοκάστρου με κατεύθυνση την Αθήνα. . . . .	62
4.16	Καμπύλη εκπαίδευσης του μοντέλου <i>pscxh.pkl</i> . . . . .	64
4.17	Πρόβλεψη για 1 ώρα με χρήση του μοντέλου <i>pscxh.pkl</i> για το σταθμό των Μεγάρων με κατεύθυνση προς Αθήνα. . . . .	65
4.18	Πρόβλεψη για 1 ώρα με χρήση του μοντέλου <i>pscxh.pkl</i> για το σταθμό του Ξυλοκάστρου με κατεύθυνση προς Πάτρα. . . . .	65

4.19 Ποσοστά Επιτυχίας Πρόβλεψης Κλάσης Κίνησης για 1, 2 και 4 ώρες στο μέλλον. . . . .	66
4.20 Ανίχνευση έκτοπων τιμών με Isolation Forest, χρησιμοποιώντας ως διάνυσμα εισόδου τις πιο πρόσφατες $N$ μετρήσεις. . . . .	68
4.21 Ανίχνευση έκτοπων τιμών με Isolation Forest, χρησιμοποιώντας ως διάνυσμα εισόδου χαρακτηριστικά του κυλιόμενου παραθύρου της χρονοσειράς. . . . .	68
4.22 Ανίχνευση έκτοπων τιμών με One-class SVM, για εκπαίδευση του SVM με $nu = 0.01$ . . . . .	69
4.23 Ανίχνευση έκτοπων τιμών με One-class SVM, για εκπαίδευση του SVM με $nu = 0.02$ . . . . .	70
4.24 Ανίχνευση έκτοπων τιμών με one-class SVM, για εκπαίδευση του SVM με $nu = 0.01$ . . . . .	70
5.1 Σχεδιάγραμμα Προτεινόμενης Αρχιτεκτονικής . . . . .	74

## Κεφάλαιο 1

### Εισαγωγή

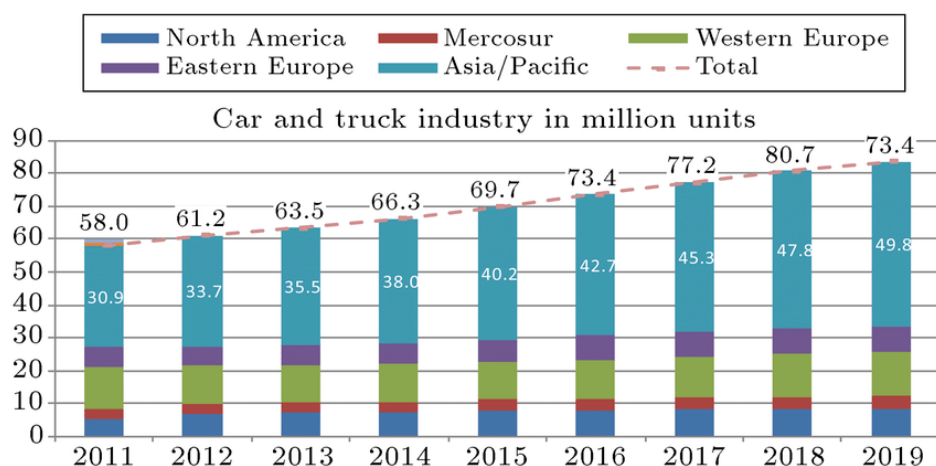
#### 1.1 Αυτοκίνηση

Τα τέλη του 20ου και οι αρχές του 21ου αιώνα έχουν αποτελέσει μία χρονική περίοδο εκρηκτικής ανάπτυξης της ανθρώπινης τεχνολογίας. Αναμφίβολα, ένας τομέας στον οποίο έχει σημειωθεί ανεπανάληπτη εξέλιξη είναι αυτός της αυτόματης μηχανοκίνησης.


Από την αρχική τους εμφάνιση και κυκλοφορία στις αρχές του 20ού αιώνα, τα αυτοκίνητα (και γενικότερα τα αυτόματα μηχανοκίνητα οχήματα) υιοθετήθηκαν ταχύτατα στην αγορά των ΗΠΑ, και σε σύντομο χρονικό διάστημα έγιναν αποδεκτά και στην Δυτική Ευρώπη και τον υπόλοιπο ανεπτυγμένο κόσμο.

Σήμερα, η βιομηχανία της αυτοκίνησης αποτελεί θεμελιώδη λίθο της παγκόσμιας οικονομίας. Η χρήση του αυτοκινήτου είναι ευρύτατα διαδεδομένη σε όλα τα μήκη και πλάτη της γης, και αυτό συμβαίνει λόγω ενός πλήθους αιτιών: Η άνεση, η ευελιξία και η ελευθερία κινήσεων που παρέχει, σε συνδυασμό με την ευκολία χρήσης και την προσιτότητά του (οικονομικά και όχι μόνο) από την συντριπτική πλειοψηφία του παγκόσμιου πληθυσμού είναι μερικές από αυτές.

Τα μηχανοκίνητα οχήματα χρησιμοποιούνται για πάσης φύσεως μετακινήσεις: Σε ατομικό επίπεδο, χρησιμοποιείται για τις καθημερινές μετακινήσεις από και προς τον χώρο εργασίας, για μετακινήσεις που απαιτούνται για κάλυψη διάφορων υποχρεώσεων, ή ακόμα και για πραγματοποίηση ταξιδιών αναψυχής. Αποτελούν επίσης πυλώνα της οικονομίας και της πραγματοποίησης αγοραπωλησιών, καθώς χρησιμοποιούνται για την μεταφορά εμπορευμάτων από τον τόπο παραγωγής τους στα καταστήματα και τους καταναλωτές. Επιπλέον, για μεγάλη μερίδα του πληθυσμού, τα αυτοκίνητα δεν είναι απλώς ένα μέσο μετακίνησης, αλλά αποτελούν και αντικείμενο απασχόλησης και ψυχαγωγίας, με χαρακτηριστικό παράδειγμα τον μηχανοκίνητο αθλητισμό.



Σχήμα 1.1: Αγορά Μηχανοκίνητων Οχημάτων κατά τα έτη 2011-2019. (Πηγή: [Hsie16])



**Σχήμα 1.2:** Εξέλιξη της Αγοράς Μηχανοκίνητων Οχημάτων κατά τα έτη 2011-2019. (Πηγή: [Hsie16])

Στο Σχήμα 1.1 απεικονίζεται το μέγεθος της αγοράς μηχανοκίνητων οχημάτων στις διάφορες ηπείρους την τελευταία δεκαετία, ενώ στο Σχήμα 1.2 καταγράφονται οι τάσεις της αγοράς μηχανοκίνητων οχημάτων για την ίδια, περίπου, χρονική περίοδο. Όπως παρατηρούμε, η τάση είναι αυξητική σε όλες τις ηπείρους και ιδιαίτερα στην Ασία, στην οποία συμβάλλει η ταχύτατα αναδυόμενη οικονομία της Κίνας. Ακόμα και στην Ευρώπη, ωστόσο, η αύξηση είναι σημαντική, εμφανίζοντας ένα μέγεθος ετήσιας αύξησης περίπου 10% τα τελευταία χρόνια.

## 1.2 Ανάπτυξη και εκσυγχρονισμός οδικών δικτύων

Προκειμένου να καλύπτονται οι ανάγκες της διαρκώς αυξανόμενης κίνησης αυτοκινήτων, αλλά και να εξασφαλίζεται ότι πληρούνται οι προδιαγραφές ασφαλείας, το οδικό δίκτυο διαρκώς αναπτύσσεται και εκσυγχρονίζεται. Κάθε χρόνο δαπανώνται αξιολογικά χρηματικά ποσά στην επέκταση των υφιστάμενων υποδομών, ή την ανάπτυξη καινούριων. Ενδεικτικά, για την Ελλάδα, στο Σχήμα 1.3 φαίνονται τα εν εξελίξει έργα που αφορούν επέκταση των υποδομών του οδικού δικτύου για το έτος 2019.

Τα πλεονεκτήματα των σύγχρονων αυτοκινητοδρόμων είναι η μεγαλύτερη άνεση και οι υψηλές προδιαγραφές ασφαλείας για τους χρήστες τους, πράγματα που συνεισφέρουν στην διευκόλυνση και την μείωση του χρόνου των μετακινήσεων. Ωστόσο, την ίδια στιγμή, στους σύγχρονους αυτοκινητόδρομους είναι πολύ πιο αυξημένες οι ανάγκες για συνεχή μέριμνα και εποπτεία της ποιότητας του δρόμου και των συστημάτων του, ούτως ώστε να μην διακυβεύεται η ασφάλεια των χρηστών του, κάτι το οποίο εν γένει φροντίζεται μέσω τηλεματικής. Παραδείγματα συστημάτων τα οποία είναι κρίσιμης σημασίας για την ασφαλή λειτουργία του αυτοκινητόδρομου μπορεί να είναι ο φωτισμός σηράγγων, ο νυχτερινός φωτισμός, τα συστήματα μέτρησης των διερχόμενων οχημάτων, ή τα συστήματα αυτόματης ανίχνευσης προβλημάτων (π.χ. σταματημένα αυτοκίνητα, καπνός, εμπόδιο στο δρόμο).

Συνοψολογίζοντας ότι ένας αυτοκινητόδρομος μπορεί να καλύπτει εκατοντάδες χιλιόμετρα μήκους, είναι εύκολα αντιληπτό ότι το κόστος λειτουργίας αυτής της υποδομής είναι κάθε άλλο παρά αμελητέο. Και φυσικά, πέραν του οικονομικού κόστους, δεν πρέπει να παραβλέπεται και το κόστος σε ενεργειακούς πόρους, ειδικά αν αυτοί καταναλώνονται αφειδώς χωρίς να προσφέρουν αξία στους χρήστες της οδού.

Συγκεκριμένα, ένα σχετικό πρόβλημα το οποίο κοστίζει ακριβά σε οικονομικούς και

Motorways investment pipeline is about € 4.3bn

No	Upcoming Projects	Details	Total Km	Total Budget (€ mn)	Remaining Budget (€ mn)	Start Date	Estimated Completion Date	Average investment/km
1	Crete Northern Highway	Chania - Chersonissos, Chersonissos - Neapoli & Neapoli - Agios Nikolaos	300	1,315	1,315	2019	2024	4.4
2	E65 Motorway (Lamia-Egnatia)	Lamia - Xyniada & Trikala - Egnatia	96	1,126	594	2008	2022	11.7
3	Egnatia Odos	Vertical axes: Ardanio-Ormenio & Mandra-Psathades, Serres-Drama-Kavala, Xanthi-Echinos	173	920	910	2011	N/A	5.3
4	Ionia Odos	Aktion-Amvrakia Vertical Axis	49	150	93	2010	2021	3.1
5	Regional roads	Ring road of Katerini, Thessaloniki-Doirani, Circumvention of Chalkida, Circumvention of Lagkadia, Kalamata-Rizomylos-Pylos-Methoni & Kalo Nero - Tsakona	167	774	711	2013 2011 2019 N/A N/A N/A	2019 2020 N/A N/A N/A N/A	4.6
6	Underwater tunnel Salamina	Underwater connection of Salamina and Perama	5	350	350	2019	N/A	71.4
7	Underwater tunnel Lefkada	Underwater connection of Lefkada and Etolokarnania	3	50	50	N/A	N/A	16.7
8	Patras-Pyrgos Motorway	Patras-Pyrgos	75	293	244	2019	2022	3.9
<b>Total</b>			<b>867</b>	<b>4,978</b>	<b>4,266</b>			<b>5.7</b>

Source: Press, PwC calculations

**Σχήμα 1.3:** Επενδύσεις για ανάπτυξη των ελληνικών αυτοκινητοδρόμων για το έτος 2019. (Πηγή: [https://www.pwc.com/gr/en/publications/greek-thought-leadership/infrastructure-in-greece/infrastructure\\_2018\\_en.pdf](https://www.pwc.com/gr/en/publications/greek-thought-leadership/infrastructure-in-greece/infrastructure_2018_en.pdf))

ενεργειακούς πόρους είναι το ζήτημα του νυχτερινού φωτισμού. Ο φωτισμός είναι μεν απαραίτητος για λόγους ασφάλειας, ωστόσο αυτό που παρατηρείται συχνά είναι τα φώτα να λειτουργούν στο 100% της ισχύος τους χωρίς να υπάρχει διέλευση οχημάτων, καταναλώνοντας ποσά ενέργειας τα οποία δεν αξιοποιούνται με κανέναν τρόπο.

### 1.3 Στόχος της εργασίας

Στόχος της παρούσας εργασίας είναι η ανάπτυξη ενός μηχανισμού πρόβλεψης κίνησης σε έναν τέτοιο αυτοκινητόδρομο, ούτως ώστε ο λειτουργός του, βασιζόμενος στην πρόβλεψη και όποιο άλλο κριτήριο αυτός επιθυμεί, να μπορεί με έναν ικανοποιητικό βαθμό βεβαιότητας και ασφάλειας να χαμηλώνει το επίπεδο φωτισμού σε τμήματα που η κίνηση είναι περιορισμένη, ελαττώνοντας σημαντικά με τον τρόπο αυτό το κόστος λειτουργίας και φυσικά εξοικονομώντας πολύτιμους ενεργειακούς πόρους.

Γενικότερα, η ύπαρξη ενός συστήματος το οποίο δύναται να προβλέψει με αρκετά υψηλή ακρίβεια το αναμενόμενο επίπεδο κίνησης στον αυτοκινητόδρομο είναι το πρώτο βήμα για πληθώρα εφαρμογών και διευκολύνσεων της λειτουργίας του. Για παράδειγμα, αν αναμένεται μεγάλος όγκος κίνησης, ο λειτουργός της οδού μπορεί να ενημερώσει έγκαιρα τους χρήστες ώστε να ελαττώσουν ταχύτητα και να οδηγούν με προσοχή, προλαμβάνοντας έτσι πιθανά ατυχήματα.

Σε κάθε περίπτωση, το σημαντικό είναι ότι μία αξιόπιστη πρόβλεψη κίνησης περιορίζει τον βαθμό αβεβαιότητας που υπάρχει για το μέλλον, επιτρέποντας προληπτικές ενέργειες, οι οποίες αντιμετωπίζουν προβλήματα που μπορεί να προκύψουν πριν αυτά καν εμφανιστούν.

### 1.4 Δομή της εργασίας

Η υπόλοιπη εργασία διαρθρώνεται ως εξής. Στο Κεφάλαιο 2 γίνεται μία εισαγωγή στα ευφυή συστήματα παρακολούθησης κίνησης, σχολιάζονται τα πλεονεκτήματά τους σε σύ-

γκριση με αντίστοιχα συμβατικά συστήματα και συζητούνται χρήσιμες εφαρμογές τους. Στην συνέχεια, στο Κεφάλαιο 3 περιγράφεται το θεωρητικό πλαίσιο της μηχανικής μάθησης και των μοντέλων που χρησιμοποιήθηκαν, με ιδιαίτερη αναφορά στα επαναληπτικά νευρωνικά δίκτυα. Στο Κεφάλαιο 4, παρουσιάζονται το πρακτικό κομμάτι της εργασίας και πιο συγκεκριμένα η κατασκευή της συλλογής δεδομένων από τα πρωτογενή δεδομένα που δόθηκαν από την εταιρία παραχώρησης αυτοκινητοδρόμων ΟΛΥΜΠΙΑ ΟΔΟΣ Α.Ε., αναλύονται οι διάφορες αρχιτεκτονικές μοντέλων μηχανικής μάθησης και τα αποτελέσματα των δοκιμών που έγιναν με αυτές, τόσο για την πρόβλεψη της κίνησης όσο και για την ανίχνευση έκτοπων τιμών. Τέλος, στο Κεφάλαιο 5 παρουσιάζονται τα συμπεράσματα που προέκυψαν, αναφέρονται πιθανές μελλοντικές κατευθύνσεις, ενώ γίνεται και πρόταση για την δομή ενός πλήρους συστήματος πρόβλεψης κίνησης.

## Κεφάλαιο 2

# Ευφυή Συστήματα Παρακολούθησης Κίνησης

Ως *ευφυή συστήματα παρακολούθησης κίνησης* (intelligent traffic management systems) αναφέρονται τα συστήματα τα οποία χρησιμοποιούνται για την παρακολούθηση οδικών δικτύων και μπορούν να εξαγάγουν δυναμικά συμπεράσματα από αυτά. Αυτό πραγματοποιείται συλλέγοντας δεδομένα από μία πληθώρα πηγών, όπως κάμερες, αισθητήρες, κινητά τηλέφωνα και άλλα, ή/και συνδυασμός αυτών για την παραγωγή της απόφασης.

Αποτελούν έναν τομέα με τεράστιο οριζόντιο εύρος, καθώς σε αυτά εμπλέκονται γνώσεις από αρκετούς κλάδους (ενδεικτικά αναφέρονται η ανάλυση μεγάλου όγκου δεδομένων, η μηχανική μάθηση και το διαδίκτυο των πραγμάτων). Στην σχετική βιβλιογραφία απαντώνται αρκετές σχετικές έρευνες, που περιλαμβάνουν και πολύ χρήσιμα συμπεράσματα από πιλοτικές εφαρμογές τέτοιων συστημάτων [Saed19, Janu16].

Στο παρόν Κεφάλαιο αναλύονται οφέλη που αποκομίζονται από την χρήση ευφυών συστημάτων παρακολούθησης κίνησης σε σύγκριση με τα συμβατικά συστήματα παρακολούθησης κίνησης, και γίνεται αναφορά σε συγκεκριμένες εφαρμογές τους.

### 2.1 Οφέλη από την χρήση ευφυών συστημάτων ελέγχου κίνησης

Στην ενότητα αυτή αναλύονται τρόποι με τους οποίους μπορεί να επωφεληθεί ένα σύστημα ελέγχου κίνησης όταν σε αυτό ενσωματώνονται ευφυείς τεχνικές. Η λίστα δεν είναι εξαντλητική, καθώς στα πλαίσια της παρούσας εργασίας μας ενδιαφέρουν κυρίως τα οφέλη που προκύπτουν από την ενσωμάτωση τεχνικών μηχανικής μάθησης.

#### 2.1.1 Αποτελεσματική αξιοποίηση των δεδομένων πραγματικού χρόνου

Ένα εγγενές χαρακτηριστικό των δεδομένων κίνησης είναι η υψηλή ευαισθησία σε τυχαία γεγονότα. Για παράδειγμα, αν σε ένα σύστημα γνωρίζουμε ότι τις Κυριακές η κίνηση είναι αυξημένη, τότε έχουμε στα χέρια μια πολύ χρήσιμη πληροφορία. Ωστόσο, αυτή είναι αδύνατο να χρησιμοποιηθεί για να κάνουμε μία εύστοχη πρόβλεψη της κίνησης για την τρέχουσα μέρα, αν δεν συμπεριλάβουμε ως είσοδο την εξέλιξη της κίνησης τις τελευταίες ώρες.

Γενικότερα, στην βιβλιογραφία, η αξιοποίηση των δεδομένων πραγματικού χρόνου αποτελεί ένα από τα ισχυρότερα προτερήματα των ευφυών συστημάτων παρακολούθησης κίνησης [Paul19].

#### 2.1.2 Ικανότητα διαχείρισης τεράστιου όγκου πληροφορίας

Είναι γνωστό ότι τα τελευταία χρόνια ο όγκος των δεδομένων που συλλέγεται, διακινείται και καταναλώνεται βρίσκεται σε εκθετική αύξηση. Σε αυτό έχουν συμβάλει η ανάπτυξη τόσο υλικού (με την έννοια των υπολογιστικών πόρων) όσο και λογισμικού τα οποία μπορούν να διαχειρίζονται τα καλούμενα *μεγάλα δεδομένα*. Τα δεδομένα κίνησης που

συλλέγονται μπορεί να είναι πολυδιάστατα και να προέρχονται ως ροή από πολλαπλές πηγές (αισθητήρες, μετρητές, κάμερες). Ένα ευφυές σύστημα μπορεί να διαχειρίζεται αποτελεσματικά τεράστιους όγκους δεδομένων, καθώς και να συνδυάζει δεδομένα από πολλαπλές πηγές [Nall19, Shar18].

Ο βαθμός στον οποίο κάθε ένα στοιχείο αυτών των πληροφοριών είναι χρήσιμο δεν είναι γνωστό από πριν, ή μπορεί να μεταβάλλεται ανάλογα με την εκάστοτε τρέχουσα κατάσταση του συστήματος. Οι αλγόριθμοι μηχανικής μάθησης, οπότε κατ' επέκταση και τα ευφυή συστήματα διαχείρισης κίνησης, έχουν την δυνατότητα να ανακαλύπτουν αυτόματα τον τρόπο με τον οποίο οι διάφορες πληροφορίες μπορούν να συνεισφέρουν σε μία ακριβή πρόβλεψη, συνεπώς μπορούν να αξιοποιήσουν με αποτελεσματικότητα το σύνολο των δεδομένων που τους παρέχεται από την τηλεματική.

### **2.1.3 Αυτόματη προσαρμογή στα δεδομένα κίνησης**

Τα ευφυή συστήματα που χρησιμοποιούν και στηρίζονται σε αλγορίθμους μηχανικής μάθησης απαιτούν ελάχιστη ανθρώπινη παρέμβαση κατά τον σχεδιασμό και την λειτουργία τους όσον αφορά την προσαρμογή τους στα δεδομένα.

Κατά την διάρκεια της εκπαίδευσης, παρουσιάζονται στο σύστημα κατ' επανάληψη γνωστά ιστορικά δεδομένα, στα οποία και προσαρμόζεται. Πρακτικά, αυτό σημαίνει ότι το σύστημα θα «μάθει» μόνο του τους κανόνες, τα πρότυπα, τις συσχετίσεις και τις αλληλεξαρτήσεις των δεδομένων, χωρίς να χρειάζεται αυτές να καθοριστούν από τον ανθρώπινο παράγοντα [Fano20, Kuma16]

### **2.1.4 Συνεχής προσαρμογή σε μεταβολές του περιβάλλοντος**

Όπως συμβαίνει σε πολλά προβλήματα της καθημερινής ζωής, το περιβάλλον εξελίσσεται διαρκώς, καθιστώντας την υπάρχουσα γνώση «πεπαλαιωμένη» ή «ξεπερασμένη». Δύο παραδείγματα που αφορούν τα συστήματα ελέγχου κίνησης μπορεί να είναι:

- η μόνιμη μείωση του αριθμού των οχημάτων, λόγω δημιουργίας νέου δρόμου που καλύπτει καλύτερα της ανάγκες των χρηστών της
- η προσωρινή αύξηση, λόγω παύσης λειτουργίας κάποιου παράλληλου δρόμου

Ένα συμβατικό σύστημα θα χρειαζόταν επαναρρύθμιση από ανθρώπινο χέρι προκειμένου να προσαρμοστεί στα νέα δεδομένα, και η επαναρρύθμιση αυτή θα ήταν πολύ δύσκολο να επαληθευτεί. Αντίθετα, σε ένα ευφυές σύστημα αρκεί απλώς να γίνει επανεκπαίδευση στα νέα δεδομένα.

Υπό προϋποθέσεις, και αν οι μεταβολές του περιβάλλοντος είναι σταδιακές, είναι δυνατό επίσης η προσαρμογή να γίνεται πλήρως δυναμικά, με πραγματοποίηση online εκπαίδευσης του συστήματος [Cram06, Somm94], δηλαδή διαρκή εκπαίδευση στα νέα δεδομένα που αυτό συλλέγει από το περιβάλλον, ενώ βρίσκεται σε λειτουργία.

### **2.1.5 Δυνατότητα προληπτικών προβλέψεων**

Τα ευφυή συστήματα έχουν την δυνατότητα όχι μόνο να παρατηρούν την τρέχουσα κατάσταση του συστήματος, αλλά και να κάνουν προβλέψεις για την κατάσταση στην οποία ενδέχεται να βρεθεί στο μέλλον. Καθίσταται έτσι δυνατή η δυναμική και αυτόματη κατάσταση σχεδίων ενεργειών και πλάνων δράσης που προλαμβάνουν προβλήματα πριν αυτά καν εμφανιστούν [Peca17, Sing19].

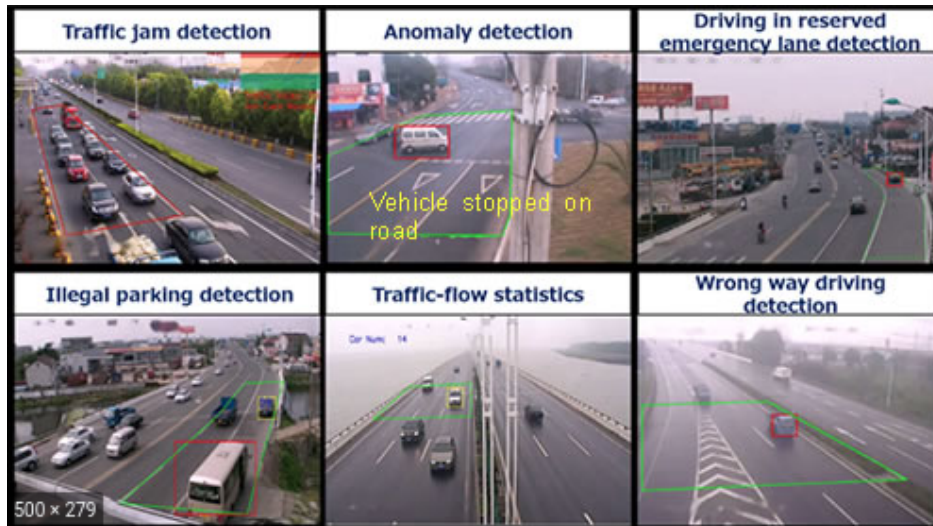
Για παράδειγμα, σε ένα σύστημα παρακολούθησης του φωτισμού ενός δρόμου, αν ένα φωτιστικό αρχίζει να παρουσιάζει διακυμάνσεις στην κατανάλωσή του, τότε μπορεί να εξαχθεί το συμπέρασμα ότι πλησιάζει το τέλος του χρόνου ζωής του και ότι πρέπει να



αντικατασταθεί. Κατ' αυτόν τον τρόπο, η βλάβη μπορεί να διορθωθεί προληπτικά, χωρίς να δημιουργηθεί ποτέ ζήτημα φωτισμού στον δρόμο.

## 2.2 Εφαρμογές

Στην Ενότητα αυτή παρουσιάζονται ενδεικτικά πιθανές εφαρμογές ευφυών συστημάτων παρακολούθησης κίνησης. Στο Σχήμα 2.1 απεικονίζεται μερικές από τις συνηθέστερες.



**Σχήμα 2.1:** Τυπικές εφαρμογές ευφυών συστημάτων παρακολούθησης κίνησης (Πηγή: <https://moasar.com/index.php/moasar-traffic-vision/>)

### 2.2.1 Δυναμική δέσμευση πόρων και κόστος λειτουργίας

Αποτέλεσμα της δυνατότητας προληπτικών προβλέψεων είναι και ότι η επιτρέπεται δυναμική δέσμευση και κατανάλωση πόρων για την λειτουργία της οδού. Για περιόδους όπου το σύστημα προβλέπει αύξηση της κίνησης εντός κάποιου χρονικού διαστήματος, μπορεί να λάβει προληπτικές ενέργειες όπως:

- αυτόματη αύξηση των ανοιχτών θυρίδων διοδίων
- έγκαιρη ενημέρωση και προειδοποίηση των χρηστών του δρόμου
- αύξηση των ατόμων που βρίσκονται σε επιφυλακή για περίπτωση ατυχήματος

Αντίστοιχα, για περιόδους όπου η κίνηση αναμένεται να μειωθεί, ένα πιθανό πλάνο ενεργειών για την μείωση του κόστους λειτουργίας θα μπορούσε να είναι:

- μείωση των ανοιχτών θυρίδων σε διόδια
- αποδέσμευση ανθρώπων από την κατάσταση επιφυλακής

Στη βιβλιογραφία, η χρήση και ο σχεδιασμός ευφυών συστημάτων παρακολούθησης κίνησης συνδέεται πολύ συχνά με την μείωση του κόστους λειτουργίας των υφιστάμενων υποδομών, ιδιαίτερα σε αναπτυσσόμενες οικονομίες [Litm15, Peca17, Miyi19].

### 2.2.2 Αυτόματη ενημέρωση οχήματος βοήθειας σε περίπτωση ανάγκης

Μια σημαντική εφαρμογή που σχετίζεται με την ασφάλεια των χρηστών του δρόμου είναι η αυτόματη κλήση οχήματος βοήθειας σε περίπτωση έκτακτης ανάγκης [Filij11, Hila20]. Το τι μπορεί να αποτελεί κατάσταση έκτακτης ανάγκης είναι ανοιχτό ζήτημα ως προς τα δεδομένα που καταγράφονται και συλλέγονται από το σύστημα παρακολούθησης της οδού.

Περιστατικά τα οποία θα μπορούσαν να αναγνωριστούν και να χαρακτηριστούν ως κατάσταση έκτακτης ανάγκης ενδεικτικά είναι:

- Σταματημένο όχημα στην άκρη του δρόμου, πραγματοποιώντας αναγνώριση εικόνας πραγματικού χρόνου από τις κάμερες ασφαλείας
- Σταματημένο όχημα σε κάποια λωρίδα κυκλοφορίας του δρόμου, επίσης με αναγνώριση εικόνας
- Αυτοκινητιστικό δυστύχημα, επίσης μέσω αναγνώρισης εικόνας
- Πυρκαγιά, πλημμύρα, πτώση φυσικού εμποδίου ή άλλη φυσική καταστροφή, μέσω αναγνώρισης εικόνας ή εξειδικευμένου αισθητήρα (λόγου χάρη αισθητήρα θερμοκρασίας, υγρασίας, ατμόσφαιρας).
- Απότομη πτώση της ταχύτητας των διερχόμενων οχημάτων, με αναγνώριση εικόνας ή λήψη μετρήσεων από αισθητήρες.
- Απότομη ή διαρκής αυξομείωση του αριθμού των διερχόμενων οχημάτων.

Σε αυτές τις περιπτώσεις, που ενδέχεται και η κλήση βοήθειας να μην είναι δυνατή υπό άλλες συνθήκες, όπως είναι η έλλειψη σήματος του κινητού τηλεφώνου, ένα όχημα της ασφαλείας μπορεί να ενημερωθεί αυτόματα, γλιτώνοντας πολύτιμα λεπτά χρόνου μέχρι να μεταβεί στο σημείο και να επιληφθεί της κατάστασης.

### 2.2.3 Δυναμική προσαρμογή λειτουργίας φωτεινού σηματοδότη σε αστικό δίκτυο

Οι φωτεινοί σηματοδότες αποτελούν αναπόσπαστο και απαραίτητο συστατικό στοιχείο των αστικών οδικών δικτύων. Η σωστή λειτουργία τους είναι κρίσιμης σημασίας για την ομαλή ροή αυτοκινήτων μέσα στο αστικό περιβάλλον, προκειμένου να μην δημιουργούνται εκνευρισμός και εντάσεις μεταξύ των οδηγών. Ωστόσο, η ρύθμισή τους συχνά είναι στατική, ρυθμισμένη εκ των προτέρων βάσει εκτιμήσεων και μόνο, και έτσι δεν είναι καθόλου σπάνιο το φαινόμενο να εμφανίζεται «αρρυθμίες» όσον αφορά την παραχώρηση προτεραιότητας στα διάφορα ρεύματα.

Ένα ευφυές σύστημα ελέγχου θα μπορούσε να συλλέγει πληροφορίες σχετικά με τον χρόνο αναμονής των αυτοκινήτων στην διασταύρωση και τη συνολική ροή τους, μέσω καμερών ή άλλων μετρητών. Στη συνέχεια, εφόσον διαπιστωθεί ότι κάποιο από τα ρεύματα «αδικείται» σε σύγκριση με άλλα, ή αν υπάρχει προσωρινή συμφόρηση, το σύστημα μπορεί δυναμικά να προσαρμόσει (μόνιμα ή προσωρινά) την χρονική διάρκεια των σηματοδοτών κατάλληλα ώστε να αποσυμφορήσει την κατάσταση [Bhat20, Roc18].

### 2.2.4 Αυτόματη ρύθμιση του επιπέδου φωτισμού σε έναν αυτοκινητόδρομο

Το ζήτημα της ρύθμισης του φωτισμού κατά το μήκος ενός αυτοκινητόδρομου παρουσιάζει αρκετό ενδιαφέρον. Στον πυρήνα του πρόκειται για την εύρεση του σημείου ισορροπίας μεταξύ ασφαλείας της χρήσης του δρόμου και της απαιτούμενης κατανάλωσης ενέργειας [Fano20, Pal19].

Ο λειτουργός του αυτοκινητόδρομου θέλει να ελαχιστοποιήσει το κόστος της λειτουργίας της οδού όσο το δυνατόν περισσότερο. Ωστόσο, ο φωτισμός είναι απαραίτητος για την ασφάλεια των χρηστών, ενώ τυπικά αποτελεί δέσμευση το να βρίσκεται πάνω από κάποια προκαθορισμένα όρια ανάλογα με το τρέχον επίπεδο κίνησης των οχημάτων.

Παράλληλα, η μεταβολή του φωτισμού δεν μπορεί να πραγματοποιηθεί στιγμιαία, αλλά χρειάζεται ένα διάστημα περίπου 10 λεπτών για να φτάσει το επιθυμητό επίπεδο, ενώ δεν είναι συμφέρον να μεταβάλλεται διαρκώς.

Υπό το πρίσμα αυτό, αποκτά πολύ μεγάλη αξία η ύπαρξη ενός προληπτικού και ευφυούς συστήματος ελέγχου, το οποίο χρησιμοποιεί την τρέχουσα κατάσταση του δρόμου (παραδείγματος χάρη αν έχει υπάρξει κάποιο ατύχημα) και την τρέχουσα κίνηση και κάνει πρόβλεψη για ένα σύντομο χρονικό διάστημα στο μέλλον (λ.χ. για τις επόμενες 1-2 ώρες). Αναλόγως με την πρόβλεψη αυτή, δίνεται στον λειτουργό με έναν υψηλό βαθμό αξιοπιστίας η δυνατότητα να μειώσει κατάλληλα το επίπεδο φωτισμού. Με τον τρόπο αυτό, μπορεί να περιορίζει σημαντικά το κόστος λειτουργίας, καθώς και να συμβάλλει στην εξοικονόμηση ενεργειακών πόρων, χωρίς να τίθεται σε κίνδυνο η ασφάλεια της οδού.

Αντικείμενο της παρούσας εργασίας είναι η πραγματοποίηση δοκιμών, με χρήση πραγματικών δεδομένων της εταιρίας παραχώρησης αυτοκινητοδρόμων ΟΛΥΜΠΙΑ ΟΔΟΣ Α.Ε. για το έτος 2018, διάφορων αρχιτεκτονικών μηχανικής μάθησης, οι οποίες είναι ικανές να πραγματοποιούν πρόβλεψη κίνησης ως μέρος ενός συστήματος δυναμικής προσαρμογής του φωτισμού, όπως αυτό που περιγράφηκε παραπάνω.



## Κεφάλαιο 3

# Τεχνικές Μηχανικής Μάθησης

### 3.1 Μηχανική μάθηση

Η *μηχανική μάθηση* (machine learning), ως επιστήμη, είναι κλάδος της *τεχνητής νοημοσύνης* (arti-ficial intelligence), μελετάει μοντέλα και υπολογιστικούς αλγορίθμους οι οποίοι δύνανται να βελτιώνονται από μόνοι τους μέσω συλλογής και αφομοίωσης εμπειρίας [Hayk09]. Ως εμπειρία λογίζεται οποιαδήποτε πληροφορία μπορεί να αξιοποιηθεί από έναν αλγόριθμο ώστε να βελτιώσει την επίδοσή του ως προς ένα πρόβλημα βάσει κάποιας μετρικής.

Η μηχανική μάθηση χρησιμοποιείται συνήθως σε προβλήματα για τα οποία δεν υπάρχουν αλγόριθμοι που να δίνουν μία πλήρη και ικανοποιητική λύση, ή υπάρχουν μεν, αλλά έχουν πολύ υψηλό (χρονικό ή και χωρικό) κόστος εκτέλεσης, οπότε η χρήση τους είναι από δύσκολη έως αδύνατη.

Η μηχανική μάθηση διακρίνεται σε 3 βασικές κατηγορίες: την *επιβλεπόμενη μάθηση* (supervised learning), τη *μη-επιβλεπόμενη μάθηση* (unsupervised learning) και την *ενισχυτική μάθηση* (reinforce-ment learning).

#### 3.1.1 Επιβλεπόμενη μάθηση

Στην επιβλεπόμενη μηχανική μάθηση, το σύστημα έχει στη διάθεση του ένα σύνολο δεδομένων εισόδου μαζί με την *ετικέτα* (label) που χαρακτηρίζει κάθε ένα *δείγμα* (sample) από αυτά. Η ετικέτα μπορεί να είναι κάποια αριθμητική ή κατηγορική τιμή. Στόχος του συστήματος είναι να κατασκευάσει μία διαδικασία αντιστοίχισης των δειγμάτων τις εισόδου με τις αντίστοιχες ετικέτες τους [Bish06].

Κατά την διαδικασία εκπαίδευσης, τα δεδομένα τροφοδοτούνται στο σύστημα. Για κάθε ένα δείγμα, το δίκτυο υπολογίζει την έξοδό του, και την συγκρίνει με την επιθυμητή ετικέτα. Η διαφορά των δύο αυτών τιμών είναι το σφάλμα εκπαίδευσης. Ανάλογα με τον αλγόριθμο εκπαίδευσης που χρησιμοποιείται, το δίκτυο αξιοποιεί το σφάλμα ώστε να ενημερώσει την κατάστασή του, με αποτέλεσμα η νέα έξοδος να προσεγγίζει καλύτερα την επιθυμητή. Με τον τρόπο αυτό το δίκτυο προσαρμόζεται διαρκώς στο σύνολο των δεδομένων εισόδου και μαθαίνει να παράγει την ζητούμενη έξοδο.

Ο αλγόριθμος που χρησιμοποιείται κατά κόρον για την εκπαίδευση είναι ο αλγόριθμος *οπισθοδιάδοσης σφάλματος* (back-propagation) ή παραλλαγές αυτού [Albe18]. Ο αλγόριθμος back-propagation παρουσιάζεται αναλυτικότερα στην συνέχεια.

Ίδιον γνώρισμα της επιβλεπόμενης μάθησης είναι ότι για την εκπαίδευση απαιτείται ένα σύνολο δεδομένων για το οποίο γνωρίζουμε εκ των προτέρων την επιθυμητή έξοδο.

Τα κυριότερα προβλήματα στα οποία χρησιμοποιείται η επιβλεπόμενη μάθηση είναι τα εξής:

- *Ταξινόμησης* (Classification): Με είσοδο τα χαρακτηριστικά ενός στοιχείου, το μοντέλο πρέπει να αποφανθεί για την κατηγορία στην οποία αυτό ανήκει.
- *Πρόβλεψης* (Prediction): Εμφανίζεται με δύο μορφές, ανάλογα την φύση του προβλήματος. Μπορεί να αφορά πρόβλεψη μιας ιδιότητας δεδομένων κάποιων χαρακτηρι-

στικών, ή μελλοντική πρόβλεψη κάποιας αριθμητικής τιμής με γνωστή την εξέλιξή της στο παρελθόν.

- *Διερμηνείας* (Interpretation): Αφορά την απόδοση χαρακτηρισμών σε ένα στοιχείο, δεδομένων κάποιων χαρακτηριστικών του. Θα μπορούσε να θεωρηθεί και γενικότερη περίπτωση των προβλημάτων ταξινόμησης.

### 3.1.2 Μη επιβλεπόμενη μάθηση

Στη μη-επιβλεπόμενη μάθηση, στόχος είναι η ομαδοποίηση και η αναζήτηση συσχετίσεων και κοινών χαρακτηριστικών σε ένα σύνολο δεδομένων για τα δείγματα του οποίου δεν υπάρχουν ετικέτες [Hayk09]. Αφαιρετικά, οι αλγόριθμοι μη-επιβλεπόμενης μάθησης επιτρέπουν την μοντελοποίηση συναρτήσεων πυκνότητας πιθανότητας πάνω από μία άγνωστη συλλογή δεδομένων.

Η μη-επιβλεπόμενη μάθηση χρησιμοποιείται κυρίως σε προβλήματα:

- *Ανάλυσης συσχετίσεων* (Association analysis): Αναζήτηση και εξαγωγή συσχετίσεων μεταξύ διαφορετικών αντικειμένων.
- *Ομαδοποίησης* (Clustering): Οργάνωση των διαφορετικών στοιχείων ενός συνόλου δεδομένων σε διακριτές ομάδες, ως προς κάποιο κοινό χαρακτηριστικό τους. Το χαρακτηριστικό ως προς το οποίο γίνεται η ομαδοποίηση συχνά αποτελεί επίσης ζήτησιμο του προβλήματος.

### 3.1.3 Ενισχυτική μάθηση

Στην ενισχυτική μάθηση [Kael96], το σύστημα βρίσκεται σε ένα δυναμικό περιβάλλον, από το οποίο λαμβάνει διαρκώς ερεθίσματα, και μέσω άμεσης αλληλεπίδρασης μαθαίνει μια στρατηγική αποφάσεων προκειμένου να προσαρμόζεται σε αυτό.

Χαρακτηριστικές πεδία στα οποία εφαρμόζεται η ενισχυτική μάθηση είναι τα προβλήματα *σχεδιασμού* (planning) με ελάχιστη *ανάδραση* (feedback), όπως για παράδειγμα ο αυτόματος έλεγχος της κίνησης ενός ρομπότ.

## 3.2 Τεχνητά νευρωνικά δίκτυα

Τα *τεχνητά νευρωνικά δίκτυα* (ΤΝΔ, artificial neural networks - ANN) αποτελούν μια από τις πιο διαδεδομένες τεχνικές μηχανικής μάθησης. Πρόκειται για μια σειρά αλγορίθμων που επιχειρούν να αναγνωρίσουν αλληλουχίες και συσχετίσεις σε ένα σύνολο δεδομένων, μέσω διαδικασιών οι οποίες μιμούνται τον βιολογικό τρόπο λειτουργίας του ανθρώπινου εγκεφάλου [Bish06]. Στην πράξη έχουν αναπτυχθεί πολλές κατηγορίες ΤΝΔ, τα οποία αντιμετωπίζουν μία πληθώρα προβλημάτων μηχανικής μάθησης.

### 3.2.1 Λειτουργίες τεχνητών νευρωνικών δικτύων

Από μια αφαιρετική σκοπιά, τα ΤΝΔ μπορούν να επιτελούν δύο βασικές λειτουργίες:

- *Εκπαίδευση* (Training): Κατά την εκπαίδευση, το δίκτυο τροφοδοτείται από μία *συλλογή δεδομένων εκπαίδευσης* (training dataset). Για το σύνολο των δεδομένων αυτών, επαναληπτικά, το δίκτυο ενημερώνει την εσωτερική του κατάσταση ούτως ώστε αυτή να ανταποκρίνεται όσο το δυνατόν πιο πιστά στα δεδομένα.
- *Συμπερασματολογία* (Inference): Το δίκτυο δέχεται ένα ερέθισμα εισόδου και παράγει μία έξοδο, αξιοποιώντας την γνώση που έχει συσσωρεύσει κατά την εκπαίδευσή του.

### 3.2.2 Τεχνητοί νευρώνες

Στοιχειώδης δομική μονάδα των ΤΝΔ είναι οι *τεχνητοί νευρώνες* (artificial neurons) [Hayk09]. Πρόκειται για εννοιολογικές δομές η μορφή και η λειτουργία των οποίων είναι εμπνευσμένη από τη μορφή και την λειτουργία των νευρώνων του ανθρώπινου εγκεφάλου, όπως αυτοί είναι γνωστοί από την βιολογία.

Τα βασικά συστατικά στοιχεία ενός τεχνητού νευρώνα είναι:


- Ένα σύνολο *συνάψεων* εισόδου, κάθε μία από τις οποίες αντιστοιχίζεται με ένα *βάρος* (weight)  $w_i$ , το οποίο μοντελοποιεί την σημαντικότητα, ή την συνεισφορά της εκάστοτε εισόδου στην ενεργοποίηση του νευρώνα.
- Ένας κεντρικός κόμβος υπολογισμού. Για κάθε σύναψη υπολογίζεται το γινόμενο της εισόδου  $x_i$  με το αντίστοιχο βάρος  $w_i$ . Τα επιμέρους γινόμενα αθροίζονται, και στο αποτέλεσμα προστίθεται ένας σταθερός όρος  $b$ , ο οποίος ονομάζεται *πόλωση ή κατώφλι* (bias). Το άθροισμα που προκύπτει είναι η ενεργοποίηση του νευρώνα, και φαίνεται στη Σχέση 3.1:

$$u = \sum x_i * w_i + b \quad (3.1)$$

- Η *συνάρτηση ενεργοποίησης* (activation function)  $\phi(u)$ . Αυτή είναι μία μη γραμμική συνάρτηση η οποία εφαρμόζεται στην συνολική ενεργοποίηση  $u$  του νευρώνα. Το αποτέλεσμα που προκύπτει από την πράξη αυτή είναι η έξοδος  $y$  του νευρώνα, και φαίνεται στη Σχέση 3.2.

$$y = \phi(u) = \phi(\sum x_i * w_i + b) \quad (3.2)$$

Στο Σχήμα 3.1 απεικονίζεται διαγραμματικά η τυπική μορφή ενός τεχνητού νευρώνα.



**Σχήμα 3.1:** Διαγραμματική απεικόνιση ενός τεχνητού νευρώνα

Με βάση τα παραπάνω, η εκπαίδευση του νευρώνα ορίζεται ως η διαδικασία προσαρμογής των μεταβλητών παραμέτρων του νευρώνα (των βαρών  $w_i$  των διαφόρων συνάψεων του, καθώς και της πόλωσης  $b$  αυτού), ούτως ώστε η έξοδος του, όπως αυτή υπολογίζεται από την Σχέση 3.2 να προσεγγίζει όσο το δυνατόν πιο πιστά την επιθυμητή έξοδο  $\bar{y}$  για τις διάφορες εισόδους του.

### 3.2.3 Συνάρτηση Ενεργοποίησης

Η συνάρτηση ενεργοποίησης  $\phi(u)$  του νευρώνα μπορεί να είναι μια οποιαδήποτε μη γραμμική συνάρτηση [Hayk09]. Στην πράξη, χρησιμοποιούνται σιγμοειδείς συναρτήσεις, καθώς έχουν μαθηματικές ιδιότητες πολύ χρήσιμες για τη διαδικασία της μάθησης, όπως το ότι είναι συνεχείς σε όλο το πεδίο ορισμού τους, φραγμένες και γνησίως μονότονες (συνήθως αύξουσες). Τέλος, μία κρίσιμη σημασίας ιδιότητά τους είναι ότι είναι παραγωγίσιμες, συνεπώς επιτρέπουν την χρήση του κανόνα της αλυσίδας στην Σχέση 3.2, έτσι ώστε να μπορεί να εφαρμοστεί ο αλγόριθμος οπισθοδιάδοσης του σφάλματος για την εκπαίδευσή τους.

Τυπικές συναρτήσεις ενεργοποιήσεων που χρησιμοποιούνται στην πλειοψηφία των εφαρμογών είναι οι εξής [Hayk09]:

- Ημιγραμμική (ReLU)

$$\phi(u) = u^+ = \max(0, u) = \begin{cases} 0, & u < 0 \\ u, & u \geq 0 \end{cases}$$

- Υπερβολική Εφαπτομένη

$$\phi(u) = \tanh(u), u \in R$$

- Λογιστική

$$\phi(u) = \text{sigmoid}(u) = \frac{1}{1 + e^{-u}}, u \in R$$

- Τόξο εφαπτομένης (arctan)

$$\phi(u) = \arctan(u), u \in R$$

- Βηματική (step)

$$\phi(u) = \text{step}(u) = \begin{cases} 0, & u < 0 \\ 1, & u \geq 0 \end{cases}$$


Στο Σχήμα 3.2 φαίνεται η γραφική παράσταση των κυριότερων αυτών συναρτήσεων ενεργοποίησης στο διάστημα  $[-1, 1]$ . Αξίζει σε αυτό το σημείο να τονιστεί η διαφορά της μορφής των συναρτήσεων αυτών, η οποία έγκειται κυρίως στην συμπεριφορά της κλίσης τους γύρω από το 0. Η βηματική ( $\text{step}(u)$ ) έχει μηδενική κλίση σε όλα τα σημεία εκτός του 0, όπως ισχύει και τις αρνητικές τιμές της ημιγραμμικής ( $\text{relu}(u)$ ). Αυτό σημαίνει ότι μία πολύ μικρή μεταβολή στην ενεργοποίηση  $u$  όταν αυτή είναι κοντά στο 0 έχει έντονη επίδραση στην τιμή εξόδου του νευρώνα. Αντίθετα, το τόξο εφαπτομένης ( $\text{atan}(u)$ ), η υπερβολική εφαπτομένη ( $\text{tanh}(u)$ ) και ακόμη περισσότερο η λογιστική ( $\text{logistic}(u)$ ) έχουν πολύ ομαλή κλίση σε όλο το διάστημα  $[-1, 1]$ , με αποτέλεσμα η μεταβολή της τιμής εξόδου να είναι σχετικά πιο ήπια όσο μεταβάλλεται η ενεργοποίηση του νευρώνα.

### 3.2.4 Νευρωνικά δίκτυα πρόσθιας τροφοδότησης

Ένα νευρωνικό δίκτυο καθορίζεται από το σύνολο των νευρώνων που το αποτελούν, καθώς και τον τρόπο με τον οποίο αυτοί οργανώνονται και συνδέονται μέσω των διάφορων συνάψεων.

Στην πλέον συνηθισμένη μορφή των νευρωνικών δικτύων, οι νευρώνες οργανώνονται σε μία σειρά από διαδοχικά επίπεδα (layers). Το πρώτο επίπεδο του δικτύου ονομάζεται





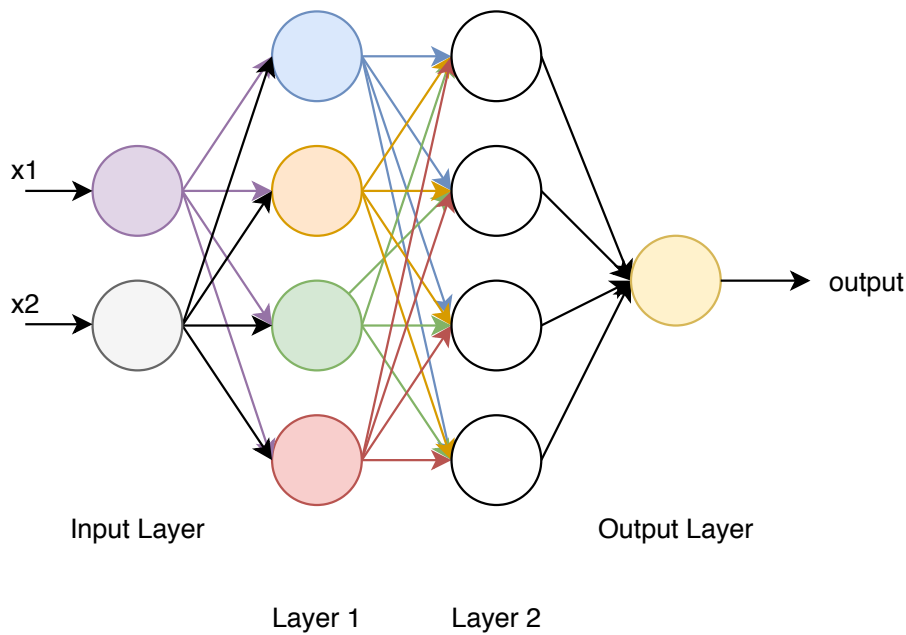
**Σχήμα 3.2:** Γραφική Παράσταση Κυριότερων Συναρτήσεων Ενεργοποίησης

επίπεδο εισόδου (input layer), καθώς είναι αυτό που λαμβάνει ως ερέθισμα εξωτερικά δεδομένα. Το τελευταίο επίπεδο αποτελεί το *επίπεδο εξόδου* (output layer), στο οποίο υπολογίζεται και επιστρέφεται η έξοδος του νευρωνικού δικτύου. Ανάμεσα στα δύο αυτά μπορεί να υπάρχουν ένα ή περισσότερα *κρυφά επίπεδα* (hidden layers) νευρώνων, ανάλογα με την δομή του δικτύου [Hayk09].

Οι νευρώνες των διάφορων επιπέδων του νευρωνικού δικτύου συνδέονται μεταξύ τους μέσω των συνάψεων. Ο νευρώνας  $j$  του επιπέδου  $K$  δέχεται εισόδους  $x_i$  από τους νευρώνες του επιπέδου  $K - 1$  με τους οποίους συνδέεται με βάρη  $w_i$ , υπολογίζει την έξοδο του  $y_j$  με τον τρόπο που αναφέρθηκε στην προηγούμενη ενότητα και την μεταφέρει ως είσοδο στους νευρώνες του επόμενου επιπέδου  $K + 1$  [Hayk09].

Στο Σχήμα 3.3 απεικονίζεται ένα νευρωνικό δίκτυο δύο εισόδων και μίας εξόδου, με την μορφή που περιγράφηκε προηγουμένως. Το νευρωνικό αυτό δίκτυο έχει δύο νευρώνες στο επίπεδο εισόδου (έναν για κάθε είσοδο) και έναν νευρώνα στο επίπεδο εξόδου (γιατί έχει μία μόνο έξοδο). Το δίκτυο διαθέτει επίσης δύο κρυφά επίπεδα με 4 νευρώνες το καθένα. Από το σχήμα έχουν παραληφθεί τα βάρη των συνάψεων για λόγους απλότητας και καθαρότητας.

Η μορφή των συνάψεων ανάμεσα σε δύο επίπεδα μπορεί να ποικίλλει [Bish06]. Συνήθως, κάθε ένας από τους νευρώνες του επιπέδου  $N$  συνδέεται με όλους τους νευρώνες του επιπέδου  $N+1$ , δημιουργώντας ένα *πλήρες συνδεδεμένο* (fully connected) πλέγμα, όπως στο παράδειγμα του Σχήματος 3.3. Σε άλλες αρχιτεκτονικές, μπορεί πολλοί νευρώνες ενός επιπέδου να συνδέονται με έναν μόνο νευρώνα του επόμενου, ή να υπάρχουν νευρώνες οι οποίοι προωθούνται άμεσα σε κάποιο άλλο από τα επόμενα επίπεδα του δικτύου.



**Σχήμα 3.3:** Παράδειγμα νευρωνικού δικτύου πρόσθιας τροφοδότησης

Συνολικά, τα δίκτυα αυτής της μορφής ονομάζονται *νευρωνικά δίκτυα πρόσθιας διάδοσης* (feed-forward neural networks) [Bish06], καθώς οι νευρώνες τους σχηματίζουν έναν *κατευθυνόμενο ακυκλικό γράφο* (directed acyclic graph - DAG), και η ροή της πληροφορίας από την είσοδο έως την έξοδο του δικτύου ακολουθεί μία και μόνο μία κατεύθυνση.

### 3.2.5 Υπερπαράμετροι

Οι *υπερπαράμετροι* (hyperparameters) είναι σταθερές οι οποίες επιλέγονται ή καθορίζονται κατά τη δημιουργία του νευρωνικού δικτύου (πριν την εκπαίδευσή του) και μεταβάλλουν ποιοτικά και ποσοτικά την συμπεριφορά του και την ικανότητα εκπαίδευσής του. Η σωστή επιλογή τους απαιτεί έναν συνδυασμό πείρας και εκτεταμένων δοκιμών και είναι καθοριστική για την ορθή εκπαίδευση και λειτουργία του νευρωνικού δικτύου.

Τυπικές υπερπαράμετροι ενός νευρωνικού δικτύου είναι [Hayk09]:

- **Ο αριθμός των νευρώνων στα επίπεδα εισόδου και εξόδου του δικτύου.** Αυτοί συνήθως καθορίζονται από την μορφή των διαθέσιμων δεδομένων εισόδου και εξόδου.
- **Ο αριθμός των κρυφών επιπέδων του νευρωνικού δικτύου.** Κατά κανόνα, η προσθήκη κρυφών επιπέδων σε ένα νευρωνικό δίκτυο του επιτρέπει να αναγνωρίζει αντικείμενα, πρότυπα, μοτίβα ή συσχετίσεις υψηλότερου επιπέδου. Ωστόσο, την ίδια στιγμή αυξάνει σημαντικά τον συνολικό αριθμό παραμέτρων του, καθιστώντας έτσι πολύ δυσκολότερη την εκπαίδευσή του.
- **Ο αριθμός των νευρώνων σε κάθε ένα από τα κρυφά επίπεδα του δικτύου.** Όπως και πριν, αύξηση του του αριθμού των νευρώνων θεωρητικά αυξάνει τη χωρητικότητα του δικτύου, οπότε αυτό έχει τη δυνατότητα να αναγνωρίζει πιο σύνθετες μορφές δεδομένων.
- **Η συνάρτηση ενεργοποίησης που χρησιμοποιείται στους νευρώνες κάθε επιπέδου του δικτύου.**
- **Οι αρχικές τιμές των παραμέτρων του δικτύου,** δηλαδή των βαρών των συνάψεων μέσω των οποίων συνδέονται οι νευρώνες του δικτύου και οι πολώσεις αυτών. Οι

αρχικές τιμές δύναται να είναι μηδενικές (σπάνια), να λαμβάνουν τιμές με δειγματοληψία από κάποια τυχαία κατανομή (συνήθως κανονική ή ομοιόμορφη), ή να καθορίζονται βάσει κάποιας συγκεκριμένης προηγούμενης γνώσης. Η τελευταία περίπτωση παρουσιάζει αρκετό ενδιαφέρον και στην βιβλιογραφία αναφέρεται συχνά ως *μεταφορά γνώσης* (transfer learning), ενώ είναι αντικείμενο πλούσιας έρευνας από την ακαδημαϊκή κοινότητα, τόσο στο παρελθόν όσο και τα τελευταία χρόνια [Tan18, Wang20].

- **Ο αλγόριθμος εκπαίδευσης.** Κατά βάση χρησιμοποιούνται αλγόριθμοι βελτιστοποίησης *κατάβασης κλίσης* (gradient descent). Σε προβλήματα επιβλεπόμενης μάθησης, συνήθως χρησιμοποιείται ο αλγόριθμος οπισθοδιάδοσης σφάλματος ή κάποια παραλλαγή αυτού.
- **Ο ρυθμός εκπαίδευσης.** Ένας γρήγορος ρυθμός εκπαίδευσης μπορεί να οδηγήσει πιο γρήγορα σε σύγκλιση του δικτύου, θυσιάζοντας μέρος της ακρίβειάς του. Αντίθετα, με έναν μικρότερο ρυθμό εκπαίδευσης η εκπαίδευση χρειάζεται περισσότερο χρόνο, αλλά έχει καλύτερες προοπτικές για υψηλότερη ακρίβεια.
- **Η συνάρτηση κόστους (cost function)** που χρησιμοποιείται κατά την εκπαίδευση. Η εκπαίδευση ενός νευρωνικού δικτύου αποτελεί κατά βάση ένα πρόβλημα βελτιστοποίησης. Δεδομένου ότι όλη η διαδικασία στοχεύει στην ελαχιστοποίηση ενός αντικειμενικού σφάλματος, ο τρόπος υπολογισμού του παίζει καθοριστικό ρόλο. Σε προβλήματα επιβλεπόμενης μάθησης, η συνάρτηση κόστους είναι μία μετρική απόκλισης από την (γνωστή εκ των προτέρων) επιθυμητή έξοδο, όπως το *μέσο τετραγωνικό σφάλμα* (mean squared error) ή *κόστος διασταυρούμενης εντροπίας* (cross-entropy loss). Σε προβλήματα μη-επιβλεπόμενης μάθησης, η επιθυμητή έξοδος δεν είναι γνωστή, συνεπώς ως συνάρτηση κόστους τυπικά χρησιμοποιείται κάποια μετρική της στατιστικής διασποράς των εξόδων του δικτύου.

### 3.2.6 Επαναληπτικά νευρωνικά δίκτυα

Η έρευνα γύρω από τα νευρωνικά δίκτυα έχει οδηγήσει και στην πρόταση αρχιτεκτονικών στις οποίες επιτρέπεται νευρώνες να συνδέονται με άλλους νευρώνες στο ίδιο ή και σε προηγούμενα επίπεδα του δικτύου, δημιουργώντας έτσι κλειστούς βρόγχους. Στη βιβλιογραφία αυτά αναφέρονται ως *επαναληπτικά νευρωνικά δίκτυα* (recurrent neural networks - RNN) [Hayk09]. Οι συνάψεις των νευρώνων σε αυτά τα δίκτυα δημιουργούν κλειστούς κύκλους, ιδιότητα που προσφέρει την ικανότητα ανάλυσης δεδομένων στα οποία εισάγεται ο παράγοντας του χρόνου. Για το λόγο αυτό, τα επαναληπτικά νευρωνικά δίκτυα χρησιμοποιούνται κατά κύριο λόγο σε προβλήματα ανάλυσης χρονοσειρών.

### 3.2.7 Αρχιτεκτονικές νευρωνικών δικτύων

Το σημείο που πρέπει να τονιστεί ιδιαίτερα είναι ότι η αρχιτεκτονική των νευρωνικών δικτύων είναι ένα ανοιχτό πρόβλημα, γύρω από το οποίο η ακαδημαϊκή κοινότητα διεξάγει διαρκώς πρωτότυπη έρευνα. Είναι άτοπο να γίνεται λόγος για «ιδανική» αρχιτεκτονική· όπως έχει ήδη φανεί από τα προηγούμενα, υπάρχουν ποικίλες μορφές νευρωνικών δικτύων οι οποίες είναι σε διαφορετικούς βαθμούς κατάλληλες για τα διάφορα προβλήματα μηχανικής μάθησης.

Οι «κλασσικές» μορφές νευρωνικών δικτύων ήταν άμεσα εμπνευσμένες από την μελέτη της λειτουργίας του ανθρώπινου εγκεφάλου. Πράγματι, τα μοντέλα που ιστορικά προτάθηκαν και πυροδότησαν ολόκληρο τον τομέα της μηχανικής μάθησης προσπαθούσαν να μοντελοποιήσουν με μαθηματικό τρόπο την λειτουργία των βιολογικών νευρώνων του ανθρώπινου σώματος. Ωστόσο, τα τελευταία χρόνια έχει αρχίσει να ανθεί μια νέα

κατεύθυνση, αυτή της αναζήτησης αρχιτεκτονικών νευρωνικών δικτύων (neural network architecture search) [Elsk18] στην οποία γίνεται χρήση νευρωνικών δικτύων για την εξερεύνηση νέων αρχιτεκτονικών νευρωνικών δικτύων, με τα πρώτα αποτελέσματα να μοιάζουν πολλά υποσχόμενα.

### 3.3 Εκπαίδευση νευρωνικών δικτύων

Η *εκπαίδευση* (training) ενός νευρωνικού δικτύου είναι η διαδικασία κατά την οποία ρυθμίζονται οι παράμετροι του δικτύου έτσι ώστε η έξοδος να προσεγγίζει όσο το δυνατόν καλύτερα την επιθυμητή. Αυτοί οι παράμετροι τυπικά είναι τα βάρη των συνάψεων και οι πολώσεις των νευρώνων του [Hayk09].

Για την διαδικασία της εκπαίδευσης απαιτείται μία *συλλογή δεδομένων εκπαίδευσης* (training dataset, ή απλά dataset), το οποίο αποτελείται από επιμέρους δείγματα δεδομένων που παρουσιάζονται στο δίκτυο. Για κάθε ένα δείγμα, το νευρωνικό δίκτυο υπολογίζει την αντίστοιχη έξοδο και το σφάλμα, βάσει της συνάρτησης κόστους που έχει επιλεγεί. Το σφάλμα αξιοποιείται από το δίκτυο έτσι ώστε να ενημερώσει κατάλληλα τα βάρη και τις ενεργοποιήσεις του, με αποτέλεσμα η νέα έξοδος να προσεγγίζει καλύτερα την επιθυμητή. Κατά τη διάρκεια της εκπαίδευσης, το δίκτυο χρησιμοποιεί επαναληπτικά το σύνολο των δεδομένων εκπαίδευσης. Κάθε μία επανάληψη ονομάζεται μία *εποχή* (epoch) εκπαίδευσης. Στο τέλος κάθε εποχής υπολογίζεται το συνολικό σφάλμα του δικτύου.

Η διαδικασία της εκπαίδευσης τερματίζει όταν ικανοποιηθεί μία από τις προκαθορισμένες συνθήκες τερματισμού της, όπως οι παρακάτω [Bish06]:

- **Η σύγκλιση του συνολικού σφάλματος εκπαίδευσης** σε μία συγκεκριμένη τιμή.
- **Η επίτευξη ενός προκαθορισμένου στόχου ακρίβειας του δικτύου.**
- **Το πέρας ενός προκαθορισμένου αριθμού εποχών εκπαίδευσης.**
- **Το πέρας ενός προκαθορισμένου χρονικού ορίου.** Αυτή η συνθήκη συνήθως χρησιμοποιείται προκειμένου να εξασφαλιστεί ότι η εκπαίδευση του δικτύου θα τερματίσει σε πεπερασμένο αριθμό βημάτων.

#### 3.3.1 Ο αλγόριθμος οπισθοδιάδοσης του σφάλματος

Ο *αλγόριθμος οπισθοδιάδοσης σφάλματος* (back-propagation) είναι ο πλέον διαδεδομένος αλγόριθμος εκπαίδευσης για τα ΤΝΔ. Προτάθηκε για πρώτη φορά το 1970, με διαφορετικό όνομα από το σημερινό [Linn70], ενώ η περαιτέρω εξέλιξή του [Werb74, Rume86] τον θεμελίωσαν ως τον βασικότερο αλγόριθμο εκπαίδευσης. Η αξία του είναι βαθιά ιστορική, καθώς είναι ο αλγόριθμος που εισήγαγε την έννοια της «αυτόματης» εκπαίδευσης ενός νευρωνικού δικτύου, αναζωογονώντας και πυροδοτώντας ένα κύμα έρευνας γύρω από τα νευρωνικά δίκτυα στις αρχές της δεκαετίας του 1980.

Μέχρι και σήμερα, παραμένει ένας από τους αποτελεσματικότερους αλγορίθμους εκπαίδευσης νευρωνικών δικτύων πρόσθιας διάδοσης. Έχουν προταθεί κατά καιρούς πιθανές βελτιώσεις του [Beng94, Liao15], χωρίς όμως να έχουν τύχει ευρείας αποδοχής καθώς σε πρακτικές εφαρμογές δεν βελτιώνουν το αποτέλεσμα, ενώ συχνά επιδρούν και αρνητικά σε αυτό [Albe18]. Επιπλέον, γενικεύσεις του όπως ο *αλγόριθμος οπισθοδιάδοσης σφάλματος στο χρόνο* (back-propagation through time - BPTT) [Werb90], χρησιμοποιούνται με μεγάλη επιτυχία σε ένα μεγάλο εύρος νευρωνικών δικτύων στα οποία ο απλός αλγόριθμος δεν μπορεί να εφαρμοστεί.

Η λειτουργία του αλγορίθμου στηρίζεται στην εφαρμογή του κανόνα της αλυσίδας για την δυναμική προσαρμογή των βαρών σε κάθε επίπεδο του δικτύου για κάθε εποχή εκπαίδευσης, αξιοποιώντας το σφάλμα που έχει προκύψει στα προηγούμενα. Απαραίτητη

προϋπόθεση για αυτό είναι οι συναρτήσεις ενεργοποίησης των νευρώνων να είναι παραγωγίσιμες.

Για κάθε μία εποχή εκπαίδευσης, ο υπολογισμός του σφάλματος ξεκινάει από το επίπεδο εξόδου του δικτύου. Αρχικά, παρουσιάζεται στο δίκτυο το διάνυσμα εισόδων  $\bar{X}$ , βάσει του οποίου υπολογίζεται το διάνυσμα εξόδου  $Y$  του δικτύου. Από τα δεδομένα εκπαίδευσης, γνωρίζουμε επίσης το διάνυσμα της επιθυμητής εξόδου  $\bar{Y}$ . Συνεπώς, μπορούμε για κάθε νευρώνα  $i$  του επιπέδου εξόδου να υπολογίσουμε το αντίστοιχο σφάλμα, όπως φαίνεται στη Σχέση 3.3:

$$e_i = |y_i - \bar{y}_i| \quad (3.3)$$

Στη συνέχεια, δεδομένης της ενεργοποίησης  $u_{ij}$  και της συνάρτησης ενεργοποίησης  $\phi(u)$ , μπορούμε να υπολογίσουμε τα σταθμισμένα σφάλματα  $d_{ij}$  για κάθε μία από τις εισόδους  $j$  του νευρώνα  $i$  στο επίπεδο εξόδου, σύμφωνα με τη Σχέση 3.4:

$$d_{ij} = e_i * \frac{d\phi}{du}(u_{ij}) \quad (3.4)$$

Με τον τρόπο αυτό, καταφέρνουμε να αποδώσουμε το συνολικό σφάλμα  $e_i$  του νευρώνα σε κάθε μία από τις εισόδους του.

Έπειτα, για την οπισθοδιάδοση του σφάλματος στο προηγούμενο επίπεδο του δικτύου, θεωρούμε ως σφάλμα του νευρώνα  $i$  στο επίπεδο  $j - 1$  το άθροισμα των σταθμισμένων σφαλμάτων των νευρώνων  $k$  του επιπέδου  $j$  που οφείλονται σε αυτό, πολλαπλασιασμένα με το βάρος  $w_{i(j-1),kj}$  που αντιστοιχεί στην κάθε σύναψη. Έτσι, παίρνουμε την Σχέση 3.5:

$$d_{i(j-1)} = \frac{da}{du}(u_{i(j-1)}) * \sum_k d_{kj} * w_{i(j-1),kj} \quad (3.5)$$

Εφαρμόζοντας επαναληπτικά την Σχέση 3.5 μπορούμε να διαδώσουμε το σφάλμα από το επίπεδο της εξόδου σε όλα τα προηγούμενα, και μάλιστα να το κάνουμε αποδίδοντας διαφορετικό «μερίδιο ευθύνης» του σφάλματος στα διάφορα βάρη του δικτύου, αναλογικά με το βαθμό στον οποίο έχουν συνεισφέρει στο σφάλμα αυτό.

Το τελευταίο βήμα που απομένει, είναι να προσαρμόσουμε τα βάρη του δικτύου βάσει των σταθμισμένων σφαλμάτων  $d_{ij}$  του κάθε νευρώνα. Για την σύναψη που συνδέει τον νευρώνα  $i$  του επιπέδου  $j$  με τον νευρώνα  $k$  του επιπέδου  $j - 1$  με βάρος  $w_{ij,k(j-1)}$ , η μεταβολή του βάρους υπολογίζεται από την Σχέση 3.6:

$$\Delta w_{ij,k(j-1)} = -r * d_{ij} * y_{k(j-1)} \quad (3.6)$$

Ο όρος  $y_{k(j-1)}$  είναι η τιμή εξόδου του νευρώνα  $k$  στο επίπεδο  $j - 1$ . Περισσότερο ενδιαφέρον έχει ο όρος  $r$ , ο οποίος παίρνει θετικές τιμές και αποτελεί τον *ρυθμό εκπαίδευσης* (learning rate) του δικτύου. Ο ρυθμός εκπαίδευσης  $r$  μπορεί να είναι σταθερός, ή να μεταβάλλεται ως φθίνουσα συνάρτηση του αριθμού εποχών εκπαίδευσης που έχουν ολοκληρωθεί. Η ιδέα πίσω από αυτό είναι ότι στα πρώτα βήματα της εκπαίδευσης θέλουμε τα βάρη να μεταβάλλονται σημαντικά, ούτως ώστε το δίκτυο να προσαρμοστεί γρήγορα στα δεδομένα εκπαίδευσης. Έπειτα, ο ρυθμός μειώνεται, τα βάρη μεταβάλλονται λιγότερο και έτσι το δίκτυο μπορεί να κάνει την *τελική προσαρμογή* (fine-tuning) στα δεδομένα.

### 3.3.2 Παράγοντες που επηρεάζουν την ποιότητα της εκπαίδευσης

Η εκπαίδευση ενός εύρωστου νευρωνικού δικτύου είναι πολύπλοκη διαδικασία και επηρεάζεται από μία πληθώρα παραγόντων [Bish06]:

- **Η αξιοπιστία και η πληρότητα των δεδομένων εκπαίδευσης.** Κατά την διαδικασία της εκπαίδευσης, το νευρωνικό δίκτυο «μαθαίνει» μια συνάρτηση απεικόνισης των

εισόδων του σε επιθυμητές ή ζητούμενες εξόδους. Είναι σημαντικό να τονιστεί η διάκριση μεταξύ του συνόλου των εισόδων του πραγματικού κόσμου, και του συνόλου των εισόδων που είναι διαθέσιμα στο μοντέλο κατά την εκπαίδευση.

Αν τα δεδομένα εκπαίδευσης περιέχουν λάθη, ή δεν είναι αντιπροσωπευτικό δείγμα της πραγματικότητας, είναι πολύ πιθανό και το μοντέλο να εκπαιδευτεί πάνω σε μια διαστρεβλωμένη προβολή των πραγματικών δεδομένων, οπότε να μην μπορεί να δώσει καλά αποτελέσματα στον πραγματικό κόσμο.

- **Κατάλληλη προεπεξεργασία (pre-processing) των Δεδομένων Εισόδου.** Συχνά, η μορφή των δεδομένων εισόδου είναι τέτοια ώστε τα δεδομένα να μην μπορούν να χρησιμοποιηθούν αποδοτικά από το νευρωνικό δίκτυο.

Πολύ συχνό βήμα σε αυτές τις περιπτώσεις είναι η εισαγωγή ενός βήματος προεπεξεργασίας, το οποίο αποτελείται από μια σειρά μετασχηματισμών πάνω στα δεδομένα. Αυτό μπορεί να περιλαμβάνει *κλιμάκωση* (scaling) των δεδομένων, *καθαρισμό* (cleaning) των δεδομένων από εμφανώς λανθασμένα δείγματα, εφαρμογή μεθόδων *ανάλυσης κύριων συνιστωσών* (principal component analysis - PCA), ή οποιονδήποτε συνδυασμό αυτών.

- **Η ισοκατανομή των διάφορων στοιχείων των δεδομένων εκπαίδευσης.** Αν τα δεδομένα εκπαίδευσης δεν έχουν ομοιόμορφη κατανομή ως προς τις ιδιότητες και τις συσχετίσεις τους, το νευρωνικό δίκτυο θα αποκτήσει προκατάληψη υπέρ των κατηγοριών που υπερτερούν σε αυτά.

Το πρόβλημα της *εκμάθησης μη-ισοροπημένων συλλογών δεδομένων* (imbalanced learning), όπως αυτό αναφέρεται στη βιβλιογραφία, εμφανίζεται συχνά σε προβλήματα που αφορούν ιατρικά δεδομένα, σπάνιων ή μη παθήσεων και για το λόγο αυτό έχει απασχολήσει αρκετά την έρευνα [Rout18], με αποτέλεσμα να έχουν προταθεί διάφοροι τρόποι αντιμετώπισής του [Salm17, Mena06].

- **Η κατάλληλη επιλογή υπερπαραμέτρων (hyperparameter selection) του δικτύου.** Τυπική διαδικασία κατά την επίλυση ενός προβλήματος μηχανικής μάθησης είναι η εύρεση του κατάλληλου συνδυασμού υπερπαραμέτρων, ούτως ώστε το νευρωνικό δίκτυο να έχει την μέγιστη δυνατή απόδοση.

Συνήθως, ένα μικρό τμήμα της συλλογής των δεδομένων εκπαίδευσης μένει κρυφό από το δίκτυο κατά την διάρκεια της εκπαίδευσης και χρησιμοποιείται μετά την ολοκλήρωση αυτής για *επαλήθευση* (validation). Επιπλέον, με χρήση μεθόδων όπως η *εξαντλητική αναζήτηση* (GridSearch), σε συνδυασμό με *διασταυρούμενη επικύρωση k-μερών* (*k*-Fold Cross Validation) μπορούν να δοκιμάζονται με αποτελεσματικό τρόπο διάφοροι συνδυασμοί υπερπαραμέτρων και να επιλέγονται αυτοί που οδηγούν στην καλύτερη συμπεριφορά του δικτύου.

- **Τερματισμός της εκπαίδευσης την κατάλληλη χρονική στιγμή.** Όπως αναφέρθηκε και προηγουμένως, η διαδικασία της εκπαίδευσης είναι μια διαδικασία βελτιστοποίησης της συνάρτησης κόστους του δικτύου. Ως εκ τούτου, ο αλγόριθμος εκπαίδευσης δεν είναι δυνατόν να εκφανθεί ως προς το αν η εκπαίδευση έχει ολοκληρωθεί, ή αν πρέπει να συνεχίσει για μερικές εποχές ακόμη.

Συχνά, ο αριθμός των εποχών εκπαίδευσης είτε επιλέγεται εκ των προτέρων, είτε αποτελεί μία ακόμη υπερπαραμέτρο για το δίκτυο.

### 3.4 Προβλήματα κατά την εκπαίδευση ενός νευρωνικού δικτύου


Στην Ενότητα 3.3 αναλύθηκε σε βάθος ο τρόπος με τον οποίο εκπαιδεύεται ένα νευρωνικό δίκτυο. Σε αυτήν την ενότητα θα γίνει αναφορά σε προβλήματα που εμφανίζονται συχνά κατά την διάρκεια της εκπαίδευσης

#### 3.4.1 Υπερπροσαρμογή

Στην στατιστική, το πρόβλημα της *υπερπροσαρμογής* (overfitting) σχετίζεται με την παραγωγή μίας ανάλυσης η οποία αντιστοιχεί με υπερβολική ακρίβεια σε ένα συγκεκριμένο σύνολο δεδομένων, με αποτέλεσμα να μην μπορεί να γενικευτεί σε καινούρια ή άγνωστα δεδομένα με αξιοπιστία [Bish06]. Ένα στοχαστικό μοντέλο που έχει υποστεί υπερπροσαρμογή λέμε ότι έχει προσαρμοστεί στα δεδομένα με ακρίβεια μεγαλύτερη από όση αυτά επιτρέπουν.

Η πεμπτουσία της υπερπροσαρμογής είναι η ακούσια εξαγωγή του θορύβου που αναπόφευκτα υπάρχει σε ένα περιορισμένο υποσύνολο δεδομένων, ως θεμελιώδους χαρακτηριστικού που περιγράφει το σύνολό τους. Κατά αυτόν τον τρόπο, το μοντέλο εξειδικεύεται και μαθαίνει το συγκεκριμένο υποσύνολο δεδομένων, πράγμα το οποίο αντιτίθεται στον βασικό του στόχο, την αναγνώριση δηλαδή των υποκείμενων συσχετίσεων που πηγάζουν από τα δεδομένα.

Στην μηχανική μάθηση η υπερπροσαρμογή σχετίζεται συχνά με την *υπερεκπαίδευση* (overtraining). Εμφανίζεται διότι τα *κριτήρια επιλογής* (selection criteria) ενός μοντέλου (συνήθως επιλέγεται αυτό που ελαχιστοποιεί το σφάλμα πάνω στα δεδομένα εκπαίδευσης) διαφέρουν από τα *κριτήριο καταλληλότητάς* (fitness criteria) του (η ικανότητά του να γενικεύει σε άγνωστα δεδομένα τα οποία δεν είχε συναντήσει κατά την εκπαίδευση).



**Σχήμα 3.4:** Παράδειγμα υπερπροσαρμογής και υποπροσαρμογής νευρωνικού δικτύου σε ένα πρόβλημα ταξινόμησης. Η μαύρη γραμμή αντιπροσωπεύει ένα μοντέλο που μαθαίνει την κατανομή με έναν ικανοποιητικό βαθμό γενίκευσης, η πράσινη γραμμή αντιπροσωπεύει ένα μοντέλο στο οποίο έχει γίνει υπερεκπαίδευση, ενώ η πορτοκαλί ένα μοντέλο στο οποίο έχει γίνει υποεκπαίδευση.

Στο Σχήμα 3.4 φαίνεται ένα χαρακτηριστικό παράδειγμα υπερεκπαιδευμένου μοντέ-

λου για ένα πρόβλημα ταξινόμησης 2 κλάσεων. Το υπερεκπαιδευμένο μοντέλο θα έχει μικρότερο σφάλμα στα δεδομένα εκπαίδευσης, ωστόσο φαίνεται ότι μάλλον θα δυσκολευτεί να γενικεύσει σωστά την γνώση αυτή σε άγνωστα δεδομένα.

Σε ένα νευρωνικό δίκτυο, το πρόβλημα της υπερπροσαρμογής κατά την εκπαίδευση μπορεί να αντιμετωπιστεί με ένα πλήθος μεθόδων, όπως είναι η διασταυρούμενη επικύρωση (που έχει ήδη αναφερθεί προηγουμένως), η εισαγωγή ενός *επιπέδου Dropout* (Dropout layer) το οποίο αγνοεί μέρος του σφάλματος κατά την εκπαίδευση, η *ομαλοποίηση* (regularization), ο *πρόωρος τερματισμός* (early stopping) της εκπαίδευσης και άλλοι.

### 3.4.2 Υποπροσαρμογή

Αντιδιαμετρικό πρόβλημα της υπερπροσαρμογής αποτελεί η *υποπροσαρμογή* (underfitting), η αδυναμία δηλαδή του μοντέλου να αναγνωρίσει και να αφομοιώσει επαρκώς την υποκείμενη δομή του συνόλου δεδομένων που του παρουσιάζονται [Bish06]. Πιθανά αίτια υποπροσαρμογής ενός μοντέλου μηχανικής μάθησης είναι:

- **Η πρόωρη διακοπή της εκπαίδευσης.** Η εκπαίδευση του δικτύου ολοκληρώνεται προτού περάσει επαρκής αριθμός εποχών, με αποτέλεσμα τα βάρη του δικτύου να μην έχουν προλάβει να συγκλίνουν σε τιμές τέτοιες ώστε η έξοδος του δικτύου να προσεγγίζει την επιθυμητή.
- **Ανεπαρκές πλήθος δειγμάτων για τα δεδομένα εκπαίδευσης.** Οι αλγόριθμοι της μηχανικής μάθησης και τα νευρωνικά δίκτυα στηρίζονται στο ότι κατά την εκπαίδευση τους παρουσιάζεται ένας επαρκής αριθμός δειγμάτων, ούτως ώστε να μπορούν να προσαρμοστούν στην κατανομή τους. Αν ο αριθμός των δεδομένων εκπαίδευσης είναι περιορισμένος, τότε είναι σχεδόν αδύνατο για το δίκτυο να καταφέρει να αναγνωρίσει την κατανομή τους.
- **Ακατάλληλη επιλογή αρχιτεκτονικής και υπερπαραμέτρων του δικτύου.** Όπως αναφέραμε και στην Ενότητα 3.2.7, η έρευνα έχει οδηγήσει σε μία πληθώρα αρχιτεκτονικών για νευρωνικά δίκτυα, κάθε μία από τις οποίες έχει χαρακτηριστικά και ιδιότητες που της επιτρέπουν να αντιμετωπίζει αποτελεσματικά συγκεκριμένες μόνο κατηγορίες προβλημάτων μηχανικής μάθησης. Επιπλέον, είναι ιδιαίτερα σημαντική η κατάλληλη επιλογή των υπερπαραμέτρων του δικτύου (παραδείγματος χάρη του αριθμού των νευρώνων ανά επίπεδο, τον αριθμό των επιπέδων, και άλλων), καθώς αυτές προκαθορίζουν την πολυπλοκότητα, την ευρωστία και την χωρητικότητα του δικτύου.

Στο Σχήμα 3.4 φαίνεται με πορτοκαλί χρώμα ένα χαρακτηριστικό παράδειγμα υποεκπαιδευμένου μοντέλου για ένα πρόβλημα ταξινόμησης 2 κλάσεων. Είναι προφανές ότι το δίκτυο δεν έχει καταφέρει να αναγνωρίσει την κατανομή των δύο κατηγοριών, δίνοντας έτσι ένα μη ικανοποιητικό αποτέλεσμα.

### 3.4.3 Εκλειπόμενη και Εκρύγνουσα Κλίση

Το πρόβλημα της *εκλειπόμενης κλίσης* (vanishing gradient) συναντάται συνήθως κατά την εκπαίδευση νευρωνικών δικτύων με πολλά κρυφά επίπεδα νευρώνων, χρησιμοποιώντας μεθόδους κατάβασης κλίσης και του αλγορίθμου οπισθοδιάδοσης σφάλματος. Στην Σχέση 3.6 φαίνεται ότι η ενημέρωση των βαρών του δικτύου είναι ανάλογη της τιμής της μερικής παραγώγου της συνάρτησης ενεργοποίησης ως προς την τρέχουσα τιμή του βάρους σε κάθε επανάληψη της εκπαίδευσης. Υπο προϋποθέσεις, και όπως φαίνεται και στο Σχήμα 3.2 η τιμή αυτής της μερικής παραγώγου μπορεί να λαμβάνει πολύ μικρές τιμές,



ουσιαστικά μεταβάλλοντας το βάρος κατά ένα αμελητέο μόνο πόσο, γεγονός που δυσχεραίνει ή ακόμα και εγκλωβίζει το βάρος σε μία συγκεκριμένη τιμή, πρακτικά εμποδίζοντας την περαιτέρω εκπαίδευση του δικτύου.

Το πρόβλημα γίνεται ακόμη πιο εμφανές όσο τα σφάλματα μεταβιβάζονται στα προηγούμενα επίπεδα του δικτύου. Στο κρυφό επίπεδο που απέχει  $N$  βήματα από την έξοδο, οι τιμές των σταθμισμένων σφαλμάτων έχουν  $N - 1$  παράγοντες με πολύ μικρές τιμές, με αποτέλεσμα η αριθμητική τιμή του να τείνει γρήγορα προς το 0. Κατά κύριο λόγο επηρεάζει βαθιά νευρωνικά δίκτυα πρόσθιας διάδοσης με πολλά κρυφά επίπεδα, αλλά και επαναληπτικά νευρωνικά δίκτυα.

Αντίστοιχο πρόβλημα της εκλειπόμενης κλίσης είναι αυτό της *εκρύνουσας κλίσης* (exploding gradient), το οποίο συμβαίνει υπό τις ίδιες συνθήκες όταν οι τιμές της κλίσης παίρνουν τιμές μεγαλύτερες της μονάδας. Όπως και πριν, ο υπολογισμός της μεταβολής του βάρους στο κρυφό επίπεδο που απέχει  $N$  βήματα από την έξοδο περιέχει  $N - 1$  παράγοντες μεγαλύτερους της μονάδας, οδηγώντας σε μία ασταθή κατάσταση όπου τα βάρη του δικτύου μεταβάλλονται διαρκώς και το δίκτυο να αδυνατεί να συγκλίνει με την πάροδο των εποχών εκπαίδευσης.

Τα δύο αυτά προβλήματα έχουν απασχολήσει επισταμένα την ερευνητική κοινότητα και έχουν κατά καιρούς προταθεί διάφορες μέθοδοι για την αντιμετώπιση τους και τον περιορισμό του αντίκτυπού τους στην εκπαίδευση [Phil17, Kole01]. Μία από τις πιο σύγχρονες προσεγγίσεις που έχει δώσει πολύ καλά αποτελέσματα είναι η χρήση της αρχιτεκτονικής των *υπολοιπόμενων νευρωνικών δικτύων* (residual neural networks - ResNets) [He15], δικτύων στα οποία το πρόβλημα της εκλειπόμενης κλίσης αντιμετωπίζεται με την εισαγωγή συνάψεων που συνδέουν άμεσα νευρώνες των αρχικών επιπέδων με νευρώνες που βρίσκονται κοντά στο επίπεδο εξόδου, παρακάμπτοντας αποτελεσματικά το πρόβλημα των πολλών παραγόντων που αναφέρθηκε προηγουμένως.

## 3.5 Επαναληπτικά νευρωνικά δίκτυα

Τα *επαναληπτικά νευρωνικά δίκτυα* (ΕΝΔ ή recurrent neural networks - RNNs) είναι μία κλάση νευρωνικών δικτύων στα οποία οι συνάψεις μεταξύ των νευρώνων του δικτύου σχηματίζουν έναν κατευθυνόμενο γράφο [Hayk09]. Η ιδιότητα αυτή τους επιτρέπει να αναγνωρίζουν, να αφομοιώνουν αλλά και να αναπαράγουν συμπεριφορά η οποία μεταβάλλεται δυναμικά με την πάροδο του χρόνου, με αποτέλεσμα να ταιριάζουν σε προβλήματα μηχανικής μάθησης με δεδομένα που αφορούν ακολουθίες ή χρονοσειρές.

Τα επαναληπτικά νευρωνικά δίκτυα στηρίζονται στις αρχές των νευρωνικών δικτύων πρόσθιας διάδοσης και τα επεκτείνουν εισάγοντας την έννοια της *εσωτερικής κατάστασης* (state ή memory), κάτι το οποίο επιτρέπει την επεξεργασία εισόδων που έχουν την μορφή χρονικών ακολουθιών.

Η ιδέα των επαναληπτικών νευρωνικών δικτύων εμφανίζεται στη βιβλιογραφία από την δεκαετία του 1990 [Smit89]. Στις πρώτες εφαρμογές και αρχιτεκτονικές, γίνεται άμεσα εμφανές το πρόβλημα της εκλειπόμενης κλίσης, καθώς οι αρχιτεκτονικές αδυνατούν να συγκρατήσουν και να χρησιμοποιήσουν με αποδοτικό τρόπο την παρελθοντική γνώση.

### 3.5.1 Long short-term memory

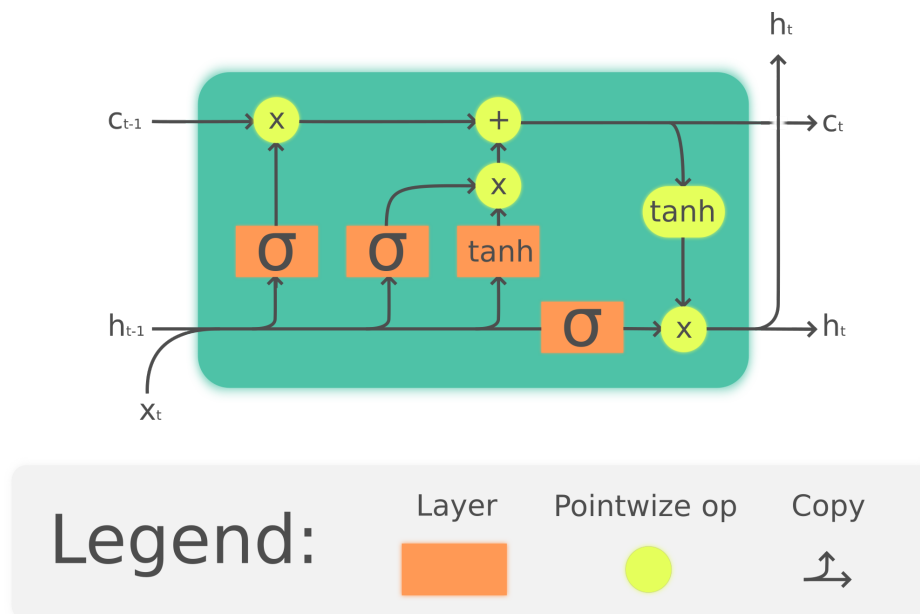
Το 1997 προτείνεται για πρώτη φορά η αρχιτεκτονική των δικτύων *μακράς βραχυπρόθεσμης μνήμης* (long short-term memory - LSTM) [Hoch97], η οποία αντιμετωπίζει το πρόβλημα της εκλειπόμενης κλίσης. Ωστόσο, οι περιορισμοί του υλικού όσον αφορά τις απαιτήσεις σε υπολογιστικούς πόρους δεν επιτρέπουν την ευρεία αποδοχή και χρήση τους. Χρειάστηκε να περάσουν περίπου 20 χρόνια μέχρι το υλικό που απαιτείται για την εκπαί-

δευση και την διαχείριση των μοντέλων να γίνει ευρέως διαδεδομένο σε βαθμό ώστε τα LSTM να επανέλθουν στο προσκήνιο της ακαδημαϊκής έρευνας.

Τα LSTM μπορούν να διαχειρίζονται τόσο απλά δεδομένα (π.χ. στατικές εικόνες) όσο και ακολουθίες αυτών (π.χ. ροή ήχου, ροή εικόνων και βίντεο, χρονοσειρές), καθιστώντας τα ικανά να χρησιμοποιηθούν σε προβλήματα αναγνώρισης γραφής, αναγνώρισης φωνής, ερμηνείας εικόνας και βίντεο, ανάλυση και πρόβλεψη χρονοσειρών, παρατήρηση ανωμαλιών σε δικτυακή κίνηση και πολλά άλλα.

Το διακριτικό στοιχείο των LSTM δικτύων είναι η ικανότητά τους να αναγνωρίζουν συσχετίσεις σε δεδομένα που απέχουν αυθαίρετα χρονικά διαστήματα μεταξύ τους. Επιπλέον, όπως μαρτυρά και η ονομασία τους, συνδυάζουν πολύ αποτελεσματικά τόσο την βραχυπρόθεσμη (short-term) πληροφορία που δέχονται όσο και την ιστορική τους μακροπρόθεσμη (long-term) γνώση. Τα δύο αυτά χαρακτηριστικά τα ξεχωρίζουν από άλλες μορφές RNNs και μεθόδων ανάλυσης χρονοσειρών.

Τα LSTM διαφέρουν από τα απλά δίκτυα πρόσθιας διάδοσης λόγω του ότι διαθέτουν *συνάψεις ανάδρασης* (feedback connections). Έχουν προταθεί πολυάριθμες παραλλαγές των LSTM [Gref17], ωστόσο η πλέον επικρατέστερη είναι αυτή που φαίνεται στο Σχήμα 3.5.



**Σχήμα 3.5:** Τυπική δομή ενός κελιού LSTM. [Πηγή: Βικιπαίδεια]

Τα δομικά συστατικά στοιχεία ενός LSTM είναι τα εξής:

- **πυρήνας (cell)**, αποτελεί την κεντρική μονάδα μνήμης του LSTM.
- **πύλη εισόδου (input gate)**, με την οποία ελέγχεται ο βαθμός στον οποίο το ερέθισμα εισόδου σε κάποια χρονική στιγμή  $x_t$  ενσωματώνεται στην μακροπρόθεσμη μνήμη του κελιού.
- **πύλη εξόδου (output gate)**, με την οποία ελέγχεται ο βαθμός στον οποίο η πληροφορία που είναι αποθηκευμένη στην μνήμη θα συνεισφέρει στην ενεργοποίηση του κελιού.
- **πύλη λήθης (forget gate)**, με την οποία ελέγχεται ο βαθμός στον οποίο το κελί θα «ξεχάσει» πληροφορία που έχει αποθηκεύσει νωρίτερα στην μνήμη του.

Με τη χρήση των τριών αυτών πυλών, το LSTM μπορεί να «θυμάται» και να αξιοποιεί πληροφορία τόσο από το μακρινό όσο και το κοντινό παρελθόν, ώστε να δίνει προβλέψεις με πολύ υψηλή ακρίβεια. Οι διάφορες παραλλαγές των LSTM που συναντώνται στην βιβλιογραφία είτε αφαιρούν κάποια από τις 3 αυτές πύλες, είτε προσθέτουν κάποια ακόμη πιο εξειδικευμένη.

Η λειτουργία του LSTM κατά τα υπόλοιπα παραμένει ίδια με αυτή του απλού νευρώνα (perceptron). Το LSTM δέχεται ένα διάνυσμα εισόδου ως ερέθισμα και το χρησιμοποιεί για τον υπολογισμό της ενεργοποίησης του, η οποία μεταφέρεται στην έξοδο του μέσω μίας μη γραμμικής συνάρτησης ενεργοποίησης. Η διαφορά είναι ότι στον υπολογισμό εμπλέκονται, εκτός από το διάνυσμα εισόδου και τα βάρη, η κρυφή μνήμη των κελιών.

Κάθε μία από τις πύλες ενός LSTM διαθέτει μία σύναψη εισόδου και εξόδου, τα βάρη των οποίων είναι μεταβλητές που μαθαίνονται κατά την εκπαίδευση του δικτύου. Μεταβλητές αποτελούν επίσης και οι πολώσεις των πυλών του LSTM.

## Μαθηματική έκφραση

Ο υπολογισμός της εξόδου ενός LSTM unit γίνεται ως εξής:

$$f_t = \sigma_g(W_f * x_t + U_f * h_{t-1} + b_f)$$

$$i_t = \sigma_g(W_i * x_t + U_i * h_{t-1} + b_i)$$

$$o_t = \sigma_g(W_o * x_t + U_o * h_{t-1} + b_o)$$

$$\bar{c}_t = \sigma_c(W_c * x_t + U_c * h_{t-1} + b_c)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \bar{c}_t$$

$$h_t = o_t \circ \sigma_h(c_t)$$

Στα παραπάνω οι αρχικές τιμές μπορεί να μηδενικές ( $c_0 = 0$  και  $h_0 = 0$ ) ή δείγματα από κάποια κανονική κατανομή. Ο δείκτης  $t$  αφορά τη χρονική στιγμή στην οποία αναφέρονται οι υπολογισμοί, και ο τελεστής  $\circ$  στο γινόμενο Hadamard δύο πινάκων (γινόμενο στοιχείο προς στοιχείο).

Οι μεταβλητές που αναφέρονται στις παραπάνω σχέσεις είναι:

- $x_t \in R^d$ : **διάνυσμα εισόδου** την χρονική στιγμή  $t$
- $f_t \in R^h$ : **διάνυσμα ενεργοποίησης της πύλης λήθης** για την είσοδο  $x_t$
- $i_t \in R^h$ : **διάνυσμα ενεργοποίησης της πύλης εισόδου** για την είσοδο  $x_t$
- $\bar{c}_t \in R^h$ : **διάνυσμα ενεργοποίησης της πύλης εξόδου** για την είσοδο  $x_t$
- $h_t \in R^h$ : **διάνυσμα κρυφής κατάστασης του LSTM**, ή αλλιώς διάνυσμα εξόδου την χρονική στιγμή  $t$
- $c_t \in R^h$ : **διάνυσμα ενεργοποίησης της μνήμης του κελιού** την χρονική στιγμή  $t$
- $c_t \in R^h$ : **διάνυσμα μνήμης του κελιού** την χρονική στιγμή  $t$
- $W \in R^{h \times d}$ : **διάνυσμα βαρών στις πύλες του LSTM**, μαθαίνεται κατά την εκπαίδευση
- $U \in R^{(h \times h)}$ : **διάνυσμα βαρών των αναδρομικών συνάψεων του LSTM**, μαθαίνεται κατά την εκπαίδευση
- $b \in R^h$ : **διάνυσμα πολώσεων στις πύλες και την έξοδο του LSTM**, μαθαίνεται κατά την εκπαίδευσή

## Εκπαίδευση

Ένα LSTM μπορεί να εκπαιδευτεί με επίβλεψη χρησιμοποιώντας έναν αλγόριθμο βελτιστοποίησης όπως η κατάβαση κλίσης, σε συνδυασμό με τον αλγόριθμο οπισθοδιάδοσης σφάλματος στο χρόνο για τον υπολογισμό των σφαλμάτων και των κλίσεων.

Η εκπαίδευση των LSTM δεν επηρεάζεται από το πρόβλημα της εκλειπόμενης κλίσης, καθώς οι τιμές του σφάλματος που διαδίδονται προς τα πίσω από το επίπεδο εξόδου παραμένουν στην μνήμη του κελιού. Λόγω αυτού, το σφάλμα μεταφέρεται συνεχώς ως ανάδραση στις υπόλοιπα κελιά χωρίς να φθίνει σε κάθε επανάληψη. Έτσι, το LSTM μπορεί μετά από πεπερασμένο αριθμό επαναλήψεων να αξιοποιήσει το σφάλμα και να συνεχίσει την εκπαίδευσή του.

### 3.5.2 Φραγμένα επαναληπτικά δίκτυα

Τα *φραγμένα επαναληπτικά δίκτυα* (gated recurrent units - GRUs) είναι μια κατηγορία επαναληπτικών νευρωνικών δικτύων τα οποία προτάθηκαν για πρώτη φορά το 2014 [Cho14]. Εμφανίζονται επίσης με διάφορες μορφές στην βιβλιογραφία, αλλά κατά κύριο λόγο πρόκειται για LSTM δίκτυα από τα οποία έχει αφαιρεθεί η θύρα εξόδου. Έχει αποδειχθεί [Weis18] ότι τα GRU είναι αυστηρά υποδεέστερα των LSTMs, καθώς αδυνατούν να πραγματοποιήσουν μη-φραγμένη μέτρηση, κάτι το οποίο τα LSTM μπορούν να κάνουν χωρίς πρόβλημα.

Η αξία των GRU έγκειται στο ότι αποτελούν μία απλούστερη μορφή των LSTM, καταφέροντας ωστόσο να επιτύχουν παρόμοια συμπεριφορά σε προβλήματα ανάλυσης φυσικής γλώσσας και αναγνώρισης φωνής. Χρησιμοποιούνται συνήθως σε προβλήματα όπου τα δεδομένα έχουν απλή μορφή, καθώς η απλότητα της σχεδίασής τους φαίνεται να τους δίνει ένα πλεονέκτημα έναντι των LSTM. [Grub20]

### 3.5.3 Sequence to sequence

Τα μοντέλα *ακολουθία-σε-ακολουθία* (sequence-to-sequence - seq2seq) είναι μία αρκετά σύγχρονη πρακτική η οποία έχει εμφανιστεί στην βιβλιογραφία τα τελευταία χρόνια [Neub17, Suts14]. Έχει αυτή την ονομασία διότι χρησιμοποιείται σε προβλήματα πρόβλεψης ακολουθιών με είσοδο άλλες ακολουθίες (π.χ. προβλήματα μετάφρασης φυσικής γλώσσας). Χρησιμοποιεί κατά κύριο δύο (ή περισσότερα) επίπεδα από LSTM, τα οποία τοποθετούνται σε σειρά. Το πρώτο LSTM, στο οποίο παρουσιάζονται τα δεδομένα εισόδου κάνει "κωδικοποίηση" αυτών και δίνει ως έξοδο ένα διάνυσμα χαρακτηριστικών αυτών. Το διάνυσμα χαρακτηριστικών (που μπορεί να επεργάζεται περαιτέρω από ένα ή περισσότερα κρυφά επίπεδα) εν τέλει δίνεται ως είσοδος σε ένα δεύτερο LSTM, το οποίο το χρησιμοποιεί για να κάνει πρόβλεψη της ακολουθίας εξόδου.

Η ιδέα πάνω στην οποία στηρίζονται τα seq2seq μοντέλα είναι ότι η κωδικοποίηση που πραγματοποιείται από το αρχικό LSTM απορρίπτει θόρυβο από την πληροφορία και αναδεικνύει τους τρόπους συσχέτισης των δεδομένων εισόδου.

### 3.5.4 Πρόβλεψη ροής κίνησης με επαναληπτικά νευρωνικά δίκτυα

Το πρόβλημα παρακολούθησης, μέτρησης και πρόβλεψης της μελλοντικής εξέλιξης της κυκλοφοριακής κίνησης ουσιαστικά πρόκειται για περαιτέρω εξειδίκευση της εφαρμογής τεχνικών μηχανικής μάθησης σε χρονοσειρές.

Η αξία της αποτελεσματικής πρόβλεψης της μελλοντικής κίνησης είναι ιδιαίτερα σημαντική, όπως αναλύθηκε εκτενώς και στο Κεφάλαιο 2. Οι χρονοσειρές των δεδομένων κίνησης έχουν το ιδιόρυθμο χαρακτηριστικό του να εμφανίζουν υψηλή περιοδικότητα και εποχικότητα, αλλά ταυτόχρονα να είναι πολύ ευαίσθητες σε τοπικές μεταβολές. Αυτή η

ανάγκη συνδυασμού ιστορικής και πρόσφατης γνώσης τις καθιστά ιδανικό πρόβλημα για εφαρμογή των επαναληπτικών νευρωνικών δικτύων, με κυρίαρχη τη χρήση LSTM και GRU μοντέλων, κάτι που αντικατοπτρίζεται και στην σύγχρονη έρευνα και την βιβλιογραφία [Wu18, Lv15, Kane17].

## 3.6 Ανίχνευση έκτοπων τιμών

Η *ανίχνευση έκτοπων τιμών*, ή *ανίχνευση ανωμαλιών* (outlier detection ή anomaly detection) είναι η διαδικασία αναγνώρισης και ανίχνευσης «σπάνιων» αντικειμένων, γεγονότων ή παρατηρήσεων, τα οποία διαφέρουν σημαντικά από την πλειοψηφία των διαθέσιμων δειγμάτων [Hodg04]. Στους τομείς για τους οποίους έχει νόημα η ανίχνευση έκτοπων τιμών, οι τιμές αυτές συνήθως συνδέονται με κάποια ανεπιθύμητη συμπεριφορά ή κατάσταση, όπως λ.χ. κάποια τραπεζική απάτη, κάποια ιατρική πάθηση ή κάποια εσφαλμένη ανάγνωση μέτρησης ενός αισθητήρα.

Ως πρόβλημα, η ανίχνευση έκτοπων τιμών κινείται σε ένα χώρο ανάμεσα στην επιβλεπόμενη και την μη επιβλεπόμενη μάθηση. Από την μία πλευρά απαιτεί μιας μορφής επίβλεψη για να επιβεβαιωθεί ότι κάποια περίεργη συμπεριφορά αποτελεί πράγματι έκτοπη τιμή, από την άλλη στον πυρήνα της είναι πρόβλημα μη επιβλεπόμενης μάθησης, καθώς μέρος της είναι και η δυνατότητα να μπορεί δυναμικά να αναγνωρίζει «νέες» και άγνωστης μορφής ιδιοτροπίες.

Η ανίχνευση έκτοπων τιμών είναι ένα πεδίο με τεράστιο οριζόντιο εύρος, λόγω των διαφορετικών τομέων με τους οποίους σχετίζεται και στους οποίους είναι χρήσιμη. Στα πλαίσια της εργασίας αυτής, μας ενδιαφέρει η εφαρμογή ανίχνευσης έκτοπων τιμών σε χρονοσειρές αριθμητικών δεδομένων και θα επικεντρωθούμε σε αυτήν την έκφασή της.

### 3.6.1 Ανίχνευση έκτοπων τιμών σε χρονοσειρές

Η εύρεση έκτοπων τιμών σε μία χρονοσειρά είναι ένα πρόβλημα που παρουσιάζει αρκετό ενδιαφέρον από μαθηματική άποψη.

Ο τυπικός τρόπος με τον οποίο προσεγγίζεται αυτό το πρόβλημα στην βιβλιογραφία είναι η ανάλυση της χρονοσειράς βάσει ενός κυλιόμενου παραθύρου. Συγκεκριμένα, η χρονοσειρά μετασχηματίζεται και κάθε ένα δείγμα της αντιστοιχίζεται σε ένα διάνυσμα, το οποίο περιγράφει κάποιες αντικειμενικές μετρικές της χρονοσειράς σε ένα κυλιόμενο παράθυρο γύρω από το δείγμα αυτό. Παράδειγμα τέτοιων μετρικών μπορεί να είναι ο μέσος όρος των δειγμάτων που ανήκουν στο κυλιόμενο παράθυρο, η διασπορά τους, η διαφορά της μέγιστης από την ελάχιστη τιμή, η μέση τιμή και η διασπορά των διαφορών μεταξύ διαδοχικών δειγμάτων της και άλλοι.

Η χρήση ενός συνόλου από τέτοιες μετρικές μπορούμε να πούμε ότι περιγράφει σε ικανοποιητικό βαθμό βασικές ιδιότητες της χρονοσειράς (π.χ. βαθμός τυχαιότητας, εποχικότητα, τάση, περιοδικότητα) και για τον λόγο αυτό δίνει πολύ καλά αποτελέσματα.

### 3.6.2 Ανίχνευση έκτοπων τιμών και μηχανική μάθηση

Στον τομέα της μηχανικής μάθησης, η ανίχνευση έκτοπων τιμών έχει διπλό ρόλο. Αποτελεί βασικό εργαλείο κατά το στάδιο της προ-επεξεργασίας μίας συλλογής δεδομένων προκειμένου να χρησιμοποιηθεί για την εκπαίδευση ενός νευρωνικού δικτύου. Επίσης, είναι πολύ χρήσιμη ως μη επιβλεπόμενος τρόπος εξερεύνησης, παρατήρησης και εξαγωγής χρήσιμων συμπερασμάτων για άγνωστες συλλογές δεδομένων.

Παράλληλα, η έρευνα γύρω από την μηχανική μάθηση έχει οδηγήσει στην ανάπτυξη μοντέλων τα οποία αντιμετωπίζουν την ανίχνευση έκτοπων τιμών ως ένα πρόβλημα ταξι-

νόμησης 2 κλάσεων (κάθε ένα δείγμα από το σύνολο δεδομένων μπορεί να χαρακτηριστεί ως κανονική ή έκτοπη τιμή).

Η χρήση μοντέλων μηχανικής μάθησης ως εργαλεία για ανίχνευση έκτοπων τιμών παρουσιάζει κάποια πολύ βασικά πλεονεκτήματα σε σχέση με τις στατιστικές και αριθμητικές μεθόδους που έχουν αναπτυχθεί ιστορικά.

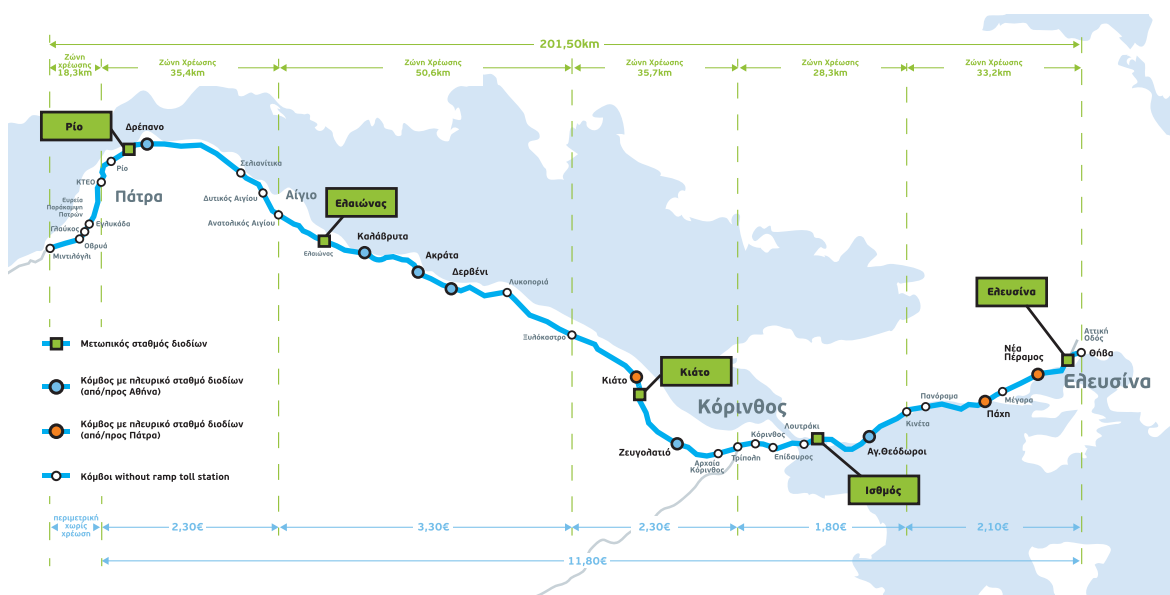
- Σε περιπτώσεις γνωστών ιστορικών δεδομένων στα οποία η «περιεκτικότητα» σε έκτοπες τιμές είναι περίπου γνωστή, είναι δυνατή η χρήση επιβλεπόμενης μάθησης για την εκπαίδευση νευρωνικών δικτύων που θα κάνουν την ανίχνευση έκτοπων τιμών, αναγνωρίζοντας μόνα τους μέσω της διαδικασίας της εκπαίδευσης τις συσχετίσεις και τις ιδιότητες που διακρίνουν τις έκτοπες τιμές. Παραδείγματα τέτοιων μοντέλων με αρκετές αναφορές στην βιβλιογραφία είναι τα *Δάση Απομόνωσης* (Isolation Forests) [Liu09] και τα *Διανύσματα Μηχανών Υποστήριξης Μίας Κλάσης* (One Class Support Vector Machines - One Class SVMs) [Jin19] [Ma03].
- Τα μοντέλα μηχανικής μάθησης είναι πολύ εύκολο να προσαρμόζονται δυναμικά σε αλλαγές της φύσης της χρονοσειράς που ελέγχουν.
- Τα μοντέλα μηχανικής μάθησης παρουσιάζουν ιδιαίτερη ευελιξία ως προς τον συνδυασμό πληροφορίας εξωτερικής της χρονοσειράς προκειμένου να αποφανθούν.
- Τα μοντέλα μηχανικής μάθησης μπορούν να συνδυάζουν τόσο ιστορικά όσο και πρόσφατα on-line δεδομένα. Αυτό δεν ισχύει για την πλειοψηφία των αριθμητικών μεθόδων που έχουν προταθεί κατά καιρούς.

## Κεφάλαιο 4

# Πρόβλεψη Κυκλοφοριακής Κίνησης

### 4.1 Συλλογή δεδομένων

Για την διεξαγωγή των πειραμάτων στα πλαίσια της εργασίας αυτής, απαραίτητη προϋπόθεση ήταν η συλλογή, η κατασκευή και το καθάρισμα της συλλογής των δεδομένων εκπαίδευσης, το οποίο δημιουργήθηκε από το μηδέν βάσει πρωτογενών δεδομένων που μας παρασχέθηκαν από την εταιρία παραχώρησης αυτοκινητοδρόμων ΟΛΥΜΠΙΑ ΟΔΟΣ Α.Ε.. Τα πρωτογενή δεδομένα κίνησης είχαν συλλεχθεί από αισθητήρες καθ' όλο το μήκος της Ολυμπίας Οδού κατά το έτος 2018 (Σχήμα 4.1).



Σχήμα 4.1: Πλήρες μήκος Ολυμπίας Οδού, μαζί με τους σταθμούς διοδίων (Πηγή: ΟΛΥΜΠΙΑ ΟΔΟΣ Α.Ε.)

#### 4.1.1 Συλλογή πρωτογενών δεδομένων

Τα πρωτογενή δεδομένα μας δόθηκαν με την μορφή αρχείων καταγραφής (log files), ένα για κάθε μία ημέρα του έτους. Μέσα στα αρχεία καταγραφής, κάθε μία γραμμή αντιστοιχούσε σε μία μέτρηση κάποιου από τους 40 διαφορετικούς σταθμούς μέτρησης σε κάθε μία από τις κατευθύνσεις της οδού. Κάθε ένας αισθητήρας ενός σταθμού αντιστοιχεί σε μία λωρίδα της οδού (ξεχωριστά για τις δύο κατευθύνσεις της), και έχει την ικανότητα να αναγνωρίζει πότε διέρχεται κινούμενο όχημα από πάνω του, με χρήση δύο πηνίων τοποθετημένων κατά μήκος του δρόμου (υπό του οδοστρώματος) και εκμεταλλευόμενος φαινόμενα επαγωγής σε αυτά. Οι αισθητήρες διαθέτουν επίσης έναν μετρητή.

Κατά την αρχική εξερεύνηση των δεδομένων, διαπιστώθηκε ότι υπάρχουν δύο διαφορετικά είδη σταθμών και αισθητήρων μέτρησης, ανάλογα με την θέση τους στην οδό. Η πρώτη κατηγορία σταθμών ήταν στις εισόδους και εξόδους της οδού (οπότε μετρούσαν τον αριθμό των οχημάτων που εισέρχονταν ή εξέρχονταν από την οδό σε εκείνο το σταθμό). Η δεύτερη κατηγορία ήταν οι «κύριοι» σταθμοί, οι οποίοι βρίσκονται στις λωρίδες της κύριας κυκλοφορίας της οδού. Οι αισθητήρες αυτοί είχαν την δυνατότητα συλλογής πιο πλούσιας πληροφορίας, καθώς διέθεταν μηχανισμό διάκρισης του τύπου των οχημάτων και της μέσης ταχύτητας με την οποία αυτά διέρχονταν, καθώς και τον βαθμό χρησιμοποίησης (%) της οδού. Στο πλαίσιο της εργασίας, χρησιμοποιήθηκαν τα δεδομένα μόνο από τους κύριους σταθμούς της οδού, οι οποίες μετρούσαν άμεσα την ροή της κίνησης.

Η λειτουργία των αισθητήρων έχει ως εξής. Με κάθε διέλευση οχήματος, ο αισθητήρας ενεργοποιείται και το σήμα ενεργοποίησης προκαλεί την αύξηση της τιμής του μετρητή κατά μία μονάδα. Ανά τακτά χρονικά διαστήματα (6 λεπτών), ο αισθητήρας «γράφει» (flush) την τιμή του μετρητή σε ένα αρχείο, μαζί με πληροφορίες για την τρέχουσα ημερομηνία και ώρα, την λωρίδα, τον σταθμό της μέτρησης. Το αποτέλεσμα είναι μία σειρά εγγραφών με τη μορφή που παρουσιάζεται στον Πίνακα 4.1

2018-01-04 10:12:00/VDS-3115-1/VDS	ZEV M	T96,6/EPT-T/1/1.3/126/24/0/19/2/0/0/0/0/0/3
2018-01-04 10:12:00/VDS-3115-1/VDS	ZEV M	T96,6/EPT-T/2/3.32/106/35/0/25/1/0/3/0/0/5/1
2018-01-04 10:18:00/VDS-3115-1/VDS	ZEV M	T96,6/EPT-T/1/1.15/133/22/0/21/0/0/0/1/0/0/0
2018-01-04 10:18:00/VDS-3115-1/VDS	ZEV M	T96,6/EPT-T/2/2.36/115/32/0/25/2/0/1/0/0/2/2

**Πίνακας 4.1:** Μορφή των δεδομένων που προέρχονται από τους αισθητήρες

Κάθε εγγραφή περιέχει την χρονική στιγμή της μέτρησης (π.χ. 2018-01-04 10:12:00 για την πρώτη εγγραφή), τον σταθμό στον οποίο έγινε η μέτρηση (VDS ZEV M T96,6), την κατεύθυνση της οδού (EPT-T), την λωρίδα στην οποία αναφέρεται η μέτρηση (1), το ποσοστό χρησιμοποίησης της λωρίδας για το διάστημα των 6 λεπτών (1.3), την μέση ταχύτητα των διερχόμενων οχημάτων ( $126 \frac{km}{h}$ ), το πλήθος τους (24) και τέλος το πλήθος τους ανά κατηγορία οχήματος. Στο πλαίσιο της εργασίας χρησιμοποιήθηκε μόνο ο συνολικός αριθμός οχημάτων που μέτρησαν οι αισθητήρες.

#### 4.1.2 Κατασκευή της συλλογής δεδομένων

Για την κατασκευή της συλλογής δεδομένων από τα παραπάνω ακολουθήθηκαν τα εξής βήματα:


1. **Άθροιση των μερικών ανά λωρίδα μετρήσεων**, ώστε να έχουμε μία αριθμητική για την κίνηση, μαζί με τη χρονοσήμανση και τον σταθμό στον οποίο αυτή πραγματοποιήθηκε.
2. **Συνένωση σταθμών που αναφέρονται στο ίδιο σημείο μέτρησης**. Υπήρχαν σταθμοί μέτρησης οι οποίοι κατά τη διάρκεια του έτος μετακινήθηκαν σε νέα θέση (1-2 χιλιόμετρα χιλιόμετρα πιο πέρα από την αρχική), με αποτέλεσμα να εμφανίζονται στα δεδομένα με διαφορετική ονομασία. Αυτοί βρέθηκαν, και έπειτα και από την επιβεβαίωση ότι πρόκειται για τον ίδιο σταθμό από την ΟΛΥΜΠΙΑ ΟΔΟ Α.Ε., συνενώθηκαν.
3. **Αποθήκευση της πληροφορίας σε μία βάση δεδομένων**, ευρετηριοποιημένη ως προς τον χρόνο και τον σταθμό μέτρησης, προκειμένου να είναι εύκολη και γρήγορη η προσπέλαση και η αξιοποίηση των δεδομένων.



4. **Αρχική στατιστική ανάλυση των δεδομένων**, προκειμένου να γίνει μια αρχική εξερεύνηση αυτών. Απο αυτήν βρέθηκαν αρκετά σημεία στα οποία τα δεδομένα των μετρητών είχαν σφάλματα. Ενδεικτικά, υπήρχαν τιμές οι οποίες ήταν καταφανώς λανθασμένες (π.χ. περισσότερα από 50000 οχήματα μέσα σε 6 λεπτά). Μετά συνεννόηση με την ΟΛΥΜΠΙΑ ΟΔΟ Α.Ε, επιβεβαιώθηκε ότι επρόκειτο για σφάλμα του μετρητή.
5. **Καθαρισμός των δεδομένων από μεμονομένες έκτοπες τιμές**. Φτιάχτηκε ένα πρόγραμμα το οποίο διαδοχικά για κάθε σταθμό της βάσης διόρθωνε μεμονομένες τιμές, αντικαθιστώντας τις με τον μέσο όρο των δύο γειτονικών τιμών τους.
6. **Καθαρισμός προβληματικών χρονικών περιόδων**. Διαπιστώθηκε ότι σε αρκετούς σταθμούς υπήρχαν εκτεταμένες χρονικές περιόδους όπου οι μετρήσεις είχαν πάρα πολύ θόρυβο, ή περιείχαν πάρα πολύ συχνά σφάλματα. Προτιμήθηκε, για λόγους απλότητας, τα αντίστοιχα χρονικά διαστήματα να αγνοηθούν πλήρως και να μην συμπεριληφθούν στην τελική συλλογή των δεδομένων.


Ως τελευταίο σχόλιο, αξίζει να σημειωθεί ότι σκόπιμα δεν αφαιρέθηκαν πλήρως οι εσφαλμένες τιμές και οι θορυβώδεις περιοχές που βρέθηκαν στη συλλογή των δεδομένων. Η επιλογή αυτή έγινε καθώς ήταν επιθυμητό και ως ένα βαθμό ζητούμενο το να εξεταστεί πώς ένα μοντέλο μηχανικής μάθησης αντιμετωπίζει τα προβλήματα αυτά, κατά πόσο επηρεάζεται η επιτυχία του και κατά πόσο μπορεί να αναγνωρίσει και να τα ξεπεράσει.

### 4.1.3 Τελική μορφή δεδομένων



**Σχήμα 4.2:** Δεδομένα κίνησης πάνω από την έξοδο της Επιδάουρου με κατεύθυνση την Ελευσίνα πριν τον καθαρισμό των δεδομένων. Οι τιμές έχουν γίνει clip στο διάστημα  $[0, 1000]$

Το αποτέλεσμα των προηγούμενων ενεργειών ήταν η κατασκευή μια πλούσιας συλλογής δεδομένων, η οποία από αποτελούνταν από πραγματικά δεδομένα κίνησης για 40 σταθμούς, με περισσότερα από περίπου 60.000 δείγματα για τον καθένα. Ενδεικτικά, στο Σχήμα 4.2 φαίνονται τα δεδομένα του σταθμού της Επιδάουρου προτού καθαριστούν, ενώ στο Σχήμα 4.3 φαίνονται τα δεδομένα αφότου αφαιρέθηκαν οι προβληματικές περιοχές.



**Σχήμα 4.3:** Δεδομένα κίνησης πάνω από την έξοδο της Επιδαύρου με κατεύθυνση την Ελευσίνα μετά τον καθαρισμό των δεδομένων.

#### 4.1.4 Σχολιασμός δεδομένων

Από το Σχήμα 4.3 μπορούμε να επιβεβαιώσουμε και την ύπαρξη των αναμενόμενων ιδιοτήτων της χρονοσειράς της κίνησης. Η χρονοσειρά παρουσιάζει δύο μορφές περιοδικότητας: ημερήσια και εβδομαδιαία (με τις Κυριακές να έχουν ιδιαίτερα αυξημένη κίνηση, λόγω της αυξημένης κίνησης προς την Αθήνα την μέρα εκείνη), παρουσιάζει εποχικότητα, καθώς κινείται σε υψηλότερα επίπεδα κατά την περίοδο του καλοκαιριού και κοντά σε αργίες και εθνικές εορτές όπως το Πάσχα, αλλά και την τυχαιότητα, η οποία οφείλεται σε τυχαία συμβάντα που μπορεί να προκύψουν κατά το μήκος της οδού.

## 4.2 Πρόβλεψη κίνησης με χρήση επαναληπτικών νευρωνικών δικτύων

Στην Ενότητα αυτή παρουσιάζονται τα διάφορα μοντέλα που δοκιμάστηκαν με στόχο την πρόβλεψη της κίνησης για τη συλλογή των δεδομένων που παρουσιάστηκε στην Ενότητα 4.1. Για την δημιουργία, την εκπαίδευση, τον έλεγχο και τη δοκιμή όλων των δομών και των μοντέλων που παρουσιάζονται σε αυτή και την επόμενη ενότητα, αναπτύχθηκε σε Python [VanR09] ένα CLI εργαλείο που φροντίζει για την διεπαφή με την βάση δεδομένων (MongoDB <https://www.mongodb.com/>) στην οποία είναι αποθηκευμένη η συλλογή των δεδομένων, καθώς και όλος ο κύκλος (κατασκευή, εκπαίδευση, επαλήθευση, δοκιμή σε πραγματικά δεδομένα) των μοντέλων μηχανικής μάθησης που χρησιμοποιήθηκαν. Για το κομμάτι της μηχανικής μάθησης, χρησιμοποιήθηκε η βιβλιοθήκη *scikit-learn* [Pedr11] και το *Keras Framework* [Chol15] της Google. Ο κώδικας των μοντέλων που χρησιμοποιήθηκαν είναι ανοιχτός και διαθέσιμος στο GitHub <https://github.com/neoaggelos/zeus.git>.

Στην Ενότητα 4.2.1 αναφέρονται δοκιμές και ενέργειες που έγιναν για την προεπεξεργασία των δεδομένων κίνησης. Ακολουθούν τρεις ενότητες στις οποίες παρουσιάζονται οι κυριότερες αρχιτεκτονικές που δοκιμάστηκαν κατά την εκπόνηση της εργασίας, καθώς και τα αποτελέσματα που αυτές έδωσαν. Στην τελευταία υποενότητα εξετάζεται το πώς

μεταβάλλεται η ακρίβεια και η συμπεριφορά των μοντέλων κατά την πρόβλεψη για διαφορετικούς χρονικούς ορίζοντες.

#### 4.2.1 Προεπεξεργασία δεδομένων

Το κομμάτι της προεπεξεργασίας των δεδομένων ήταν κυρίως μέρος της διαδικασίας της κατασκευής της συλλογής των δεδομένων. Ως αποτέλεσμα, δεν υπήρχε ανάγκη για περαιτέρω μετασχηματισμούς κατά την χρήση τους κατά την εκπαίδευση.

Στις αρχικές δοκιμές, ελέγχθηκαν δύο πιθανοί μετασχηματισμοί των δεδομένων. Ο πρώτος ήταν η κλιμάκωση (scaling) των τιμών των δεδομένων κίνησης σε ένα μικρότερο διάστημα τιμών (π.χ.  $[0, 1]$ ). Ωστόσο, αυτό βρέθηκε να μην βελτιώνει τα αποτελέσματα εκπαίδευσης των μοντέλων, ή ακόμα και σε κάποιες περιπτώσεις να τα επιβαρύνει.


Επιπλέον, δοκιμάστηκε η πρόβλεψη των τιμών να γίνεται με χρήση των διαφορών μεταξύ διαδοχικών δειγμάτων της χρονοσειράς (timeseries differencing), οι οποίες αθροίζονται για να δώσουν την τελική πρόβλεψη του μοντέλου. Για παράδειγμα, αν υποθέσουμε ως είσοδο την ακολουθία  $x(t) = [0, 10, 14, 7]$ , τότε η ακολουθία διαφορών της θα ήταν η  $x'(t) = [10 - 0, 14 - 10, 7 - 14] = [10, 4, -7]$ . Χρησιμοποιώντας την ακολουθία  $x'(t)$ , το μοντέλο δεν χρησιμοποιεί την απόλυτη τιμή της μέτρησης, αλλά την μεταβολή της σε κάθε χρονικό βήμα. Η τελική πρόβλεψη βρίσκεται προσθέτοντας τις επιμέρους προβλέψεις για την μεταβολή της κίνησης σε κάθε βήμα.

Η τεχνική αυτή χρησιμοποιείται σε ανάλυση χρονοσειρών όταν αυτές εμφανίζουν έντονη εποχικότητα ή μη στασιμότητα του μέσου όρου τους. Για τα δεδομένα του προβλήματός μας, αυτό δεν ήταν σημαντικό ζήτημα, οπότε η διαφορίση της χρονοσειράς δεν μπόρεσε να προσφέρει καλύτερο αποτέλεσμα, και τελικά εγκαταλείφθηκε.

#### 4.2.2 Πρόβλεψη χρονοσειράς κίνησης

##### Αρχιτεκτονική

Για την πρόβλεψη της μελλοντικής κίνησης χρησιμοποιείται ένα μοντέλο μηχανικής μάθησης που χτίζεται γύρω από ένα LSTM. Η αρχιτεκτονική φαίνεται στο Σχήμα 4.4.



**Σχήμα 4.4:** Απλή αρχιτεκτονική μοντέλου πρόβλεψης κίνησης βασισμένη σε LSTM

Η συλλογή των δεδομένων που έχουμε στη διαθεσή μας είναι μετρήσεις  $x(t)$  για χρονικές στιγμές  $t$  ανά 6 λεπτά. Έστω ότι βρισκόμαστε στην χρονική στιγμή  $t_0 = 0$  και θέλουμε να κάνουμε πρόβλεψη με χρονικό ορίζοντα 1 ώρας. Μιλώντας σε χρονικά "βήματα", θέλουμε να κάνουμε πρόβλεψη για την τιμή της κίνησης 10 χρονικά βήματα αργότερα, δηλαδή την στιγμή  $t_p = 10$ .

Η πρώτη απόφαση που πρέπει να πάρουμε είναι πόσα δεδομένα από το παρελθόν θα χρησιμοποιήσουμε ως είσοδο στο LSTM για την πρόβλεψη. Με δοκιμές, βρέθηκε ότι μία καλή τιμή είναι η χρήση δεδομένων που πηγαίνουν πίσω στο χρόνο περίπου όσο μπροστά πηγαίνει και η πρόβλεψη που θέλουμε να κάνουμε. Ως αιτιολόγηση αυτής της επιλογής, το επιχείρημα είναι ότι η χρήση πολύ μικρής διάρκειας δεδομένων οδηγεί σε απώλεια πληροφορίας, ενώ η χρήση δεδομένων πολύ μακρινών εισάγουν άχρηστη πληροφορία στο μοντέλο. Συνεπώς, για πρόβλεψη 1 ώρας, χρησιμοποιούνται δεδομένα από τις μετρήσεις της τελευταίας 1 ώρας.

Με βάση τα παραπάνω, η είσοδος που δίνεται στο LSTM φαίνεται στη Σχέση 4.1

$$x(t_0) = [y(t_0 - N + 1), y(t_0 - N + 2), \dots, y(t_0 - 1), y(t_0)] \quad (4.1)$$

Η τιμή που υπολογίζεται από το LSTM μεταφέρεται ως είσοδος σε ένα πλήρως διασυνδεδεμένο επίπεδο, του οποίου η έξοδος είναι και η συνολική έξοδος του δικτύου. Η μορφή της ζητούμενης έξοδου  $O(t)$  φαίνεται στη Σχέση 4.2

$$O(t_0) = [y(t_0 + 1), y(t_0 + 2), \dots, y(t_0 + N - 1), y(t_0 + N)] \quad (4.2)$$


Πρακτικά, η έξοδος του δικτύου είναι μια πρόβλεψη για την χρονική εξέλιξη της κίνησης σε όλο το διάστημα από το παρόν ( $t_0$ ) μέχρι και την ζητούμενη χρονική στιγμή. Μερικές από τις σταθερές επιλογές που έγιναν για το δίκτυο είναι:

- Ως συνάρτηση ενεργοποίησης στο πλήρως διασυνδεδεμένο επίπεδο χρησιμοποιήθηκε η ημιγραμμική.
- Μετά από μικρό αριθμό αρχικών δοκιμών, ως συνάρτηση ενεργοποίησης στο LSTM/GRU χρησιμοποιήθηκε η υπερβολική εφραπτομένη, λόγω της μεγαλύτερης κλίσης της συγκριτικά με τη σιγμοειδή. Η χρήση της σιγμοειδούς ήταν προβληματική, καθώς η πολύ μικρή της κλίση καθιστούσε την εκπαίδευση εξαιρετικά αργή και αναποτελεσματική. Η χρήση της ημιγραμμικής αντίστοιχα είχε υπερβολικά απότομες μεταβολές κατά την εκπαίδευση (λόγω της μορφής της κλίσης της), ενώ γενικότερα δεν ενδείκνυται για χρήση σε LSTM.
- Το πλήρως συνδεδεμένο επίπεδο αποτελείται από  $N$  νευρώνες, όσα και τα χρονικά βήματα για τα οποία θέλουμε να κάνουμε πρόβλεψη. Η έξοδος κάθε νευρώνα είναι η κάθε μία από τις προβλέψεις του δικτύου.
- Πρόβλεψη για 1 ώρα στο μέλλον (10 βήματα), χρησιμοποιώντας δεδομένα 1 ώρα στο παρελθόν (10 βήματα).
- Ως συνάρτηση κόστους επιλέχθηκε το μέσο τετραγωνικό σφάλμα (RMSE) μεταξύ της πραγματικής και της επιθυμητής εξόδου.

Ενώ οι ελεύθερες υπερπαραμέτροι ήταν:

- Ο αριθμός νευρώνων εντός του LSTM κελιού.
- Η χρήση LSTM κελιών ή GRU κελιών.
- Η χρήση ή μη ενός Dropout layer μεταξύ των επιπέδων του δικτύου.
- Ο αριθμός των κρυφών επιπέδων του μοντέλου (τα οποία αποτελούνται από LSTM κελιά). Στο Σχήμα 4.4 υπάρχει μόνο ένα κελί LSTM. Αν θέλουμε να χρησιμοποιήσουμε περισσότερα από 1, τότε αυτά τοποθετούνται σε σειρά πριν το πλήρες διασυνδεδεμένο επίπεδο, όπως στο Σχήμα 4.5.
- Ο αριθμός των εποχών εκπαίδευσης.
- Το batch size της εκπαίδευσης.

Στόχος αυτού του δικτύου είναι η εξαγωγή μιας πρόβλεψης για όλη την εξέλιξη της κίνησης μέχρι τη ζητούμενη χρονική στιγμή.



**Σχήμα 4.5:** Απλή αρχιτεκτονική μοντέλου πρόβλεψης κίνησης, με χρήση δύο stacked LSTMs

## Εκπαίδευση και εύρεση βέλτιστου συνδυασμού υπερπαραμέτρων για την αρχιτεκτονική

Η διαδικασία εκπαίδευσης του νευρωνικού μοντέλου για την πρόβλεψη της κίνησης ενός σταθμού έχει ως εξής:

1. Ανάκτηση ιστορικών δεδομένων κίνησης από κάποιον σταθμό με τα οποία θα πραγματοποιηθεί η εκπαίδευση.
2. Μετασχηματισμός για χρήση με το LSTM, ανάλογα με τον χρονικό ορίζοντα για τον οποίο θέλουμε να κάνουμε πρόβλεψη. Συγκεκριμένα, για κάθε χρονική στιγμή  $t$ , φτιάχνεται το διάνυσμα εισόδου σύμφωνα με τη Σχέση 4.1 και το διάνυσμα επιθυμητής εξόδου σύμφωνα με τη Σχέση 4.2.
3. Επιλογή ενός συνδυασμού υπερπαραμέτρων, κατασκευή του μοντέλου και αρχικοποίηση των βαρών του.
4. Εκπαίδευση του μοντέλου με βάση τα δεδομένα του επιλεγμένου σταθμού.
5. Επαλήθευση της εκπαίδευσης σε άγνωστα δεδομένα του ίδιου σταθμού.
6. Επαλήθευση της εκπαίδευσης σε δεδομένα άλλου σταθμού από αυτόν για τον οποίο έγινε η εκπαίδευση.

<b>LSTM neurons</b>	10, 30, 50, 70
<b>Cell Class</b>	<i>GRU, LSTM</i>
<b>Hidden LSTM Layers</b>	1, 2, 3
<b>Dropout</b>	0, 0.01, 0.02, 0.1
<b>Training Batch Size</b>	64, 128
<b>Training Epochs</b>	10, 30, 50

**Πίνακας 4.2:** Τιμές υπερπαραμέτρων που δοκιμάστηκαν για το μοντέλο του απλού LSTM

Η επαλήθευση της λειτουργία των μοντέλων έγινε με διασταυρούμενη επικύρωση 5 μερών. Για την εύρεση του βέλτιστου συνδυασμού υπερπαραμέτρων έγινε εξαντλητική αναζήτηση σε όλους τους συνδυασμούς των τιμών υπερπαραμέτρων που φαίνονται στον Πίνακα 4.2. Τα αποτελέσματα για τους 10 καλύτερους συνδυασμούς υπερ-παραμέτρων φαίνονται στον Πίνακα 4.3. Το όνομα των μοντέλων είναι ένα τυχαίο αλφαριθμητικό μήκους 5 χαρακτήρων για λόγους διαχειριστικής ευκολίας και μόνο.

<b>model</b>	<b>loss</b>	<b>val-loss</b>	<b>batch</b>	<b>epochs</b>	<b>neurons</b>	<b>layers</b>	<b>base</b>	<b>dropout</b>
<i>ayivu</i>	198.15	166.39	64	30	50	2	<i>GRU</i>	0.01
<i>sttgc</i>	201.81	167.14	64	10	30	1	<i>LSTM</i>	0.01
<i>sqclx</i>	195.04	168.36	128	30	30	2	<i>LSTM</i>	0.01
<i>unmbm</i>	213.90	168.52	64	30	50	3	<i>GRU</i>	0.01
<i>aklna</i>	196.08	168.53	128	50	30	2	<i>GRU</i>	0.01
<i>uhkvn</i>	198.38	169.16	64	10	30	1	<i>GRU</i>	0
<i>nhbqv</i>	197.56	169.43	64	30	70	2	<i>LSTM</i>	0.01
<i>yhhbs</i>	194.95	169.58	64	30	70	2	<i>GRU</i>	0
<i>iiadx</i>	194.10	169.87	128	30	50	3	<i>LSTM</i>	0
<i>tqrwr</i>	192.89	170.32	128	50	30	2	<i>LSTM</i>	0

**Πίνακας 4.3:** Αποτελέσματα gridsearch για την απλή αρχιτεκτονική με LSTM

Η επιλογή των 5 καλύτερων συνδυασμών έγινε με κριτήριο την τιμή της συνάρτησης κόστους στο σύνολο δεδομένων επικύρωσης, το οποίο όπως φαίνεται μπορεί να είναι διαφορετικό από την αντίστοιχη τιμή στο σύνολο δεδομένων εκπαίδευσης. Για παράδειγμα, το μοντέλο *ayivu*, μπορεί να είχε το χαμηλότερο σφάλμα επικύρωσης από αυτά που φαίνονται στον πίνακα, ωστόσο το σφάλμα εκπαίδευσης ήταν μεγαλύτερο από αυτό άλλων, όπως το *tgrwr*. Αυτό σημαίνει πως το *ayivu* έχει την δυνατότητα να γενικεύει καλύτερα από το *tgrwr*, στο οποίο συγκριτικά μοιάζει να έχει συμβεί υπερπροσαρμογή (το οποίο είναι συνεπές και με τον αριθμό των εποχών εκπαίδευσης του καθενός). Μερικά ακόμη σχόλια που μπορούμε να εξάγουμε από τον πίνακα των αποτελεσμάτων είναι:

- **Τα μοντέλα που στηρίζονται σε GRU έχουν επιτυχία συγκρίσιμη με αυτή των LSTM.** Η συμπεριφορά αυτή ήταν αρκετά αναμενόμενη και συνεπής με την βιβλιογραφία, στην οποία τα GRU επιλέγονται συχνά όταν τα δεδομένα του προβλήματος έχουν μικρή διαστατικότητα και απλή μορφή.
- **Τα καλύτερα αποτελέσματα δόθηκαν από μοντέλα που εκπαιδεύτηκαν για μικρότερο αριθμό εποχών.** Αυτό σημαίνει ότι για μεγαλύτερο αριθμό εποχών (50) αρχίζουμε να έχουμε υπερπροσαρμογή.
- **Τα μοντέλα έδωσαν καλύτερο αποτέλεσμα όταν είχαν μία μικρή τιμή Dropout.** Αυτό μπορεί να αποδοθεί επίσης στην δυνατότητα καλύτερης εκπαίδευσης αγνώστου μέρους της τυχαιότητας των δεδομένων.
- **Τα stacked LSTM και GRU (2 ή 3 κρυφά επίπεδα αντί για 1) δίνουν καλύτερο αποτέλεσμα.** Από επιβεβαιώνει επίσης την βιβλιογραφία, στην οποία αναφέρεται ότι η προσθήκη κρυφών επιπέδων σε ένα νευρωνικό δίκτυο επιτρέπει την αναγνώριση προτύπων και συσχετίσεων μεγαλύτερης πολυπλοκότητας.

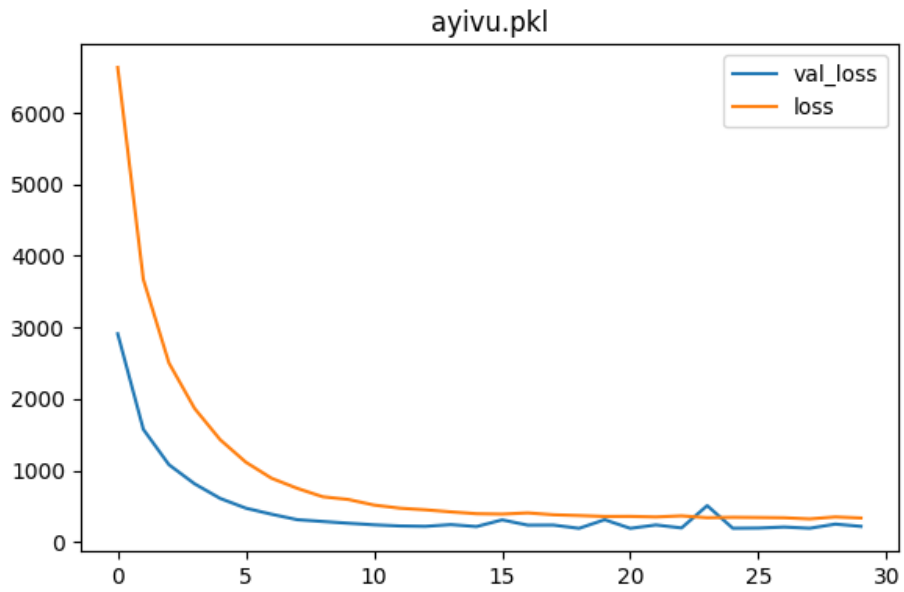
## Αποτελέσματα

Η καμπύλη εκπαίδευσης του μοντέλου *ayivu.pkl* φαίνεται στο Σχήμα 4.6. Η μορφή της ακολουθεί αυτήν που συστήνεται από την βιβλιογραφία. Η κλίση είναι πολύ μεγάλη κατά την αρχή της εκπαίδευσης, καθώς το μοντέλο κάνει την αρχική προσαρμογή του στα δεδομένα εκπαίδευσης. Μετά την πάροδο αυτών, τα βάρη του μοντέλου αρχίζουν να προσαρμόζονται μέχρι το τέλος της εκπαίδευσης. Πολύ σημαντικό είναι επίσης να παρατηρήσουμε και την καμπύλη του σφάλματος επαλήθευσης. Ακολουθεί την μορφή του σφάλματος εκπαίδευσης όσο περνάνε οι εποχές εκπαίδευσης, πράγμα που επιβεβαιώνει ότι το μοντέλο δεν έχει (τουλάχιστον εμφανές) πρόβλημα υπερπροσαρμογής.


Στα Σχήματα 4.7 και 4.8 ακολουθούν δύο παραδείγματα πρόβλεψης κίνησης για 1 ώρα στο μέλλον με χρήση του μοντέλου *ayivu.pkl*. Αξίζει να σημειωθεί ότι το μοντέλο αναγνωρίζει και προσαρμόζεται με επιτυχία σε μέρες με αυξημένη κίνηση, αντιμετωπίζοντας αποτελεσματικά τα όποια φαινόμενα εποχικότητας εμφανίζει ο κάθε σταθμός, χωρίς να έχει χρειαστεί κάποια ειδική μέριμνα για αυτό. Επιπλέον, και οι δύο προβλέψεις αφορούν σταθμούς άλλους από αυτόν στον οποίο έγινε η εκπαίδευση, επαληθεύοντας την δυνατότητα γενίκευσης του μοντέλου και της «μεταφερσιμότητάς» του.

### 4.2.3 Πρόβλεψη χρονοσειράς κίνησης με είσοδο δεδομένα προηγούμενου σταθμού

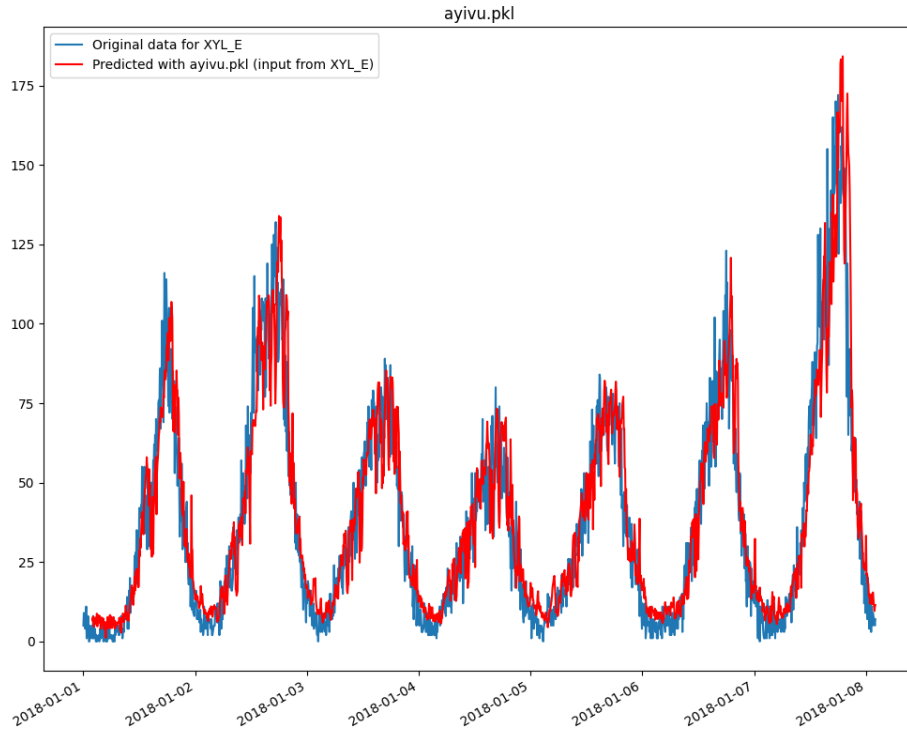
Το οδικό δίκτυο της Ολυμπίας Οδού είναι ένα «κλειστό» σύστημα στο οποίο μετρώνται τόσο τα οχήματα που εισέρχονται όσο και αυτά που εξέρχονται από την οδό και είναι βέβαιο ότι ένα όχημα που διέρχεται από έναν σταθμό  $k$  μία χρονική στιγμή  $t$ , σε επόμενη χρονική στιγμή  $t' > t$  θα μετρηθεί σε κάποιον επόμενο σταθμό  $k'$ . Λόγω αυτού, μπορούμε



**Σχήμα 4.6:** Καμπύλη εκπαίδευσης του μοντέλου *ayivu.pkl*.



**Σχήμα 4.7:** Πρόβλεψη για 1 ώρα με χρήση του μοντέλου *ayivu.pkl* για το σταθμό της Κορίνθου με κατεύθυνση προς Πάτρα.



**Σχήμα 4.8:** Πρόβλεψη για 1 ώρα με χρήση του μοντέλου *ayivu.pkl* για το σταθμό του Ξυλοκάστρου με κατεύθυνση προς Αθήνα.

να υποθέσουμε ότι, αν θέλουμε να προβλέψουμε την κίνηση ενός σταθμού  $k$  στο μέλλον, θα ήταν πιο χρήσιμο ως είσοδο να χρησιμοποιήσουμε την τρέχουσα κατάσταση κάποιου προηγούμενου σταθμού της ίδιας κατεύθυνσης.

Υπό αυτό το πρίσμα, έγινε δοκιμή μίας τέτοιας αρχιτεκτονικής. Η μορφή του νευρωνικού δικτύου παραμένει ακριβώς ίδια με αυτήν που παρουσιάστηκε στην Ενότητα 4.2.2, αλλάζει όμως ο τρόπος με τον οποίο αξιοποιούνται τα διαθέσιμα δεδομένα. Συγκεκριμένα, αν η πρόβλεψη αφορά τον σταθμό  $k$ , αλλά η είσοδος λαμβάνεται από τον σταθμό  $l < k$ , τότε το διάνυσμα εξόδου κατασκευάζεται με τον τρόπο που υποδεικνύει η Σχέση 4.3 (η οποία είναι ίδια με την Σχέση 4.2):

$$O_k(t_0) = [y_k(t_0 + 1), y_k(t_0 + 2), \dots, y_k(t_0 + N - 1), y_k(t_0 + N)] \quad (4.3)$$

Ενώ η είσοδος χρησιμοποιεί τα δεδομένα του σταθμού  $l$ :


$$x(t_0) = [y_l(t_0 - N + 1), y_l(t_0 - N + 2), \dots, y_l(t_0 - 1), y_l(t_0)] \quad (4.4)$$

### Αποτελέσματα δοκιμής

Δοκιμαστικά έγινε εκπαίδευση ενός μοντέλου, το οποίο δέχεται είσοδο από τον σταθμό Ξυλοκάστρου (με κατεύθυνση Αθήνα), με στόχο την πραγματοποίηση πρόβλεψης στον σταθμό Κορίνθου (επίσης με κατεύθυνση την Αθήνα). Παρότι το σφάλμα εκπαίδευσης και επαλήθευσης ήταν ενθαρρυντικά, εν τέλει η ποιότητα των προβλέψεων δεν άγγιζε το επιθυμητό, ενώ σε αρκετά χρονικά διαστήματα ήταν εμφανώς χειρότερο. Χαρακτηριστικά παρατίθεται το Σχήμα 4.9, στο οποίο φαίνεται ότι η πρόβλεψη της κίνησης έχει μια εμφανή υστέρηση σε σχέση με την πραγματική τιμή.

Δεδομένου ότι το αποτέλεσμα δεν ήταν αυστηρά καλύτερο από την χρησιμοποίηση του ίδιου του σταθμού για είσοδο, και λαμβάνοντας υπόψιν το γεγονός ότι η χρήση δύο





**Σχήμα 4.9:** Πρόβλεψη για 1 ώρα με χρήση του μοντέλου *xmgHz.pkl* για το σταθμό της Κορίνθου με κατεύθυνση προς Αθήνα. Η πρόβλεψη έχει γίνει χρησιμοποιώντας δεδομένα από τον σταθμό του Ξυλοκάστρου.

σταθμών εισάγει αρκετές νέες πηγές προβλημάτων (ανάγκη συγχρονισμού μεταξύ των δύο σταθμών, αν σταματήσει η λειτουργία του αισθητήρα σε έναν σταθμό, τότε χάνουμε την δυνατότητα πρόβλεψης σε δύο σημεία, ζητήματα μεταφερσιμότητας του μοντέλου σε άλλους σταθμούς από αυτούς για τους οποίους εκπαιδεύτηκε), δεν εξερευνήθηκε περαιτέρω η ιδέα αυτή.

Ωστόσο, αξίζει να σημειωθεί ότι υπάρχουν πάρα πολλά ενδιαφέροντα περιθώρια βελτίωσης της συγκεκριμένης ιδέας, απλώς ξεφεύγουν της κλίμακας και του εύρους της παρούσας εργασίας. Ενδεικτικά αναφέρονται δύο από τις πιθανές βελτιώσεις:

- Χρήση δεδομένων περισσότερων του ενός προηγούμενων σταθμών. Ο σταθμός από τον οποίο λαμβάνεται κάθε ένα στοιχείο του διανύσματος εισόδου μπορεί να διαφέρει, και εν γένει σχετίζεται με την «χρονική» απόσταση από τον σταθμό για τον οποίο θέλουμε να κάνουμε πρόβλεψη της κίνησης.
- Χρήση πολλών παράλληλων μοντέλων, χρησιμοποιώντας διαφορετικό σταθμό εισόδου για το κάθε ένα. Η τελική πρόβλεψη γίνεται συνδυάζοντας τις επιμέρους (επιλογή πιο «κατάλληλης», υπολογισμό ως γραμμικού συνδυασμού).

#### 4.2.4 Πρόβλεψη χρονοσειράς κίνησης με αξιοποίηση επιπλέον δεδομένων


Μία παρατήρηση της μορφής των δεδομένων είναι ότι ανα σταθμό υπάρχουν κατά κύριο λόγο δύο διαφορετικές κατηγορίες ημερών·τα Σαββατοκύριακα και οι αργίες, στα οποία η κίνηση είναι ιδιαίτερα αυξημένη, και οι εργάσιμες μέρες, που η οδός εμφανίζει μικρότερη κίνηση. Γεννιέται κατά αυτόν τον τρόπο μια νέα προσέγγιση του προβλήματος, το μοντέλο να λαμβάνει υπόψιν του όχι μόνο τα τρέχοντα δεδομένα της κίνησης, αλλά και το είδος της ημέρας στην οποία αναφέρεται η πρόβλεψη. Αυτό θα μπορούσε να γίνει με δύο τρόπους:

1. Χρήση δύο διακριτών δικτύων όπως αυτό του Σχήματος 4.5, και χρήση κάθε φορά ενός μόνο από τα δύο, ανάλογα με την ημέρα στην οποία αναφέρονται τα δεδομένα.
2. Εμπλουτισμός της αρχιτεκτονικής του Σχήματος 4.5 ώστε να λαμβάνει μία ακόμη είσοδο κατά την πρόβλεψη, το είδος της ημέρας.

Η πρώτη λύση μοιάζει αρκετά απλή στην υλοποίηση, ωστόσο έχει αρκετά προβλήματα. Τα πιο προφανή είναι ότι κάνει μια αυθαίρετη παραδοχή για την μορφή των δεδομένων, ενώ περιορίζει σημαντικά τα δεδομένα εκπαίδευσης κάθε ενός από τα δύο μοντέλα. Έτσι, στα πλαίσια της εργασίας αυτής επιλέχθηκε ο δεύτερος τρόπος.

## Αρχιτεκτονική

Ο σχεδιασμός της αρχιτεκτονικής του μοντέλου φαίνεται στο Σχήμα 4.10.



**Σχήμα 4.10:** Αρχιτεκτονική μοντέλου πρόβλεψης κίνησης, με χρήση δύο stacked LSTMs, και με επιπλέον είσοδο το είδος της ημέρας για το οποίο γίνεται η πρόβλεψη

Πρακτικά, έχουμε πάλι ένα ή περισσότερα stacked LSTM για την επεργασία της χρονοσειράς κίνησης για την πραγματοποίηση της πρόβλεψης. Ωστόσο, αυτή τη φορά στο πλήρως διασυνδεδεμένο επίπεδο (dense layer) δίνεται μία ακόμη είσοδος, η οποία είναι ένα κατηγορικό χαρακτηριστικό της ημέρας στην οποία αναφέρεται η πρόβλεψη. Με αυτόν τον τρόπο, το δίκτυο δύναται κατά την εκπαίδευση να μάθει τον τρόπο με τον οποίο η μέρα επηρεάζει την εξέλιξη της κίνησης, προσαρμόζοντας κατάλληλα την πρόβλεψή του.

Κατά την υλοποίηση, δοκιμάστηκαν δύο διαφορετικοί τρόποι ενσωμάτωσης της πληροφορίας της ημέρας στην πρόβλεψη:

- **WithDay:** Στο μοντέλο δίνεται ως είσοδος η πληροφορία της ημέρας ως ένας αριθμός από το 1 έως το 7. Επιτρέπει στο μοντέλο να αξιοποιήσει με τον τρόπο που θεωρεί αυτό πιο κατάλληλο.
- **WithROI:** Στο μοντέλο δίνεται ως είσοδος μία δυαδική πληροφορία για την ημέρα: αν αναμένεται υψηλή κίνηση ή όχι. Αυτό επιτρέπει, κατά την παραγωγή προβλέψεων από το μοντέλο, ο χρήστης να ζητήσει ρητά πρόβλεψη για μέρα υψηλής ή χαμηλής κυκλοφορίας, το οποίο ενδεχομένως θα πρόσθετε σημαντική αξία σε πραγματικές συνθήκες λειτουργίας.

## Εκπαίδευση

Όπως και στην Ενότητα 4.2.2, έγινε αναζήτηση των βέλτιστων υπερπαραμέτρων με εξαντλητική αναζήτηση και διασταυρούμενη επικύρωση 5-μερών κατά την εκπαίδευση. Δοκιμάστηκαν οι συνδυασμοί των υπερπαραμέτρων που φαίνονται στον Πίνακα 4.4.

## Αποτελέσματα και σχολιασμός

Τα αποτελέσματα για τους 10 καλύτερους συνδυασμούς φαίνονται στον Πίνακα 4.5:


Συγκρίνοντας τα αποτελέσματα με αυτά του Πίνακα 4.3, βλέπουμε ότι στο σύνολό τους είναι συγκρίσιμα. Όμοια, η καμπύλη εκπαίδευσης του *tvryc.pkl* φαίνεται στο Σχήμα 4.11 έχει την επιθυμητή μορφή, με απότομη κλίση στην αρχή της και πιο ομαλή στη συνέχεια, με το σφάλμα επαλήθευσης να μειώνεται σταθερά στην πορεία.

<b>Day Feature Type</b>	<i>WithDay, WithROI</i>
<b>LSTM neurons</b>	10, 30, 50, 70
<b>Cell Class</b>	<i>GRU, LSTM</i>
<b>Hidden LSTM Layers</b>	1, 2, 3
<b>Dropout</b>	0, 0.01, 0.02, 0.1
<b>Training Batch Size</b>	64, 128
<b>Training Epochs</b>	10, 30, 50

**Πίνακας 4.4:** Τιμές υπερπαραμέτρων που δοκιμάστηκαν για το μοντέλο του LSTM με επιπλέον χαρακτηριστικό την ημέρα για την οποία γίνεται η πρόβλεψη


model	loss	val-loss	batch	epochs	neurons	layers	base	dropout	type
<i>tvryc</i>	194.86	165.88	128	30	70	2	<i>GRU</i>	0	<i>WithROI</i>
<i>cnxrs</i>	202.55	166.69	64	10	50	2	<i>GRU</i>	0.01	<i>WithDay</i>
<i>oaxpt</i>	197.86	166.77	64	10	30	2	<i>LSTM</i>	0	<i>WithROI</i>
<i>hlabp</i>	194.80	167.47	128	30	30	2	<i>LSTM</i>	0	<i>WithROI</i>
<i>ucshd</i>	194.94	168.08	128	30	50	3	<i>LSTM</i>	0	<i>WithDay</i>
<i>ppieo</i>	196.76	168.46	128	50	30	1	<i>GRU</i>	0.01	<i>WithROI</i>
<i>amvuv</i>	201.20	168.54	128	10	50	1	<i>GRU</i>	0.01	<i>WithDay</i>
<i>cwvnm</i>	197.79	168.61	64	10	50	1	<i>LSTM</i>	0	<i>WithDay</i>
<i>mtugo</i>	193.50	168.69	128	50	50	3	<i>GRU</i>	0.01	<i>WithROI</i>
<i>smhcm</i>	202.50	168.75	64	10	70	2	<i>LSTM</i>	0.01	<i>WithDay</i>

**Πίνακας 4.5:** Αποτελέσματα gridsearch για την αρχιτεκτονική LSTM με χρήση της μέρας ως επιπλέον χαρακτηριστικό



**Σχήμα 4.11:** Καμπύλη εκπαίδευσης του μοντέλου *tvryc.pkl*.

Ωστόσο, με παρατήρηση των προβλέψεών του, παρατηρούμε ότι το μοντέλο δεν κατάφερε εν τέλει να βελτιώσει το αποτέλεσμα για τις υψηλές κορυφές των τιμών. Αντίθετα, υπήρχαν περιπτώσεις στις οποίες το μοντέλο δεν μπόρεσε καν να ακολουθήσει την κορυφή, όπως φαίνεται και στο Σχήμα 4.12. Αυτή η συμπεριφορά πιθανότατα οφείλεται στις ανομοιογενείς εισόδους του πλήρως διασυνδεδεμένου επιπέδου στην έξοδο του δικτύου.



**Σχήμα 4.12:** Πρόβλεψη για 1 ώρα με χρήση του μοντέλου *tvryc.pkl* για το σταθμό της Κορίνθου με κατεύθυνση προς Αθήνα.

Δοκιμαστικά, επιχειρήθηκε η χρήση της ημιγραμμικής συνάρτησης ενεργοποίησης αντί της υπερβολικής εφαπτομένης. Δημιουργήθηκε έτσι το μοντέλο *uzvjg.pkl*, πανομοιότυπο του *tvryc.pkl* με μόνη διαφορά την συνάρτηση ενεργοποίησης. Η καμπύλη εκπαίδευσης του *uzvjg.pkl* φαίνεται στο Σχήμα 4.13. Η απότομη κλίση της ReLU κάνει την εκπαίδευση πολύ απότομη, με τις περισσότερες εποχές να περνούν χωρίς ιδιαίτερο αποτέλεσμα.

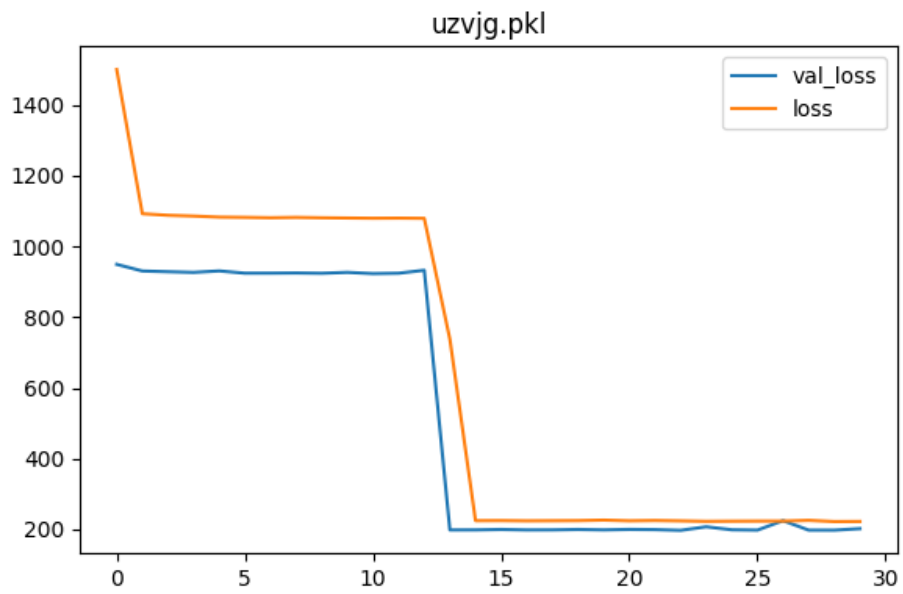
Ωστόσο, η πρόβλεψη καταφέρνει να ακολουθήσει σωστά τις κορυφές της κίνησης, όπως φαίνεται στο Σχήμα 4.14:

#### 4.2.5 Πρόβλεψη επιπέδου κίνησης


##### Κίνητρο

Τα μοντέλα που παρουσιάστηκαν στις προηγούμενες ενότητες χρησιμοποιούν τα πρόσφατα δεδομένα κίνησης και παράγουν πρόβλεψη για την ακριβή τιμή της κίνησης. Πράγματι, ως αρχιτεκτονικές είναι αποτελεσματικές σε αυτό. Παρά την ακρίβειά τους, όμως, εμφανίζονται δύο κρίσιμα ζητήματα σχετικά την λειτουργία τους:

1. Το πρόβλημα της πρόβλεψης κίνησης είναι πρόβλημα παλινδρόμησης, συνεπώς δεν είναι δυνατό (και ούτε και ζητούμενο) να επιτευχθεί 100% επιτυχία. Ωστόσο, κατά τη διάρκεια της εκπαίδευσης, ο αλγόριθμος υπολογίζει την έξοδο του δικτύου, την συγκρίνει με την επιθυμητή και μεταβάλλει τα βάρη του δικτύου κατά ένα ποσό ανάλογο του σφάλματος. Αποτέλεσμα αυτού είναι, ακόμα και για ελάχιστες αποκλίσεις,



**Σχήμα 4.13:** Καμπύλη εκπαίδευσης του μοντέλου *uzvjg.pkl*.

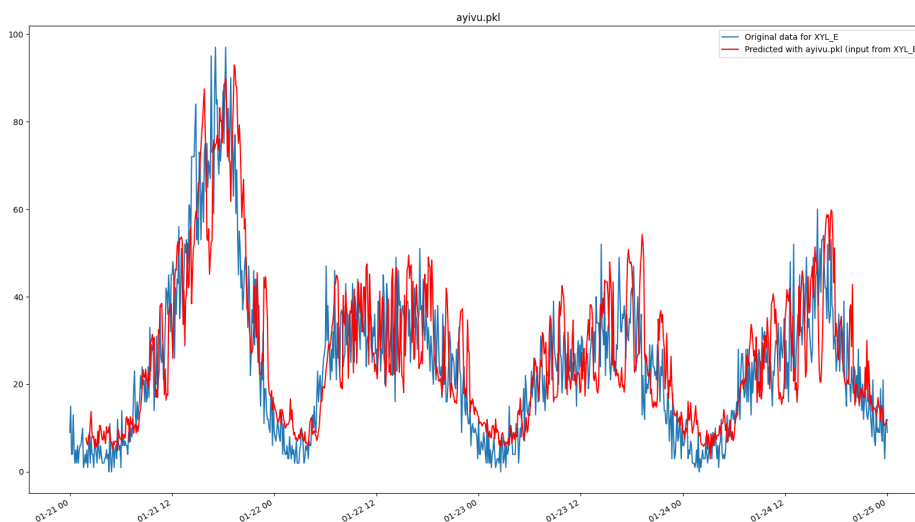


**Σχήμα 4.14:** Πρόβλεψη για 1 ώρα με χρήση του μοντέλου *uzvjg.pkl* για το σταθμό της Κορίνθου με κατεύθυνση προς Αθήνα.

τα βάρη του δικτύου να μεταβάλλονται διαρκώς. Το ποσό της μεταβολής δεν είναι αμελητέο, αν αναλογιστούμε πως σε κάθε εποχή παρουσιάζονται στο δίκτυο περισσότερα από 80.000 δείγματα εκπαίδευσης. Εν τέλει, το δίκτυο μεταβάλλει συνεχώς την κατάσταση, αδυνατώντας να ισορροπήσει με επιτυχία και να κάνει προσαρμογή των παραμέτρων του.

- Είναι σημαντικό να κάνουμε ένα βήμα πίσω και να επανέλθουμε στο αρχικό πρόβλημα που προσπαθούσαμε να λύσουμε. Η πρόβλεψη της κίνησης ως πρόβλημα δεν ενδιαφέρεται πραγματικά για την ακριβή τιμή των αυτοκινήτων, αλλά περισσότερο για το επίπεδο ή κλάση στην οποία αυτή κινείται (π.χ. πολύ χαμηλή, χαμηλή, ..., υψηλή και ούτω καθεξής), καθώς και την εξέλιξη της στον χρόνο.

Μία ενδεικτική εικόνα του πρώτου ζητήματος αυτού αποτελεί το Σχήμα 4.15. Δεν μπορούμε να ισχυριστούμε ότι το δίκτυο δεν είναι ακριβές στις προβλέψεις του ως μεμονομένα σημεία. Παρ' όλα αυτά, θα θέλαμε να έχουμε μία αρχιτεκτονική η οποία να είναι πιο «ευσταθής» στην πορεία του χρόνου.



**Σχήμα 4.15:** Πρόβλεψη για 1 ώρα με χρήση του μοντέλου *ayivu.pkl* για το σταθμό του Ξυλοκάστρου με κατεύθυνση την Αθήνα. Η προβλέψη σε κάθε χρονική στιγμή μπορεί να θεωρηθεί ακριβής, ωστόσο συνολικά η έξοδος του μοντέλου παρουσιάζει τεράστια μεταβλητότητα

Με βάση τα παραπάνω, έχει αξία η δημιουργία ενός μοντέλου το οποίο θα κάνει πρόβλεψη για το διάστημα της αναμενόμενης κίνησης, μετατρέποντας έτσι το πρόβλημα της πρόβλεψης σε πρόβλημα ταξινόμησης διακριτών κλάσεων. Συγκεκριμένα, κάθε διάστημα κίνησης αποτελεί και μία κλάση ή κατηγορία.

## Αρχιτεκτονική

Η αρχιτεκτονική αυτού του μοντέλου εποπτικά είναι ίδια με αυτή των Σχημάτων 4.5 και 4.10. Η διαφορά έγκειται στην μορφή του επιπέδου εξόδου. Αυτό πλέον θα έχει  $N$  νευρώνες, όσες είναι και οι κλάσεις στις οποίες θέλουμε να διαχωρίσουμε την κίνηση. Ως συνάρτηση ενεργοποίησής του κάθε νευρώνα χρησιμοποιήθηκε η συνάρτηση *softmax*, ενώ ως συνάρτηση κόστους για την εκπαίδευση χρησιμοποιήθηκε η συνάρτηση *κατηγορικής διασταυρούμενης εντροπίας* (categorical crossentropy), η οποία συνίσταται για προβλήματα ταξινόμησης.

Ανάλογα με τον νευρώνα που ενεργοποιείται κάθε φορά (ενεργοποιείται αυτός που θα δώσει την μέγιστη τιμή για κάποια είσοδο), θεωρούμε ότι έχουμε πρόβλεψη της αντίστοιχης κλάσης κίνησης. Οι υπερπαραμέτροι του δικτύου αυτού είναι:

- **Το πλάτος κάθε κλάσης.** Επιλέχθηκε εκ των προτέρων σταθερό και ίσο με 20. Έτσι, τα διαστήματα για τα οποία γίνεται πρόβλεψη είναι τα  $[0, 20]$ ,  $[21, 40]$ , ...
- **Ο αριθμός των κλάσεων πρόβλεψης.** Επιλέχθηκε εκ των προτέρων σταθερό και ίσο με 30. Η τελευταία κλάση είναι η  $[541, +\infty]$
- **Ο αριθμός των νευρώνων του LSTM ή GRU.**
- **Ο αριθμός των κρυφών επιπέδων LSTM ή GRU.**
- **Ο τύπος κελιού (LSTM ή GRU).**
- **Η ύπαρξη ή όχι ενός επιπέδου Dropout ανάμεσα στα κρυφά επίπεδα.**
- **Ο αριθμός εποχών εκπαίδευσης.**
- **Το batch-size κατά την εκπαίδευση.**

## Εκπαίδευση

Για την εύρεση της βέλτιστης αρχιτεκτονικής, εκτελέστηκε εξαντλητική αναζήτηση με διασταυρούμενη επικύρωση 5-μερών κατά την εκπαίδευση του δικτύου. Η αναζήτηση έγινε για τους συνδυασμούς υπερπαραμέτρων που φαίνονται στον Πίνακα 4.6:

<b>LSTM neurons</b>	30, 40, 50, 60, 70
<b>Cell Class</b>	<i>GRU, LSTM</i>
<b>Hidden LSTM Layers</b>	1, 2, 3
<b>Dropout</b>	0, 0.01, 0.1
<b>Training Batch Size</b>	64, 128
<b>Training Epochs</b>	10, 20, 30

**Πίνακας 4.6:** Τιμές υπερπαραμέτρων που δοκιμάστηκαν για το μοντέλο πρόβλεψης κλάσεων κίνησης

## Αποτελέσματα

Τα αποτελέσματα των 10 καλύτερων συνδυασμών υπερπαραμέτρων παρουσιάζονται στον Πίνακα 4.7. Στο Σχήμα 4.16 φαίνεται η καμπύλη εκπαίδευσης του μοντέλου *psexh.pkl*. Όπως και παραπάνω, έχει απότομη κλίση στην αρχή της εκπαίδευσης και έπειτα εξομαλύνεται. Δύο παραδείγματα προβλέψεων με το μοντέλο πρόβλεψης κλάσεων κίνησης φαίνονται στα Σχήματα 4.17 και 4.18.


## Σχολιασμός

Σε γενικές γραμμές βλέπουμε ότι το μοντέλο ανταπεξέρχεται με επιτυχία στις προβλέψεις του, ακολουθώντας τις κορυφές. Επιπλέον, διαθέτει μία μεγαλύτερη σταθερότητα στις προβλέψεις του, κάτι από έλειπε από τις προβλέψεις συνεχούς τιμής.

Η αξία του μοντέλου πρόβλεψης κατηγορίας κλάσεων έγκειται στην μεγαλύτερη ευκολία χρήσης του, χωρίς ταυτόχρονα να θυσιάζεται η ποιότητα των προβλέψεων. Όπως

model	neurons	layers	base	correct	±20	±40	±60
<i>pscxh</i>	30	3	<i>GRU</i>	59.29%	94.91%	99.70%	99.91%
<i>orxyr</i>	40	3	<i>GRU</i>	60.65%	95.50%	99.69%	99.92%
<i>fvayc</i>	30	3	<i>LSTM</i>	59.55%	95.31%	99.69%	99.92%
<i>rrpch</i>	30	2	<i>LSTM</i>	62.33%	95.54%	99.72%	99.91%
<i>npzkl</i>	50	3	<i>LSTM</i>	58.85%	95.11%	99.68%	99.91%
<i>hhglj</i>	70	2	<i>LSTM</i>	62.08%	96.48%	99.70%	99.92%
<i>wlrux</i>	40	3	<i>LSTM</i>	61.05%	95.76%	99.71%	99.93%
<i>galfd</i>	60	3	<i>LSTM</i>	58.58%	94.01%	99.67%	99.91%
<i>ylwyt</i>	60	3	<i>GRU</i>	60.76%	95.42%	99.67%	99.91%
<i>xaftu</i>	60	2	<i>LSTM</i>	61.31%	94.90%	99.67%	99.92%
<i>htclq</i>	50	3	<i>GRU</i>	59.31%	94.86%	99.66%	99.91%

**Πίνακας 4.7:** Αποτελέσματα gridsearch για την αρχιτεκτονική πρόβλεψης κλάσεων κίνησης. Για όλα τα μοντέλα είναι  $epochs = 30$  και  $dropout = 0$ .



**Σχήμα 4.16:** Καμπύλη εκπαίδευσης του μοντέλου *pscxh.pkl*.

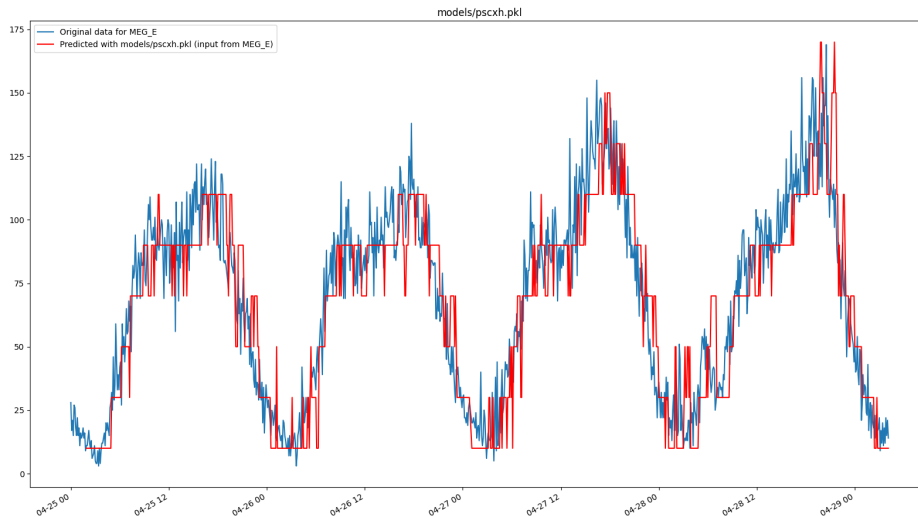
βλέπουμε και στον Πίνακα 4.7, μπορεί το αποτέλεσμα της πρόβλεψης να μην είναι πάντοτε σωστό, ωστόσο αν επιτραπεί σφάλμα ενός βήματος η επιτυχία ξεπερνάει το 95%, ενώ με δύο βήματα καλύπτεται το 99,7% των δειγμάτων.

#### 4.2.6 Σύγκριση ακρίβειας μοντέλου για διαφορετικούς χρονικούς ορίζοντες πρόβλεψης


Σε όλες τις προηγούμενες υποενότητες, η πρόβλεψη της κίνησης έχει γίνει για χρονικό ορίζοντα 10 βημάτων (1 ώρας), χρησιμοποιώντας ως είσοδο επίσης 10 δείγματα (1 ώρα στο παρελθόν). Στην υποενότητα αυτή εξετάζεται η συμπεριφορά των μοντέλων όσο αυτός ο ορίζοντας μεταβάλλεται.

Για λόγους απλότητας, εξετάζεται μόνο το μοντέλο πρόβλεψης κλάσεων κίνησης. Χρησιμοποιώντας τις υπερπαραμέτρους του *pscxh.pkl* της προηγούμενης ενότητας, εκπαιδεύτηκαν σε δεδομένα του Σταθμού της Κορίνθου με κατεύθυνση την Αθήνα (KOR\_E) και επαληθεύτηκαν στα δεδομένα του Σταθμού Ξυλοκάστρου (XYL\_T) με κατεύθυνση την Πά-





**Σχήμα 4.17:** Πρόβλεψη για 1 ώρα με χρήση του μοντέλου *pscch.pkl* για το σταθμό των Μεγάρων με κατεύθυνση προς Αθήνα.



**Σχήμα 4.18:** Πρόβλεψη για 1 ώρα με χρήση του μοντέλου *pscch.pkl* για το σταθμό του Ξυλοκάστρου με κατεύθυνση προς Πάτρα.

τρα τα μοντέλα του Πίνακα 4.8.

Τα δεδομένα του Πίνακα 4.8 έχουν τοποθετηθεί και στο Σχήμα 4.19 για καλύτερη εποπτεία. Το συμπέρασμα που προκύπτει άμεσα είναι ότι ακόμα και για προβλέψεις πολύ μακριά στο μέλλον, το μοντέλο πρόβλεψης κλάσης δίνει πολύ καλά αποτελέσματα, με δεδομένο ότι του επιτρέπεται ένα λογικό περιθώριο σφάλματος.


### 4.3 Ανίχνευση έκτοπων τιμών

#### 4.3.1 Κίνητρο και χρησιμότητα

Ως τελευταίο μέρος της εργασίας αναπτύχθηκε ένα σύστημα ανίχνευσης έκτοπων τιμών για τα δεδομένα της κίνησης. Το κίνητρο για την ανάπτυξη ενός τέτοιου μοντέλου ήταν διπλό:

Μοντέλο	Είσοδος	Έξοδος	Ακριβής Πρόβλεψη	±20	±40	±60
ywjus	1 ώρα	1 ώρα	62.21%	95.62%	99.64%	99.89%
uxrjz	1 ώρα	2 ώρες	45.73%	81.86%	98.18%	99.71%
krnkh	2 ώρες	2 ώρες	46.73%	85.34%	98.95%	99.83%
xehjw	4 ώρες	4 ώρες	20.93%	61.41%	85.17%	97.25%
micgx	2 ώρες	4 ώρες	29.17%	73.71%	93.18%	98.95%

**Πίνακας 4.8:** Ποσοστά Επιτυχίας Πρόβλεψης Κλάσης Κίνησης για 1, 2 και 4 ώρες στο μέλλον. Τα αποτελέσματα έχουν ληφθεί για τα δεδομένα του σταθμού Ξυλοκάστρου με κατεύθυνση την Πάτρα.



**Σχήμα 4.19:** Ποσοστά Επιτυχίας Πρόβλεψης Κλάσης Κίνησης για 1, 2 και 4 ώρες στο μέλλον. Στον οριζόντιο άξονα φαίνονται τα επιτρεπτά όρια απόκλισης της πρόβλεψης από την πραγματική τιμή.

- Όπως αναφέρθηκε εκτενώς στην Ενότητα 4.1, τα πρωτογενή δεδομένα που είχαν συλλεχθεί από τους αισθητήρες περιείχαν μεγάλο αριθμό σφαλμάτων, λανθασμένων μετρήσεων, θορύβου ή/και ελλείψεις τιμών. Δεδομένου ότι το μοντέλο μηχανικής μάθησης που φτιάχνουμε πρέπει να μπορεί να ανταπεξέρχεται στα δεδομένα που θα του δίνονται στον πραγματικό κόσμο, είναι απαραίτητο να μπορεί να διαχειριστεί ή έστω να αναγνωρίσει αυτή την κατάσταση.
- Η ποιότητα των προβλέψεων του μοντέλου στηρίζεται στην ποιότητα των δεδομένων εκπαίδευσης, αλλά και των δεδομένων πρόβλεψης. Ακόμα και αν το μοντέλο έχει ιδανικό σχεδιασμό, δεν είναι δυνατό να δώσει καλύτερο από αυτό που του επιτρέπουν τα δεδομένα του. Συνεπώς, είναι απαραίτητο να υπάρχει ένας μηχανισμός που διαπιστώνει ή ελέγχει την ποιότητα των δεδομένων.

### 4.3.2 Πρόβλημα ανίχνευσης έκτοπων τιμών

Κατά την αρχική δημιουργία της συλλογής των δεδομένων, έγινε μία μεγάλη χειροκίνητη προσπάθεια καθαρισμού, με χρήση μόνο απλών προγραμμάτων για την ανίχνευση έκτοπων τιμών, βασιζόμενα σε στατικούς κανόνες (rule-based). Στην συνέχεια, διαπιστώθηκε ότι δεν είχαν αφαιρεθεί όλα τα προβληματικά σημεία και εν τέλει αποτέλεσε και ευκαιρία για την δοκιμή ενός συστήματος ανίχνευσης έκτοπων τιμών. Ένα τέτοιο σύστημα θα μπορούσε να έχει δύο μορφών επίβλεψη:

1. Εκπαίδευση με βάση εκ των προτέρων γνώση για το αν κάποιο δείγμα αποτελεί έκτοπη τιμή ή όχι. Αυτό είναι πρακτικά αδύνατο για τα δεδομένα μας, λόγω του αχα-

νούς όγκου τους. Επιπλέον, δεν λύνει το πρόβλημα της αναγνώρισης ιδιότροπων χαρακτηριστικών με άγνωστη μορφή.

2. Εκπαίδευση χωρίς εκ των προτέρων γνώση για το αν κάποιο δείγμα αποτελεί έκτοπη τιμή ή όχι, αλλά με χρήση μίας μετρικής η οποία ορίζει κατά πόσο τα δεδομένα περιέχουν έκτοπες τιμές. Το μοντέλο στη συνέχεια, κατά την προσαρμογή του στα δεδομένα, θα προσπαθήσει να ανακαλύψει μόνο του τις ιδιότητες και τα χαρακτηριστικά που κρίνουν αν ένα δείγμα των δεδομένων είναι έκτοπη τιμή. Επιλέχτηκε η χρήση αυτής της μεθόδου.

Ακόμη μία σημαντική παρατήρηση που πρέπει να γίνει σε αυτό το σημείο είναι ότι ένας τρόπος εντοπισμού έκτοπων τιμών θα ήταν η χρήση κάποιου από τα μοντέλα πρόβλεψης που παρουσιάστηκαν στην Ενότητα 4.2, και η σήμανση ενός δείγματος ως έκτοπου με βάση το κατά πόσο αυτό συμφωνεί με την πρόβλεψη. Ένα πολύ σοβαρό μειονέκτημα αυτής της λύσης είναι ότι η πρόβλεψη του μοντέλου καθορίζεται από τα ίδια τα δεδομένα, οπότε δεν γίνεται πραγματικός έλεγχος της ποιότητάς τους, καθώς το μοντέλο μπορεί να οδηγήσει τον εαυτό του σε εσφαλμένα συμπεράσματα.

### 4.3.3 Isolation forests

Τα Isolation forests μπορούν να βρίσκουν έκτοπες τιμές σε μία συλλογή δεδομένων βασισμένα στην κατασκευή δεντρικών δομών οι οποίες απομονώνουν τις έκτοπες τιμές. Είναι αλγόριθμος μη επιβλεπόμενης μάθησης, και χρησιμοποιεί ως βασική υπερπάρμετρο την *μόλυνση* (contamination) των δεδομένων, δηλαδή μία ποσότητα που καθορίζει πόσο περιεκτικό σε έκτοπες τιμές είναι το σύνολο των δεδομένων.

#### Αρχική Δοκιμή


Για να εφαρμοστεί στις χρονοσειρές κίνησης που μας ενδιαφέρει στα πλαίσια της εργασίας, για κάθε χρονική στιγμή  $t$  παίρνουμε ως διάνυσμα εισόδου τις  $N$  πιο πρόσφατες μετρήσεις κίνησης, π.χ. για  $N = 3$ , το διάνυσμα εισόδου θα είναι  $[x(t-2), x(t-1), x(t)]$ . Δεν χρησιμοποιούνται δεδομένα μετά την χρονική στιγμή  $t$ , έτσι ώστε η πρόβλεψη για το παρόν να μην απαιτεί γνώση του μέλλοντος, και έτσι να μπορεί να εφαρμοστεί on-line.

Στο Σχήμα 4.20 φαίνεται το αποτέλεσμα. Το δέντρο εκπαιδεύτηκε στα δεδομένα του σταθμού της Κορίνθου. Λόγω της μορφής των δεδομένων εισόδου, έμαθε ως έκτοπες τιμές όλες τις ημέρες στις οποίες υπήρχε αυξημένη κίνηση λόγω ημέρας (Κυριακή). Αυτό προφανώς δεν είναι το επιθυμητό αποτέλεσμα.


#### Βελτίωση μέσω μετασχηματισμού των δεδομένων

Για την αντιμετώπιση του προβλήματος αποφασίστηκε να ακολουθηθεί μία απλούστερη μορφή της λύσης που προτείνεται στο [Ma03]. Το διάνυσμα εισόδου αποτελεί ένα κυλιόμενο παράθυρο της χρονοσειράς, για το οποίο υπολογίζονται η μέση τιμή, η μέγιστη και η ελάχιστη διαφορά μεταξύ των διαδοχικών τιμών του, καθώς και η διασπορά των διαφορών αυτών. Στο δέντρο δίνεται ως είσοδος το νέο αυτό διάνυσμα, το οποίο είναι αρκετά πιο πλούσιο σε πληροφορία.

Πράγματι, στο Σχήμα 4.21 φαίνεται ότι το δέντρο δεν επικεντρώνεται σε στοιχεία που ξεπερνούν κάποια τιμή κατωφλίου, αλλά αναγνωρίζει πραγματικά περιοχές με έκτοπες τιμές και σφάλματα.



**Σχήμα 4.20:** Ανίχνευση έκτοπων τιμών με Isolation Forest, χρησιμοποιώντας ως διάλυσμα εισόδου τις πιο πρόσφατες  $N$  μετρήσεις. Είναι  $N = 5$  και  $contamination = 0.1$ .



**Σχήμα 4.21:** Ανίχνευση έκτοπων τιμών με Isolation Forest, χρησιμοποιώντας ως διάλυσμα εισόδου χαρακτηριστικά του κυλιόμενου παραθύρου της χρονοσειράς. Είναι  $N = 5$  και  $contamination = 0.1$

## Συμπεράσματα

Συνολικά, μερικά από τα συμπεράσματα που εξάχθηκαν κατά τις δοκιμές των Isolation Forest για ανίχνευση έκτοπων τιμών στα δεδομένα μας:

- Τα Isolation Forests αποτελούν έναν πολύ γρήγορο (στην εκπαίδευση και την χρήση), απλό και σχετικά μη απαιτητικό σε πόρους αλγόριθμο για εύρεση εκτόπων τιμών σε ένα σύνολο δεδομένων.
- Η επιτυχία τους σε χρονοσειρές βελτιώνεται εφαρμόζοντας κατάλληλο μετασχηματισμό στα δεδομένα.
- Η σωστή επιλογή της υπερπαραμέτρου μόλυνσης και η επιλογή των δεδομένων στα οποία προσαρμόζεται το δέντρο έχουν πολύ μεγάλη σημασία. Ένα προσαρμοσμένο

δέντρο κατά κύριο λόγο είναι μεταφύσιμο σε άγνωστα δεδομένα, ωστόσο το αποτέλεσμα δεν είναι πάντοτε πολύ χρήσιμο.

- Επειδή δεν έχουμε πραγματική γνώση για το πότε οι τυχαίες μεταβολές αφορούν κάποιο τυχαίο συμβάν, είναι σφάλμα μέτρησης, ή απλά η κίνηση σε εκείνο το σημείο απλώς χαρακτηρίζεται από μεγάλη τυχαιότητα, είναι πολύ δύσκολο να κρίνουμε το κατά πόσο το δίκτυο έχει προσαρμοστεί σωστά.
- Η πρόβλεψη για το αν ένα δείγμα της συλλογής δεδομένων αποτελεί έκτοπη τιμή δεν χρησιμοποιεί μελλοντική πληροφορία, και έτσι μπορεί εν δυνάμει να αξιοποιηθεί σε on-line συστήματα.

#### 4.3.4 Μηχανές διανυσμάτων υποστήριξης μίας κλάσης


Η αναζήτηση έκτοπων τιμών με χρήση μηχανών διανυσμάτων υποστήριξης μίας κλάσης (one-class SVM) βασίζεται στην εύρεση μίας ελάχιστης σφαίρας ( $c, r$ ) εντός της οποίας ανήκουν τα "κανονικά" δεδομένα. Οτιδήποτε βρίσκεται εκτός αυτής κατηγοριοποιείται ως έκτοπη τιμή.

Η ιδέα της χρήσης των one-class SVMs για τις χρονοσειρές κίνησης είναι πανομοιότυπη με αυτή των Isolation Forests. Οι υπερπαραμέτροι σε αυτή την περίπτωση είναι η *συνάρτηση πυρήνα* (kernel function), η παράμετρος  $\gamma$ , καθώς και μία αριθμητική  $\nu$  η οποία καθορίζει και πάλι την περιεκτικότητα του συνόλου δεδομένων σε έκτοπες τιμές.

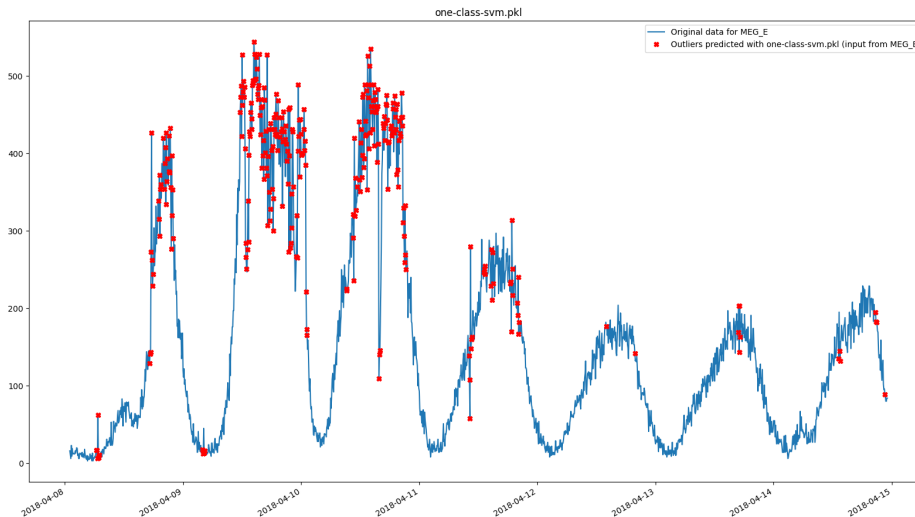
Όπως και με τα Isolation Forests, έτσι και εδώ μετασχηματίζουμε το κυλιόμενο παράθυρο της χρονοσειράς σε ένα διάνυσμα που περιγράφει τα τοπικά χαρακτηριστικά της.

#### Αποτελέσματα


Με δοκιμές βρέθηκε ότι ένας καλός συνδυασμός υπερπαραμέτρων είναι  $\nu \in [0.01, 0.02]$  και χρήση *rbf* ως συνάρτηση πυρήνα. Στα Σχήματα 4.24 και 4.23 φαίνεται πώς επηρεάζει η παράμετρος  $\nu$  την συμπεριφορά του μοντέλου και την πυκνότητα των σημείων που θεωρεί ως έκτοπα. Επίσης, στο Σχήμα 4.22 φαίνεται ότι το μοντέλο βρίσκει πράγματι έκτοπες τιμές και όχι απλώς τιμές μεγαλύτερες από κάποιο όριο.



**Σχήμα 4.22:** Ανίχνευση έκτοπων τιμών με One-class SVM, για εκπαίδευση του SVM με  $\nu = 0.01$ . Ως έκτοπες τιμές σημαδεύονται από το μοντέλο σημεία που πράγματι έχουν πρόβλημα, και όχι η αυξημένη κίνηση του Σαββατοκύριακου.



**Σχήμα 4.23:** Ανίχνευση έκτοπων τιμών με One-class SVM, για εκπαίδευση του SVM με  $\nu = 0.02$ .



**Σχήμα 4.24:** Ανίχνευση έκτοπων τιμών με one-class SVM, για εκπαίδευση του SVM με  $\nu = 0.01$ .

### Συμπεράσματα

Τα συμπεράσματα που μπορούμε να εξάγουμε για τις μηχανές διανυσμάτων υποστήριξης μίας κλάσης σχετικά με την επίδοσή τους στην ανίχνευση έκτοπων τιμών στα δεδομένα μας είναι τα εξής:

- Απαιτείται σημαντικά περισσότερος χρόνος κατά την εκπαίδευση. Στις δοκιμές που έγιναν, ο χρόνος εκπαίδευσης αυξανόταν σημαντικά για μεγαλύτερες τιμές της παραμέτρου  $\nu$ .
- Για προβλέψεις στα ίδια δεδομένα, οι μηχανές διανυσμάτων υποστήριξης μίας κλάσης είχαν παρόμοια συμπεριφορά και ακρίβεια με τα Isolation Forests. Αν μπορούσαμε να ξεχωρίσουμε κάποιο από τα δύο ως επικρατέστερο, αυτό θα ήταν οι μηχανές διανυσμάτων υποστήριξης, με πολύ μικρή όμως διαφορά.
- Όπως αναφέρθηκε και στην αρχή της ενότητας, το πρόβλημα ανίχνευσης έκτοπων

τιμών σε δεδομένα είναι πρόβλημα μη επιβλεπόμενης μάθησης, συνεπώς η επιλογή των κατάλληλων τιμών για τις υπερπαραμέτρους των μοντέλων αποτελεί ευριστική διαδικασία, και εξαρτάται σε μεγάλο βαθμό από τα δεδομένα που χρησιμοποιούνται κατά την προσαρμογή.





## Κεφάλαιο 5

# Συμπεράσματα και Μελλοντικές Κατευθύνσεις

### 5.1 Συμπεράσματα

Στα πλαίσια της παρούσας εργασίας πραγματοποιήθηκαν τρεις βασικοί στόχοι: Η κατασκευή μίας ογκώδους συλλογής δεδομένων από πρωτογενή δεδομένα, η ανάπτυξη και η δοκιμή διάφορων μοντέλων για την πρόβλεψη της κίνησης με χρήση των δεδομένων αυτών και τέλος η ανάπτυξη μοντέλων για ανίχνευση έκτοπων τιμών. Και οι τρεις αυτοί στόχοι επετεύχθηκαν σε έναν ικανοποιητικό βαθμό, και οδήγησαν σε αρκετά χρήσιμα συμπεράσματα.

Βασικό συμπέρασμα είναι η ότι η επιτυχία των μοντέλων μηχανικής μάθησης βασίζεται στην ποιότητα, την καθαρότητα και την αξιοπιστία των δεδομένων που χρησιμοποιούνται για την εκπαίδευσή τους. Πράγματι, από τις δοκιμές που έγιναν κατά την εκπόνηση της εργασίας, η χρήση δεδομένων με αυξημένο θόρυβο ή/και σφάλματα οδηγούσε στα αποτελέσματα της πρόβλεψης να απέχουν πολύ από τα επιθυμητά.

Όσον αφορά τις προβλέψεις κίνησης, τα LSTM και GRU έδωσαν πολύ καλά αποτελέσματα και μάλιστα συγκρίσιμα μεταξύ τους. Αυτό επιβεβαιώνει και τα συμπεράσματα της βιβλιογραφίας, ότι τα GRU ενδείκνυνται σε προβλήματα όπου η μορφή των δεδομένων και οι συσχετίσεις αυτών έχουν μικρή σχετικά πολυπλοκότητα, όπως ισχύει και στα δεδομένα που χρησιμοποιήθηκαν στην εργασία αυτή.

Επιπλέον, η πρόβλεψη κίνησης μπορεί να είναι ένα πρόβλημα παλινδρόμησης, ωστόσο η φύση του ως πρόβλημα αφήνει ένα επιτρεπτό σφάλμα κατά την πρόβλεψη. Έτσι, μπορεί να αντιμετωπιστεί αποτελεσματικά και ως πρόβλημα ταξινόμησης, στο οποίο η πρόβλεψη δεν αφορά τον ακριβή αριθμό της πρόβλεψης, αλλά περισσότερο την κλάση αυτής, με κάθε κλάση να αντιστοιχεί σε ένα εύρος τιμών.

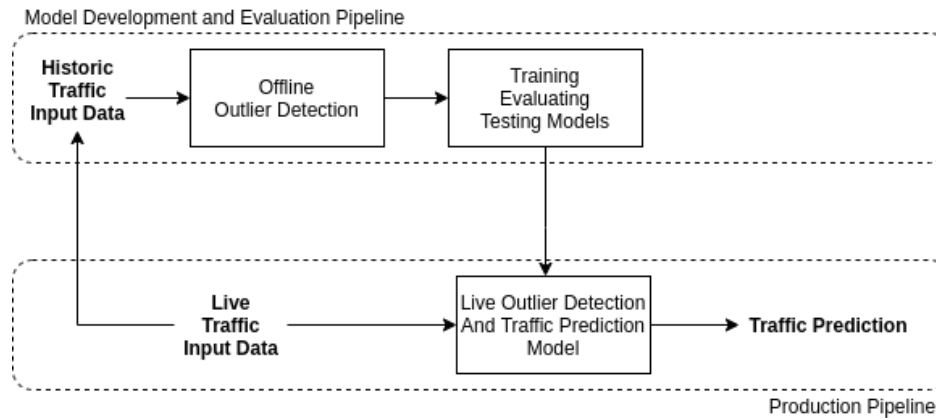
Ένα αρκετά θετικό στοιχείο που προέκυψε ήταν η μεταφερσιμότητα των μοντέλων σε δεδομένα άλλων σταθμών με πολύ υψηλό ποσοστό επιτυχίας. Στις περισσότερες δοκιμές, η επαλήθευση και ο έλεγχος των μοντέλων γινόταν σε δεδομένα διαφορετικού σταθμού από αυτόν στον οποίο είχε γίνει η εκπαίδευση. Επιπλέον, το μοντέλο συμπεριφερόταν με παρόμοια επιτυχία σε σταθμούς και των δύο κατευθύνσεων της οδού. Το συμπέρασμα είναι ότι τα μοντέλα καταφέρνουν να γενικεύσουν με επιτυχία την χρονική εξέλιξη της κίνησης, παρά να κάνουν υπερπροσαρμογή σε τοπικές ιδιαιτερότητες του κάθε σταθμού. Ο εμπλουτισμός της εισόδου με περισσότερη πληροφορία για την πρόβλεψη είχε επίσης θετική συνεισφορά.

Τέλος, όσον αφορά την ανίχνευση έκτοπων τιμών, τα Isolation Forests και one-class SVM επέδειξαν παρόμοια συμπεριφορά, με τα one-class SVM να απαιτούν περισσότερο χρόνο κατά την εκπαίδευση αλλά να δίνουν οριακά καλύτερη εικόνα.

Συνολικά, από τα αποτελέσματα της εργασίας αυτής φαίνεται ότι τα μοντέλα μηχανικής μάθησης που αναπτύχθηκαν είναι ικανά να υποστηρίξουν ένα σύστημα πρόβλεψης και παρακολούθησης κίνησης.

## 5.2 Πρόταση αρχιτεκτονικής ολοκληρωμένου συστήματος πρόβλεψης κίνησης

Στηριζόμενοι στα αποτελέσματα της παρούσας εργασίας, στην Ενότητα αυτή προτείνεται μια αρχιτεκτονική ενός ολοκληρωμένου συστήματος πρόβλεψης κίνησης.



Σχήμα 5.1: Σχεδιάγραμμα Προτεινόμενης Αρχιτεκτονικής

Όπως φαίνεται στο Σχήμα 5.1, το σύστημα αποτελείται από δύο διακριτές ροές πληροφορίας.

### 5.2.1 Εκπαίδευση και δοκιμή μοντέλων

Το πρώτο μέρος του συστήματος είναι μια ροή εκπαίδευσης, δοκιμής και επαλήθευσης μοντέλων μηχανικής μάθησης. Λειτουργεί off-line, δέχεται ως είσοδο γνωστά ιστορικά δεδομένα (αποθηκευμένα σε κάποια βάση δεδομένων), και τα χρησιμοποιεί για να δοκιμάζει διαφορετικές αρχιτεκτονικές μοντέλων μηχανικής μάθησης, καθώς και την εύρεση του βέλτιστου συνδυασμού υπερπαραμέτρων αυτών.

Σε αυτό τη ροή λαμβάνουν χώρα όλες οι ενέργειες και οι δοκιμές που περιγράφηκαν με λεπτομέρεια στις ενότητες 4.2 και 4.3. Η λειτουργία του είναι συνεχής (ούτως ώστε να ενσωματώνεται διαρκώς η νέα πληροφορία που συσσωρεύεται στο σύστημα από τους αισθητήρες μέτρησης) και να βελτιώνεται διαρκώς το αποτέλεσμα των προβλέψεων.

Επιπλέον, αποτελεί το ιδανικό σημείο για περαιτέρω ανάπτυξη των υπάρχοντων μοντέλων και δοκιμές εναλλακτικών αρχιτεκτονικών. Εν τέλει, αποτελεί ένα ασφαλές και ελεγχόμενο περιβάλλον, παραγόμενο αποτέλεσμα του οποίου είναι μοντέλα μηχανικής μάθησης τα οποία επαληθευμένα δίνουν εύστοχες προβλέψεις για τα δεδομένα κίνησης που του παρουσιάζονται.

### 5.2.2 Παρατήρηση και προβλέψεις σε πραγματικό χρόνο

Το δεύτερο μέρος του συστήματος είναι η ροή που εκτελεί προβλέψεις για την κίνηση σε πραγματικό χρόνο. Σε αυτό χρησιμοποιούνται μοντέλα που έχουν εκπαιδευτεί εκ των προτέρων (από την πρώτη ροή).

Τα δεδομένα εισόδου στη ροή αυτή έρχονται σε πραγματικό χρόνο από τους αισθητήρες που βρίσκονται στην οδό. Αρχικά, οι μετρήσεις ελέγχονται από το σύστημα ανίχνευσης έκτοπων τιμών, και έπειτα γίνεται πρόβλεψη για την χρονική εξέλιξη του επιπέδου της κίνησης. Πρόταση είναι η πρόβλεψη να γίνεται για μισή ώρα, μία ώρα, δύο ώρες και τέσσερις ώρες στο μέλλον, ούτως ώστε να δίνεται μία κατατοπιστική εικόνα στον λειτουργό του συστήματος. Έξοδος της ροής είναι οι προβλέψεις της κίνησης, καθώς και η εκτίμηση

για το αν η είσοδος περιέχει έκτοπες τιμές (οπότε να δίνεται η αντίστοιχη βαρύτητα και εμπιστοσύνη στην προβλεπόμενη τιμή).

Η πρόβλεψη ανανεώνεται διαρκώς (κάθε φορά που γίνεται διαθέσιμη νέα μέτρηση), οπότε ο λειτουργός του συστήματος έχει χρόνο να διαχειριστεί κατάλληλα την πληροφορία αυτή.

Εν προκειμένω, ο λειτουργός της οδού, ο οποίος δύναται να είναι κάποιος χειριστής ή κάποιο αυτόματο σύστημα, μπορεί εκ των προτέρων να γνωρίζει με μεγάλη ακρίβεια τα επίπεδα κίνησης που αναμένονται κατά μήκος της οδού, οπότε έχει την δυνατότητα να ρυθμίσει κατάλληλα το επίπεδο φωτισμού αυτής, και έτσι να περιορίσει την απαιτούμενη κατανάλωση ηλεκτρικής ενέργειας.

### 5.3 Μελλοντικές κατευθύνσεις

Μελλοντικά βήματα που επεκτείνουν τα μοντέλα που παρουσιάστηκαν καθώς και τα συμπεράσματα που προέκυψαν κατά την εκπόνηση της εργασίας αυτής είναι:

- Προσαρμογή των μοντέλων και δοκιμή ε αρχιτεκτονικών ακολουθίας-σε-ακολουθία.
- Αναζήτηση περισσότερο περίπλοκων αρχιτεκτονικών, ενδεχομένως αξιοποιώντας και συνελκτικά νευρωνικά δίκτυα, τα οποία συνδυάζονται αρκετά συχνά με LSTM στην βιβλιογραφία.
- Προς το παρόν, όλα τα μοντέλα που παρουσιάστηκαν χρησιμοποιούν δεδομένα εισόδου από έναν μόνο σταθμό κάθε φορά. Θα ήταν ενδιαφέρον να εξεταστεί πως επηρεάζεται το αποτέλεσμα αν χρησιμοποιούνται δεδομένα από περισσότερους του ενός σταθμών. Αυτό είναι μία γενίκευση του μοντέλου που δοκιμάστηκε στην Ενότητα 4.2.3, και θα μπορούσε να βοηθήσει αρκετά στο πρόβλημα του εντοπισμού έκτοπων τιμών.
- Έλεγχος αν η εισαγωγή στατικής γνώσης στο σύστημα μηχανικής μάθησης μπορεί να βοηθήσει στην ποιότητα των προβλέψεων (για παράδειγμα, ο χαρακτηρισμός ορισμένων ημερών όπως τα Χριστούγεννα ή ο Δεκαπενταύγουστο ως ημέρες υψηλής κίνησης).
- Τα προβλήματα του εντοπισμού έκτοπων τιμών και της πρόβλεψης κίνησης αντιμετωπίστηκαν ως ξεχωριστά, ωστόσο το ένα μπορεί να λειτουργεί συμπληρωματικά με το άλλο. Θα είχε αξία η εξέταση του κατά πόσο τα δύο αυτά μοντέλα μπορούν να συνδυαστούν σε ένα.
- Όλες οι δοκιμές έγιναν με δεδομένα μετρήσεων ανά 6 λεπτά. Μία επέκταση της υπάρχουσας δουλειάς που θα μπορούσε να πραγματοποιηθεί, προκειμένου τα μοντέλα να είναι ευκολότερο να χρησιμοποιηθούν γενικότερα, θα ήταν η δοκιμή με χρονικά βήματα μεγαλύτερης διάρκειας (παραδείγματος χάρη 12 λεπτών) ή μικρότερης (σε άλλα, βέβαια δεδομένα, καθώς στη συγκεκριμένη περίπτωση η χρονική ανάλυση είναι 6 λεπτά.).
- Αναζήτηση μεθόδων ώστε γνωστές έκτοπες τιμές να μην επηρεάζουν, ή γνωστές κενές τιμές να μην καθιστούν αδύνατη την χρήση των μοντέλων.
- Έλεγχος της ακρίβειας των μοντέλων για καταστάσεις που συμβαίνουν συχνά. Τα υψηλά ποσοστά ακρίβειας που επιτεύχθηκαν δεν σημαίνουν ότι το μοντέλο αδυνατεί συστηματικά να αναγνωρίσει καταστάσεις που μπορεί μεν να συμβαίνουν σπάνια, ωστόσο είναι καταστάσεις στις οποίες θέλουμε να μπορεί να αντεπεξέλθει.



## Βιβλιογραφία

- [Albe18] Maximilian Alber, Irwan Bello, Barret Zoph, Pieter-Jan Kindermans, Prajit Ramachandran and Quoc Le, “Backprop Evolution”, 2018.
- [Beng94] S. Bengio, Y. Bengio and J. Cloutier, “Use of genetic programming for the search of a new learning rule for neural networks”, in *Proceedings of the First IEEE Conference on Evolutionary Computation. IEEE World Congress on Computational Intelligence*, pp. 324–327 vol.1, 1994.
- [Bhat20] Manpreet Bhatia, Dr Aggarwal and Kshitij Garg, “Smart traffic light systems”, 06 2020.
- [Bish06] Christopher M. Bishop, *Pattern Recognition and Machine Learning (Information Science and Statistics)*, Springer-Verlag, Berlin, Heidelberg, 2006.
- [Burn03] K.P. Burnham and D.R. Anderson, *Model Selection and Multimodel Inference: A Practical Information-Theoretic Approach*, Springer New York, 2003.
- [Cho14] Kyunghyun Cho, Bart van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk and Yoshua Bengio, “Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation”, 2014.
- [Chol15] François Chollet et al., “Keras”, <https://keras.io>, 2015.
- [Cram06] Koby Crammer, Ofer Dekel, Joseph Keshet, Shai Shalev-Shwartz and Yoram Singer, “Online Passive-Aggressive Algorithms”, *Journal of Machine Learning Research*, vol. 7, pp. 551–585, January 2006.
- [Elsk18] Thomas Elsken, Jan Hendrik Metzen and Frank Hutter, “Neural Architecture Search: A Survey”, 2018.
- [Fano20] A Fanoon and Shafana A.R.F., “Smart Lighting System for Efficient Street Lighting”, 08 2020.
- [Filj11] Renato Filjar, Kresimir Vidovic, Pavao Britvic and Marijan Rimac, “eCall: Automatic notification of a road traffic accident.”, pp. 600–605, 01 2011.
- [Gref17] Klaus Greff, Rupesh K. Srivastava, Jan Koutnik, Bas R. Steunebrink and Jürgen Schmidhuber, “LSTM: A Search Space Odyssey”, *IEEE Transactions on Neural Networks and Learning Systems*, vol. 28, no. 10, p. 2222–2232, Oct 2017.
- [Grub20] Nicole Gruber and Alfred Jockisch, “Are GRU Cells More Specific and LSTM Cells More Sensitive in Motive Classification of Text?”, *Frontiers in Artificial Intelligence*, vol. 3, p. 40, 2020.
- [Hayk09] Simon S. Haykin, *Neural networks and learning machines*, Pearson Education, Upper Saddle River, NJ, third edition, 2009.

- [He15] Kaiming He, Xiangyu Zhang, Shaoqing Ren and Jian Sun, “Deep Residual Learning for Image Recognition”, 2015.
- [Hila20] Nur Hilal and Arda Yurdakul, “Model-based Design of a Roadside Unit for Emergency and Disaster Management”, pp. 1–6, 04 2020.
- [Hoch97] Sepp Hochreiter and Jürgen Schmidhuber, “Long Short-term Memory”, *Neural computation*, vol. 9, pp. 1735–80, 12 1997.
- [Hodg04] Victoria Hodge and Jim Austin, “A survey of outlier detection methodologies”, *Artificial intelligence review*, vol. 22, no. 2, pp. 85–126, 2004.
- [Hsie16] C.Y. Hsieh, Hui Wee and A. Chen, “Resilient logistics to mitigate supply chain uncertainty: A case study of an automotive company”, *Scientia Iranica*, vol. 23, pp. 2287–2296, 10 2016.
- [Janu16] Lucia Janušová and Silvia Čičmancová, “Improving Safety of Transportation by Using Intelligent Transport Systems”, *Procedia Engineering*, vol. 134, pp. 14 – 22, 2016. TRANSBALTICA 2015: PROCEEDINGS OF THE 9th INTERNATIONAL SCIENTIFIC CONFERENCE. May 7–8, 2015. Vilnius Gediminas Technical University, Vilnius, Lithuania.
- [Jin19] Baihong Jin, Yuxin Chen, Dan Li, Kameshwar Poolla and Alberto Sangiovanni-Vincentelli, “A One-Class Support Vector Machine Calibration Method for Time Series Change Point Detection”, 2019.
- [Kael96] Leslie Pack Kaelbling, Michael L. Littman and Andrew W. Moore, “Reinforcement Learning: A Survey”, *CoRR*, vol. cs.AI/9605103, 1996.
- [Kane17] Per Øyvind Kanestrøm, “Traffic flow forecasting with deep learning”, 2017.
- [Kole01] J. F. Kolen and S. C. Kremer, *A Field Guide to Dynamical Recurrent Networks*, chapter Gradient Flow in Recurrent Nets: The Difficulty of Learning LongTerm Dependencies, pp. 237–243, 2001.
- [Kuma16] Rahul Kumar and Kunal Gupta, *ITMS (Intelligent Traffic Management System)*, pp. 487–495, 03 2016.
- [Liao15] Qianli Liao, Joel Z. Leibo and Tomaso Poggio, “How Important is Weight Symmetry in Backpropagation?”, 2015.
- [Linn70] Seppo Linnainmaa, “The representation of the cumulative rounding error of an algorithm as a Taylor expansion of the local rounding errors”, *Master’s Thesis (in Finnish), Univ. Helsinki*, pp. 6–7, 1970.
- [Litm15] T. Litman, “Smart Congestion Relief Comprehensive Evaluation Of Traffic Congestion Costs and Congestion Reduction Strategies 24 July 2018”, 2015.
- [Liu09] Fei Tony Liu, Kai Ting and Zhi-Hua Zhou, “Isolation Forest”, pp. 413 – 422, 01 2009.
- [Lv15] Y. Lv, Y. Duan, W. Kang, Z. Li and F. Wang, “Traffic Flow Prediction With Big Data: A Deep Learning Approach”, *IEEE Transactions on Intelligent Transportation Systems*, vol. 16, no. 2, pp. 865–873, 2015.
- [M19] Mumdouh M., Dr. Yusuf Perwej, Awad Ahmed and Dr. Firoj Parwej, “Using Intelligent Transportation Systems the Modern Traffic Safety on the Highway in the Sudan”, vol. Volume 7, pp. Pages 1–13, 05 2019.

- [Ma03] Junshui Ma and S. Perkins, “Time-series novelty detection using one-class support vector machines”, vol. 3, pp. 1741 – 1745 vol.3, 08 2003.
- [Mena06] L. Mena and J. A. Gonzalez, “Machine Learning for Imbalanced Datasets: Application in Medical Diagnostic”, in *FLAIRS Conference*, 2006.
- [Miyi19] Abubakar Miyim and Mansur Muhammed, “Smart Traffic Management System”, pp. 1–6, 12 2019.
- [Nall19] Dinithi Nallaperuma, Rashmika Nawaratne, Tharindu Bandaragoda, Achini Adikari, Su Nguyen, Thimal Kempitiya, Daswin Silva, Daminda Alahakoon and Dakshan Pothuhera, “Online Incremental Machine Learning Platform for Big Data-Driven Smart Traffic Management”, *IEEE Transactions on Intelligent Transportation Systems*, vol. PP, pp. 1–12, 07 2019.
- [Neub17] Graham Neubig, “Neural Machine Translation and Sequence-to-sequence Models: A Tutorial”, 2017.
- [Pal19] Jakub Palša, Liberios Vokorokos, Eva Chovancova and Martin Chovanec, “Smart Cities and the Importance of Smart Traffic Lights”, pp. 587–592, 11 2019.
- [Paul19] John Paul, “Smart Traffic management”, 11 2019.
- [Peca17] Martin Pecar and Gregor Papa, “Transportation problems and their potential solutions in smart cities”, pp. 195–199, 10 2017.
- [Pedr11] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot and E. Duchesnay, “Scikit-learn: Machine Learning in Python”, *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [Phil17] George Philipp, Dawn Song and Jaime G. Carbonell, “The exploding gradient problem demystified - definition, prevalence, impact, origin, tradeoffs, and solutions”, 2017.
- [Roc18] A. Roc, P. Banuprakash, G. Raj and L. Prasad, “Smart Traffic Light Systems”, *International Journal of Emerging Research in Management and Technology*, vol. 6, p. 243, 06 2018.
- [Rout18] Neelam Rout, “Handling Imbalanced Data: A Survey”, 01 2018.
- [Rume86] D. Rumelhart, Geoffrey E. Hinton and R. J. Williams, “Learning representations by back-propagating errors”, *Nature*, vol. 323, pp. 533–536, 1986.
- [Saed19] Ramin Saedi and Navid Khademi, “Travel time cognition: Exploring the impacts of travel information provision strategies”, *Travel Behaviour and Society*, vol. 14, pp. 92 – 106, 2019.
- [Salm17] Issam Salman and Jiří Vomlel, “A machine learning method for incomplete and imbalanced medical data”, 09 2017.
- [Shar18] Abida Sharif, Jianping Li, Mudassir Khalil, Rajesh Kumar, Muhammad Sharif and Atiqa Sharif, “Internet of things – smart traffic management system for smart cities using big data analytics”, 11 2018.
- [Sing19] Vedant Singh, Vyom Unadkat and Pratik Kanani, “Intelligent Traffic Management System”, pp. 2277–3878, 09 2019.

- [Smit89] A.W. Smith and D. Zipser, “Learning sequential structures with the real-time recurrent learning algorithm”, *International Journal of Neural Systems*, vol. 1, pp. 125–131, 01 1989.
- [Somm94] Edgar Sommer, Katharina Morik, Jean-Michel André and Marc Uszynski, “What online machine learning can do for knowledge acquisition—a case study”, *Knowledge Acquisition*, vol. 6, no. 4, pp. 435 – 460, 1994.
- [Suts14] Ilya Sutskever, Oriol Vinyals and Quoc V Le, “Sequence to Sequence Learning with Neural Networks”, in Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence and K. Q. Weinberger, editors, *Advances in Neural Information Processing Systems 27*, pp. 3104–3112, Curran Associates, Inc., 2014.
- [Tan18] Chuanqi Tan, Fuchun Sun, Tao Kong, Wenchang Zhang, Chao Yang and Chunfang Liu, “A Survey on Deep Transfer Learning”, 2018.
- [VanR09] Guido Van Rossum and Fred L. Drake, *Python 3 Reference Manual*, CreateSpace, Scotts Valley, CA, 2009.
- [Wang20] Jing Wang, Jiahong Chen, Jianzhe Lin, Leonid Sigal and Clarence W. de Silva, “Discriminative Feature Alignment: Improving Transferability of Unsupervised Domain Adaptation by Gaussian-guided Latent Alignment”, 2020.
- [Weis18] Gail Weiss, Yoav Goldberg and Eran Yahav, “On the Practical Computational Power of Finite Precision RNNs for Language Recognition”, 2018.
- [Werb74] Paul Werbos and Paul John, “Beyond regression : new tools for prediction and analysis in the behavioral sciences /”, 01 1974.
- [Werb90] P. J. Werbos, “Backpropagation through time: what it does and how to do it”, *Proceedings of the IEEE*, vol. 78, no. 10, pp. 1550–1560, 1990.
- [Wu18] Yuankai Wu, Huachun Tan, Lingqiao Qin, Bin Ran and Zhuxi Jiang, “A hybrid deep learning based traffic flow prediction method and its understanding”, *Transportation Research Part C: Emerging Technologies*, vol. 90, pp. 166 – 180, 2018.



## Παράρτημα Α

### Ευρετήριο Όρων και Συντμήσεων

#### A.1 Ελληνικοί όροι

**ΕΝΔ:** Επαναληπτικά Νευρωνικά Δίκτυα  
**ΜΔΥ:** Μηχανές Διανυσμάτων Υποστήριξης  
**ΤΝΔ:** Τεχνητά Νευρωνικά Δίκτυα  
**ΤΝ:** Τεχνητή Νοημοσύνη

#### A.2 Αγγλικοί όροι

**AI:** Artificial Intelligence  
**ANN:** Artificial Neural Network  
**AN:** Artificial Neuron  
**BP:** Back Propagation  
**BPTT:** Back Propagation Through Time  
**GRU:** Gated Recurrent Unit  
**LSTM:** Long Short-Term Memory  
**ML:** Machine Learning  
**MSE:** Mean Squared Error  
**PCA:** Principal Component Analysis  
**RNN:** Recurrent Neural Network  
**ResNet:** Residual Neural Network  
**Seq2Seq:** Sequence To Sequence  
**SVM:** Support Vector Machine