



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΔΠΜΣ ΕΠΙΣΤΗΜΗ ΔΕΔΟΜΕΝΩΝ ΚΑΙ ΜΗΧΑΝΙΚΗ
ΜΑΘΗΣΗ

**Πρόβλεψη Τροχιάς Πεζών και Οχημάτων σε
Πολυσύχναστες Σκηνές με Μεθόδους Βαθιάς Μάθησης**

ΜΕΤΑΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

ΙΩΑΝΝΗΣ ΦΙΛΙΠΠΑΣ

Επιβλέπων : Κωνσταντίνος Καράντζαλος

Αν. Καθηγητής ΕΜΠ

Αθήνα, Νοέμβριος 2021



NATIONAL TECHNICAL UNIVERSITY OF ATHENS
MASTER PROGRAMME - DATA SCIENCE AND
MACHINE LEARNING

Human and Vehicle Trajectory Prediction in Crowded Scenes with Deep Learning

MASTER THESIS

IOANNIS FILIPPAS

Supervisor: Karantzalos Konstantinos
Associate Professor, NTUA

Athens, November 2021



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΔΠΜΣ ΕΠΙΣΤΗΜΗ ΔΕΔΟΜΕΝΩΝ ΚΑΙ ΜΗΧΑΝΙΚΗ
ΜΑΘΗΣΗ

Πρόβλεψη Τροχιάς Πεζών και Οχημάτων σε Πολυσύχναστες Σκηνές με Μεθόδους Βαθιάς Μάθησης

ΜΕΤΑΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

ΙΩΑΝΝΗΣ Θ. ΦΙΛΙΠΠΑΣ

Επιβλέπων : Κωνσταντίνος Καράντζαλος

Αν. Καθηγητής ΕΜΠ

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 1 Νοεμβρίου 2021.

.....

Κ. Καράντζαλος

Αν. Καθηγητής

Εθνικό Μετσόβιο Πολυτεχνείο

.....

Μ. Βακαλοπούλου

Επ. Καθηγήτρια

CentraleSupélec, University of
Paris-Saclay, Γαλλία

.....

Ι. Σπυροπούλου

Αν. Καθηγήτρια

Εθνικό Μετσόβιο Πολυτεχνείο

Αθήνα, Νοέμβριος 2021

ΙΩΑΝΝΗΣ Θ. ΦΙΛΙΠΠΑΣ

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

Copyright © Ιωάννης Φίλιππας, 2021.

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

Η ανάλυση δεδομένων μαζικής κίνησης είναι μια ερευνητική περιοχή μεγάλης έκτασης η οποία επανήλθε στο προσκήνιο με την ανάπτυξη των τεχνολογιών Μεγάλων Δεδομένων. Ένα από τα κρίσιμα θέματα αυτής της περιοχής είναι το πρόβλημα της πρόβλεψης της τροχιάς ενός κινούμενου οχήματος ή πεζού, που αφορά την πρόβλεψη της τοποθεσίας του οχήματος ή πεζού στο βραχυπρόθεσμο μέλλον, εντός των ορίων μιας προκαθορισμένης περιοχής και περιλαμβάνει αρκετές προκλήσεις εξ αιτίας της στοχαστικότητας της κίνησης. Μερικές από τις εφαρμογές που μπορούν να επωφεληθούν μιας αποτελεσματικής μεθοδολογίας για τη μοντελοποίηση αυτού του προβλήματος περιλαμβάνουν τη βελτιστοποίηση ή εκτίμηση κίνησης σε ένα οδικό δίκτυο, τα αυτό-οδηγούμενα αυτοκίνητα και τη βελτιστοποίηση δικτύων τηλεφωνίας, μεταξύ άλλων. Οι παραδοσιακές προσεγγίσεις πρόβλεψης φαίνεται να μην μπορούν να ανταποκριθούν ικανοποιητικά στα προβλήματα αυτά λόγω της μη – γραμμικότητας των τροχιών και πορειών. Έτσι την τελευταία δεκαετία έχουν δοκιμαστεί με επιτυχία μοντέλα βαθιάς μάθησης, που όμως απαιτούν τεράστιους υπολογιστικούς πόρους για να έχουν την επιθυμητή επίδοση. Δύο από αυτά, το Social GAN και το Trajectory Transformer παρουσιάζονται, υλοποιούνται και αξιολογούνται στο πλαίσιο της παρούσας εργασίας. Παράλληλα, παρουσιάζεται ένα αναδρομικό νευρωνικό δίκτυο, ενισχυμένο με τον μηχανισμό προσοχής (Attention), με σκοπό να προσφέρει μια εναλλακτική, χαμηλού κόστους προσέγγιση για την αντιμετώπιση του προβλήματος της πρόβλεψης τροχιάς. Τα πειραματικά αποτελέσματα δείχνουν ότι η προτεινόμενη μεθοδολογία πετυχαίνει ανταγωνιστικά αποτελέσματα σε ένα ανοικτά διαθέσιμο σύνολο δεδομένων που περιλαμβάνει πορείες πεζών, ενώ βελτιώνει κατά 29% το Μέσο Σφάλμα Μετατόπισης (Mean Displacement Error) σε ένα σύνολο δεδομένων προσομοίωσης μαζικής κίνησης σε αστικό περιβάλλον που δημιουργήθηκε για τις ανάγκες της εργασίας και περιλαμβάνει οχήματα εκτός από πεζούς.

Λέξεις κλειδιά

Πρόβλεψη τροχιάς, Πολυσύχναστες Σκηνές, Βαθιά Μάθηση, Προβλήματα Χρονοσειράς σε Χρονοσειρά, Social GAN, Transformer, GRU with Attention.

Abstract

Mass Movement data analysis is a wide researching field which returned to the forefront with the advancement of Big Data. One of the most critical tasks of the field is the problem of trajectory prediction of a pedestrian or vehicle in motion, which involves the projection of the location of the pedestrian or vehicle in short term future, inside the boundaries of a predefined area and includes many challenges related to stochasticity of motion. Some of the applications that can benefit from an effective methodology for the modelling of this task include traffic estimation and optimization, self-driving cars and mobile network optimization among others. Traditional predictive approaches seem to fail to respond satisfactorily to the task due to non-linearities of the trajectories. Thus, in the last decade, deep neural architectures have been tested to the problem, but they require huge computational resources to have the desired performance. Two of them, Social-GAN and Trajectory Transformer, will be presented, implemented and evaluated in the context of this work. At the same time, a recurrent neural network enhanced with Attention mechanism will be presented, to offer a low-cost alternative approach to the problem of trajectory prediction. Experimental results indicate that the proposed methodology achieves competitive results in a publicly available pedestrian dataset, while reducing Mean Displacement Error by 29% in a mixed pedestrian and vehicle urban movement dataset that was created for the purposes of this thesis.

Keywords

Trajectory Prediction, Crowded Scenes, Deep Learning, Sequence to Sequence Learning, Social GAN, Transformer, GRU with Attention

Ευχαριστίες

Καταρχάς, θα ήθελα να ευχαριστήσω θερμά τον επιβλέποντα καθηγητή αυτής της εργασίας, κ. Κωνσταντίνο Καράντζαλο, για την ευκαιρία που μου έδωσε να καταπιαστώ με το συγκεκριμένο ερευνητικό αντικείμενο καθώς και για τη συνεχή καθοδήγηση που μου παρείχε στο διάστημα της εκπόνησής της.

Οφείλω επίσης να ευχαριστήσω την εταιρεία Intelligent για την παροχή των απαραίτητων πόρων για την κατασκευή του συνόλου δεδομένων κίνησης, χωρίς το οποίο η εργασία αυτή δε θα μπορούσε να πραγματοποιηθεί.

Ιδιαίτερες ευχαριστίες πρέπει να απευθύνω στο συνάδελφο και αδελφικό μου φίλο Αλκιβιάδη Μάριο Κούκο, για τη διαρκή συνδρομή του καθόλη τη διάρκεια των μεταπτυχιακών μου σπουδών, αλλά και στη σύντροφό μου Άννα, για την απέραντη στήριξη και υπομονή.

Τέλος, ευχαριστώ από καρδιάς την οικογένειά μου, που μου προσέφερε όλα τα απαραίτητα εφόδια για να αξιοποιήσω τις δυνατότητές μου στο έπακρο, από την αρχή της ζωής μου έως σήμερα.

Περιεχόμενα

Κεφάλαιο 1	Εισαγωγή.....	9
1.1	Σύνολα Δεδομένων Μαζικής Κίνησης	9
1.2	Το πρόβλημα της πρόβλεψης πορείας τροχιάς ως πρόβλημα χρονοσειράς σε χρονοσειρά.....	10
1.3	Σκοπός της εργασίας.....	10
Κεφάλαιο 2	Μηχανική Μάθηση	12
2.1	Παλινδρόμηση (Regression).....	12
2.2	Αναδρομικά Νευρωνικά Δίκτυα	12
2.3	Η αρχιτεκτονική Κωδικοποιητή Αποκωδικοποιητή	17
2.4	Γεννητικά μοντέλα (GANS).....	18
2.5	Ο μηχανισμός Προσοχής (Attention Mechanism).....	19
Κεφάλαιο 3	Μεθοδολογία	20
3.1	Μοντέλα Βαθιάς Μάθησης.....	20
3.2	Σύνολα Δεδομένων	26
3.3	Μετρικές Αξιολόγησης και Πειραματική Διαδικασία.....	29
Κεφάλαιο 4	Αποτελέσματα.....	31
4.1	Ποσοτική αξιολόγηση με βάση τις μετρικές.....	31
4.2	Σύγκριση επικρατέστερων αρχιτεκτονικών στα διαφορετικά σενάρια	34
4.3	Διδιάστατη απεικόνιση αποτελεσμάτων	37
4.4	Ανάλυση αποτελεσμάτων GRU.....	44
4.5	Υπολογιστική πολυπλοκότητα	50
Κεφάλαιο 5	Συμπεράσματα.....	51

Κεφάλαιο 1 Εισαγωγή

Η κατανόηση και μοντελοποίηση της πορείας οχημάτων και της ανθρώπινης κίνησης είναι ένα πεδίο όπου μπορούν να βρουν εφαρμογή πολλές νέες τεχνολογίες και έξυπνα συστήματα. Η πρόβλεψη της πορείας είναι ένα από τα κεντρικά προβλήματα σε αυτό το πεδίο, καθώς επιτρέπει την πρόγνωση της εξέλιξης της κινητικότητας σε μία σκηνή όπου συνυπάρχουν πολλαπλοί πράκτορες κίνησης. Η επιτυχημένη μοντελοποίηση και πρόβλεψη της κίνησης μπορεί να τροφοδοτήσει πληθώρα εφαρμογών, όπως συστήματα πλοήγησης σε αυτό-οδηγούμενα αυτοκίνητα, συστήματα βελτιστοποίησης χαρτών και εκτίμησης κίνησης και συστήματα βελτιστοποίησης δικτύων τηλεπικοινωνιών, μεταξύ άλλων. Η μεγάλη πρόκληση σε αυτό το πρόβλημα προκύπτει από την πολυπλοκότητα της ανθρώπινης κίνησης και την ποικιλία των παραγόντων που την επηρεάζουν. Η αυξημένη πολυπλοκότητα καθώς και η δημιουργία, πολλών συνόλων δεδομένων μαζικής κίνησης, έχουν οδηγήσει τα τελευταία χρόνια στην ανάπτυξη ποικίλων μοντέλων οδηγούμενων από δεδομένα, για την αντιμετώπιση του προβλήματος, με αξιοσημείωτα αποτελέσματα.

1.1 Σύνολα Δεδομένων Μαζικής Κίνησης

Τα Σύνολα δεδομένων μαζικής κίνησης αποτελούν συλλογές γεωγραφικών δεδομένων που αναπαριστούν τις πορείες κίνησης πολλών διαφορετικών οντοτήτων. Οι οντότητες μπορεί να περιλαμβάνουν πεζούς και οχήματα διαφορετικού μεγέθους. Στο εξής οι οντότητες παρατήρησης θα αναφέρονται ως πράκτορες (agents) και το περιβάλλον παρατήρησης θα αναφέρεται ως σκηνή (scene). Ο όρος μαζική κίνηση αναφέρεται στην παρατήρηση της τροχιάς πολλαπλών και, πολύ συχνά, όλων των πρακτόρων που κινούνται στην ίδια σκηνή.

Ο τρόπος συλλογής των δεδομένων κίνησης καθορίζει και τη μορφή τους. Η συλλογή μπορεί να γίνει με κάμερες μέσα από τη σκηνή ή από εναέρια μέσα (drones), που καταγράφουν τους πράκτορες τη σκηνής και την κίνησή τους. Σε δεύτερο στάδιο, το οπτικό υλικό περνάει από διαδικασίες αναγνώρισης (object detection), και επισήμανσης των αντικειμένων και των πρακτόρων που βρίσκονται στη σκηνή. Στη συνέχεια, το οπτικό υλικό μπορεί να χρησιμοποιηθεί ως έχει, δηλαδή σε μορφή εικόνας ή βίντεο, ή να εξαχθούν μόνο τα δεδομένα που απαιτούνται για να σχηματιστούν τα διάφορα μονοπάτια των πρακτόρων. Εναλλακτικά, τα δεδομένα μπορούν να ανακτηθούν απευθείας από κινητές συσκευές που διαθέτουν πρόσβαση σε GPS αλλά και άλλου τύπου αισθητήρες (Wi-Fi, RFID κλπ.), όπως είναι τα σύγχρονα τηλέφωνα. Σε αυτή την περίπτωση, η εξαγωγή των μονοπατιών είναι πιο άμεση, καθώς τα χαρακτηριστικά που μας ενδιαφέρουν (αναγνωριστικό πράκτορα, χρονικό βήμα, γεωγραφικές συντεταγμένες) περιέχονται σχεδόν αυτούσια στα μετα-δεδομένα των υπηρεσιών. Για την ολοκλήρωση της διαδικασίας και την τελική μορφή ενός συνόλου μαζικής κίνησης, απαιτείται ένα στάδιο ανωνυμοποίησης, για την προστασία της των προσωπικών δεδομένων των χρηστών – πρακτόρων.

Σε κάθε περίπτωση, τα σύνολα δεδομένων μαζικής κίνησης αποτελούν ένα απαραίτητο εργαλείο για ερευνητές διαφόρων επιστημονικών πεδίων με κλασικότερο παράδειγμα τη συγκοινωνιολογία ενώ χρησιμοποιούνται ευρέως σε πολλές εμπορικές εφαρμογές, όπως για παράδειγμα στη βελτιστοποίηση δικτύων δεδομένων κινητής τηλεφωνίας, και όχι μόνο. Πρόσφατα, μεγάλη ερευνητική δραστηριότητα στον τομέα επικεντρώθηκε στην πρόβλεψη κυκλοφορίας πεζών για την αποφυγή συνωστισμών, λόγω των μέτρων πρόληψης από τον ιό Covid 19.

1.2 Το πρόβλημα της πρόβλεψης πορείας τροχιάς ως πρόβλημα χρονοσειράς σε χρονοσειρά

Για τις ανάγκες της εργασίας, θα χρησιμοποιήσουμε την αναπαράσταση της τροχιάς ενός πράκτορα ως χρονοσειρά. Για να είμαστε σε θέση να περιγράψουμε πλήρως αυτή την τροχιά, χρειαζόμαστε τρία στοιχεία :

- Ένα μοναδικό χαρακτηριστικό για τον πράκτορα
- Ένα χρονικό βήμα
- Τις συντεταγμένες για κάθε χρονικό βήμα

Ένα μονοπάτι, λοιπόν, δηλαδή η πορεία ενός πράκτορα μέσα στη σκηνή ενδιαφέροντος για το χρονικό διάστημα ενδιαφέροντος μπορεί να γραφεί ως $\vec{X} = ((x_1, y_1), \dots, (x_N, y_N))$, όπου το χρονικό βήμα τρέχει από 1 έως N, δηλαδή το χρονικό διάστημα ενδιαφέροντος. Για την καλύτερη και πιο εύκολη αντιμετώπιση των δεδομένων κίνησης, ζητάμε το χρονικό βήμα να είναι σταθερό για όλα τα μονοπάτια. Εάν αυτό δεν είναι εφικτό, μπορούμε να χρησιμοποιήσουμε μεθόδους παρεμβολής, για να δουλέψουμε με μονοπάτια σταθερού χρονικού βήματος.

Ένα μονοπάτι ορίζεται ως το διακριτό ίχνος που διαγράφει ένας πράκτορας καθώς κινείται μέσα σε μια σκηνή. Βασικός σκοπός στο πρόβλημα πρόβλεψης πορείας τροχιάς είναι, δοθέντος αυτού του μονοπατιού, η πρόβλεψη της βραχυπρόθεσμης μελλοντικής πορείας του πράκτορα με όσο δυνατόν μεγαλύτερη ακρίβεια. Πιο απλά, δεδομένων των τελευταίων βημάτων ενός μονοπατιού, σκοπός είναι η πρόβλεψη των επόμενων. Η μαθηματική περιγραφή του προβλήματος μπορεί να γραφεί ως εξής:

Έστω X_t^i το διάνυσμα συντεταγμένων του χρήστη i τη στιγμή παρατήρησης t , με $t \in \{1, 2, \dots, T_{obs}\}$, όπου T_{obs} είναι το τρέχον χρονικό βήμα στη σειρά των παρατηρήσεων. Το δεδομένο (παρελθοντικό) μονοπάτι για τον πράκτορα i είναι η χρονοσειρά $X^i = \{X_1^i, X_2^i, \dots, X_{T_{obs}}^i\}$. Δεδομένων όλων των παρελθοντικών μονοπατιών όλων των πρακτόρων στη σκηνή, ζητείται η πρόβλεψη των μελλοντικών (βραχυπρόθεσμων) μονοπατιών όλων των πρακτόρων, $\hat{Y}^i = \{\hat{Y}_{T_{obs}+1}^i, \hat{Y}_{T_{obs}+2}^i, \dots, \hat{Y}_{T_{pred}}^i\}$.

1.3 Σκοπός της εργασίας

Στην παρούσα εργασία θα χρησιμοποιηθούν δεδομένα μαζικής κίνησης για την εκπαίδευση μοντέλων βαθιάς μάθησης (deep learning), με σκοπό την βραχυπρόθεσμη πρόβλεψη της πορείας – τροχιάς όλων των πρακτόρων που κινούνται σε μια σκηνή. Θα χρησιμοποιηθούν δύο γνωστές από τη βιβλιογραφία αρχιτεκτονικές, οι οποίες θα υλοποιηθούν και θα εκπαιδευτούν σε ένα ανοιχτά διαθέσιμο σύνολο κίνησης πεζών, καθώς και σε ένα σύνολο δεδομένων προσομοίωσης κίνησης πεζών και οχημάτων. Παράλληλα, θα παρουσιαστεί μια προτεινόμενη αρχιτεκτονική, εμπνευσμένη από τα δύο προαναφερθέντα μοντέλα, η οποία μειώνει σημαντικά την πολυπλοκότητα της υλοποίησης, με πολύ λιγότερες απαιτήσεις σε μνήμη και υπολογιστικούς πόρους για τη διαδικασία της εκπαίδευσης αλλά και της πρόβλεψης. Βασικός σκοπός της εργασίας είναι να διαπιστωθεί, εάν είναι δυνατό να επιτευχθεί επίδοση συγκρίσιμη, ή και καλύτερη, με το υπολογιστικό κέρδος της προτεινόμενης αρχιτεκτονικής. Παράλληλα, η εργασία φιλοδοξεί να προσφέρει ορισμένα

ερευνητικά συμπεράσματα που αφορούν τη γενικότερη μοντελοποίηση του προβλήματος και τους κρίσιμους παράγοντες για την επιτυχή πρόβλεψη της πορείας τροχιάς πεζών και οχημάτων.

Κεφάλαιο 2 Μηχανική Μάθηση

Σε αυτό το κεφάλαιο θα εξεταστεί η βασική θεωρία που απαιτείται για να περιγραφούν οι τεχνικές της Μηχανικής Μάθησης που θα χρησιμοποιηθούν παρακάτω για την αντιμετώπιση του προβλήματος της πρόβλεψης πορείας τροχιάς.

2.1 Παλινδρόμηση (Regression)


Η βασική προσέγγιση είναι να αντιμετωπιστεί το φαινόμενο ως ένα πρόβλημα παλινδρόμησης. Ως πρόβλημα παλινδρόμησης μπορεί να χαρακτηριστεί κάθε πρόβλημα στο οποίο εκτιμάται η σχέση μεταξύ μιας (ή περισσότερων) μεταβλητής εισόδου και μιας (ή περισσότερων) μεταβλητής εξόδου. Τεχνικές παλινδρόμησης χρησιμοποιούνται κατά κόρον όταν οι μεταβλητές εξόδου είναι πραγματικοί αριθμοί. Μερικές από τις κλασικότερες τεχνικές είναι η γραμμική παλινδρόμηση, η πολυωνυμική, η μπασειανή, η παλινδρόμηση κατά Lasso και άλλες. Πολλές από αυτές είχαν δοκιμαστεί και στο πρόβλημα της πρόβλεψης πορείας τροχιάς, με σημαντική επιτυχία για τα τότε ερευνητικά δεδομένα. Η μη γραμμικότητα όμως των μονοπατιών δεν επέτρεπε σε αυτές τις μεθόδους να είναι εξαιρετικά αποτελεσματικές, με αποτέλεσμα να αναζητηθούν λύσεις από το χώρο της βαθιάς μάθησης [1].

Τα τελευταία χρόνια, η ραγδαία ανάπτυξη στο χώρο της μηχανικής μάθησης και πιο συγκεκριμένα της βαθιάς μάθησης, έχει προσφέρει πολύ αποτελεσματικές λύσεις σε διάφορα προβλήματα παλινδρόμησης. Ειδικά σε προβλήματα που τα δεδομένα εισόδου/εξόδου έχουν τη μορφή χρονοσειράς, όπως στην πρόβλεψη μονοπατιού, δύο είναι οι κύριες αρχιτεκτονικές που έχουν κυριαρχήσει στη βιβλιογραφία την τελευταία δεκαετία: α) τα αναδρομικά νευρωνικά δίκτυα (recurrent networks) β) τα νευρωνικά δίκτυα προσοχής (attention based networks) καθώς και αρχιτεκτονικές που συνδυάζουν αυτά τα δύο δομικά στοιχεία. Παρακάτω παρουσιάζονται αυτές οι αρχιτεκτονικές ώστε να γίνει κατανοητό γιατί είναι κατάλληλες για προβλήματα πρόβλεψης χρονοσειρών. Μια πιο εμπειριστατωμένη μελέτη γύρω από τη σχετική βιβλιογραφία μπορεί να βρεθεί εδώ [3].

2.2 Αναδρομικά Νευρωνικά Δίκτυα

Τα αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Networks - RNN) είναι μια ειδική υπό – κατηγορία νευρωνικών δικτύων, που αποτελούν την κατεξοχήν αρχιτεκτονική για προβλήματα στα οποία τα δεδομένα εισόδου είναι σειριακής (sequential) μορφής, ή δεδομένα τα οποία έχουν την παράμετρο του χρόνου ως μια διάσταση, όπως είναι οι χρονοσειρές [2]. Η βασική τους διαφορά με τα παραδοσιακά, εμπρόσθιας τροφοδότησης (feed-forward) δίκτυα, είναι ότι στα τελευταία, όπως μαρτυρά και η ονομασία τους, η διάδοση της πληροφορίας γίνεται μόνο προς μία κατεύθυνση, από το επίπεδο εισόδου στο επίπεδο εξόδου. Αντίθετα, τα αναδρομικά δίκτυα περιέχουν βρόχους (loops), όπου η έξοδος

ενός νευρώνα επιστρέφει ως είσοδος για το επόμενο χρονικό βήμα, όπως φαίνεται στην εικόνα 2.1.



Εικόνα 2.1 Σχηματική αναπαράσταση του νευρώνα ενός αναδρομικού δικτύου

Γίνεται εύκολα αντιληπτός ο λόγος που τα αναδρομικά δίκτυα είναι συνυφασμένα με δεδομένα σειριακής φύσης. Μαζί με το στιγμιότυπο εισόδου για τη στιγμή t , έστω x_t ο νευρώνας δέχεται ως είσοδο και την h_{t-1} , δηλαδή την έξοδό του για τη στιγμή $t-1$. Έτσι, οι αναδρομικοί νευρώνες διατηρούν ένα είδος μνήμης για τις προηγούμενες εισόδους. Αποτελούν λοιπόν μια φυσιολογική αρχιτεκτονική όταν εργαζόμαστε με δεδομένα που έχουν χρονική διάσταση.


Το γεγονός αυτό τα έκανε ιδιαίτερα δημοφιλή τα τελευταία χρόνια, σε προβλήματα όπως είναι η αναγνώριση ήχου, ενώ κυριάρχησαν και στην επεξεργασία φυσικής γλώσσας, στη μοντελοποίηση κειμένου και τη μετάφραση κειμένου. Μεγάλο κομμάτι της επιτυχίας των αναδρομικών αρχιτεκτονικών οφείλεται σε μια συγκεκριμένη παραλλαγή τους, τα λεγόμενα δίκτυα Μακροχρόνιας Βραχυπρόθεσμης Μνήμης (Long Short Term Memory networks - LSTM).

2.2.1. Long Short - Term Memory (LSTM)

Τα LSTM κατάφεραν σε μεγάλο βαθμό να λύσουν ένα σημαντικό πρόβλημα που αντιμετώπιζαν οι αναδρομικές αρχιτεκτονικές, το οποίο είχε να κάνει με τις μακροπρόθεσμες εξαρτήσεις μεταξύ των όρων μιας ακολουθίας. Όταν η έξοδος του δικτύου εξαρτάται σε μεγάλο βαθμό από τους τελευταίους, πιο πρόσφατους όρους της χρονοσειράς, οι κλασσικές αναδρομικές αρχιτεκτονικές ήταν σε θέση να συλλάβουν αυτό το συσχετισμό και να δώσουν την επιθυμητή έξοδο. Συχνά όμως, υπάρχει σημαντική εξάρτηση της εξόδου και από πιο

μακρινούς στο χρόνο όρους της χρονοσειράς. Σε αυτές τις περιπτώσεις, η απαραίτητη πληροφορία χάνεται με το πέρασμα των επαναλήψεων.

Τα LSTM δίκτυα, που προτάθηκαν το 1996 [4], είναι ακριβώς σχεδιασμένα ώστε να είναι ανθεκτικά σε τέτοιου είδους μακροχρόνιες εξαρτήσεις ανάμεσα στα δεδομένα εισόδου και να διατηρούν τις πληροφορίες που εξάγουν από τα δεδομένα για μεγάλα χρονικά διαστήματα. Θα εξηγηθεί αναλυτικά στη συνέχεια, πώς η πιο εκλεπτυσμένη αρχιτεκτονική τους, επιτρέπει κάτι τέτοιο. Στην εικόνα 2.2 φαίνεται η πορεία των δεδομένων εντός ενός αναδρομικού νευρώνα, ο οποίος στο επόμενο χρονικό βήμα τροφοδοτεί τον εαυτό του με την προηγούμενη έξοδο (για λόγους σαφήνειας στην εικόνα η αναδρομή παρουσιάζεται «ξεδιπλωμένη»).



Εικόνα 2.2 Η αναδρομική μονάδα ενός απλού RNN

Βλέπουμε πως στην περίπτωση των απλών αναδρομικών αρχιτεκτονικών, η επαναλαμβανόμενη μονάδα έχει μια πολύ απλή δομή, όπως ένα απλό επίπεδο με ενεργοποίηση τη συνάρτηση της εφαπτομένης (tanh activation function). Με αυτό τον τρόπο συνδυάζονται η παρούσα είσοδος με την προηγούμενη έξοδο του επιπέδου.


Στην εικόνα 2.3 φαίνεται η ίδια διαδικασία για το νευρώνα ενός LSTM δικτύου. Εδώ η δομή είναι σαφώς πιο πολύπλοκη, κάτι που εξασφαλίζει τη δυνατότητα καλύτερης «μνήμης» για μακροπρόθεσμες εξαρτήσεις. Εδώ η είσοδος περνάει από τέσσερις διαφορετικές ενεργοποιήσεις αντί για μία. Στο παρακάτω σχήμα, οι κύκλοι με χρώμα ροζ αντιπροσωπεύουν πράξεις σημείου προς σημείο ανάμεσα στα διανύσματα, όπως πρόσθεση διανυσμάτων, ενώ τα ορθογώνια με κίτρινο χρώμα αντιπροσωπεύουν διαφορετικά νευρωνικά επίπεδα με παραμέτρους προς εκπαίδευση. Τα βέλη μαύρου χρώματος που συναντιούνται αντιπροσωπεύουν συνένωση (concatenation), ενώ αυτά που διαχωρίζονται αντιπροσωπεύουν αντιγραφή ενός διανύσματος, ώστε τα δύο αντίγραφα να προχωρήσουν προς άλλη κατεύθυνση.

Η βασική ιδέα πίσω από τους νευρώνες LSTM, είναι κατάσταση **πυρήνα** (cell state), δηλαδή η οριζόντια γραμμή στο πάνω μέρος του νευρώνα. Η πληροφορία μπορεί να διατρέχει όλον τον πυρήνα, από την είσοδο στην έξοδο του νευρώνα, χωρίς καμία διάδραση με άλλα στοιχεία. Όμως τα LSTM έχουν τη δυνατότητα να προσθέτουν ή να αφαιρούν πληροφορία

στον πυρήνα, μέσα από δομές που ονομάζονται **πύλες** (gates). Οι πύλες αποτελούνται από ένα επίπεδο με σιγμοειδή ενεργοποίηση, που ακολουθείται από μια εσωτερική πράξη. Η σιγμοειδής ενεργοποίηση εξάγει έναν αριθμό μεταξύ μηδέν και ένα, που καθορίζει πόση πληροφορία θα «περάσει» στον πυρήνα: μηδέν σημαίνει ότι δε θα περάσει τίποτα, ένα σημαίνει ότι θα περάσει ολόκληρη. Υπάρχουν τρεις διαφορετικές τέτοιες πύλες σε ένα LSTM νευρώνα για τον έλεγχο της λειτουργίας του πυρήνα.

Το πρώτο βήμα είναι να αποφασιστεί τι πληροφορίες θα διαγραφούν από την προηγούμενη κατάσταση. Αυτό γίνεται με ένα επίπεδο με σιγμοειδή ενεργοποίηση που ονομάζεται **forget state** (το πρώτο βέλος στο εσωτερικό του νευρώνα, Εικόνα 2.3). Η μαθηματική περιγραφή αυτής τα κατάστασης είναι :

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f)$$



Εικόνα 2.3 Η αναδρομική μονάδα ενός LSTM

Στο επόμενο βήμα, αποφασίζεται ποιες νέες πληροφορίες θα αποθηκευτούν στον πυρήνα. Αυτό γίνεται σε δύο στάδια, πρώτα με ένα επίπεδο σιγμοειδούς ενεργοποίησης που ονομάζεται **πύλη εισόδου** και στη συνέχεια με ένα επίπεδο με **tanh** ενεργοποίηση που δημιουργεί ένα διάνυσμα με υποψήφιας τιμές \tilde{C}_t . Μαθηματικά:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C)$$

Πλέον μπορεί να γίνει η ανανέωση της προηγούμενης κατάστασης του πυρήνα, C_{t-1} , στη νέα κατάσταση C_t , με τη βοήθεια των πυλών που περιγράψαμε παραπάνω. Πρώτα πολλαπλασιάζεται η παλιά κατάσταση, C_{t-1} , με την f_t , ώστε να «ξεχαστούν» οι πληροφορίες χρειάζεται. Έπειτα, προστίθεται σε αυτό το γινόμενο $i_t * \tilde{C}_t$. Η ποσότητα αυτή αντιπροσωπεύει τις νέες υποψήφιας τιμές, σταθμισμένο με το ποσοστό που καθορίστηκε νωρίτερα για την ανανέωση κάθε τιμής. Αυτό περιγράφεται από την εξίσωση:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$


Για την τελική έξοδο η κατάσταση πυρήνα περνάει από μια tanh ενεργοποίηση για την κανονικοποίηση της τιμής στο διάστημα (-1,1), πολλαπλασιασμένη με μια σιγμοειδή ενεργοποίηση που διατηρεί στην έξοδο τα κομμάτια της κατάστασης πυρήνα που είναι επιθυμητά. Μαθηματικά:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$

2.2.2. Gated Recurrent Unit (GRU)

Η λειτουργία των LSTM δικτύων περιεγράφηκε αναλυτικά στα προηγούμενα παραρτήματα, όμως υπάρχουν και ορισμένες παραλλαγές αναδρομικών αρχιτεκτονικών, που όμως φαίνεται να λειτουργούν εξίσου καλά σε προβλήματα χρονοσειρών. Σε αυτή την παράγραφο θα παρουσιαστεί μια από αυτές, καθώς αποτελεί σημαντικό κομμάτι της αρχιτεκτονικής που προτείνεται στο πλαίσιο αυτής της εργασίας. Η παραλλαγή ονομάζεται Μονάδα Αναδρομικής Πύλης (Gated Recurrent Unit – GRU), που έχει αποκτήσει ιδιαίτερη δημοφιλία τα τελευταία χρόνια, καθώς η πιο απλή δομή (Εικόνα 2.4) της την καθιστά μια πιο γρήγορη και αποδοτική σε θέμα μνήμης εναλλακτική των LSTM.



Εικόνα 2. 4 Η αναδρομική μονάδα ενός GRU

Σε ένα νευρώνα GRU, οι δύο πρώτες πύλες του LSTM, forget και input state, συνδυάζονται σε μία πύλη ανανέωσης, update gate. Αντίθετα με τα LSTM λοιπόν, τα GRU δε διαθέτουν μηχανισμό για να ελέγχουν το βαθμό κατά τον οποίο η προηγούμενη κατάσταση εκτίθεται κατά το νέο βήμα, αλλά εκθέτουν σε κάθε βήμα ολόκληρη την περασμένη κατάσταση. Πιο τυπικά:

$$z_t = \sigma(W_z[h_{t-1}, x_t])$$

$$r_t = \sigma(W_r[h_{t-1}, x_t])$$


$$\hat{h}_t = \tanh(W[r_t * h_{t-1}, x_t])$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \hat{h}_t$$

Όπου z_t είναι η πύλη ανανέωσης, r_t είναι η πύλη επαναφοράς, \hat{h}_t είναι η υποψήφια ενεργοποίηση, και h_t είναι η τελική ενεργοποίηση της εξόδου της μονάδας. Με αυτή την τεχνική, μειώνεται σημαντικά ο αριθμός των παραμέτρων προς εκπαίδευση στα δίκτυα GRU σε σχέση με τα LSTM, καθιστώντας τα έτσι λιγότερο ευαίσθητα στην υπερ - εκπαίδευση (overfitting), ενώ διατηρούν τη μνήμη που τους επιτρέπει να αναγνωρίζουν μακροπρόθεσμες συσχετίσεις [16].

2.3 Η αρχιτεκτονική Κωδικοποιητή Αποκωδικοποιητή

Η πιο συνηθισμένη αρχιτεκτονική για την κατασκευή μοντέλων Ακολουθίας σε Ακολουθία (Seq2Seq), δηλαδή μοντέλων που δέχονται ακολουθία ως είσοδο και δίνουν ακολουθία ως έξοδο είναι η αρχιτεκτονική Κωδικοποιητή – Αποκωδικοποιητή (Encoder - Decoder). Στην εικόνα 2.5 φαίνεται μια αρκετά αφαιρετική αναπαράσταση αυτής της αρχιτεκτονικής. Τόσο ο Κωδικοποιητής όσο και ο αποκωδικοποιητής αποτελούνται από αναδρομικά δίκτυα, συνήθως LSTM ή GRU [14].



Εικόνα 2.5 Η αρχιτεκτονική Κωδικοποιητή – Αποκωδικοποιητή

Ο Κωδικοποιητής διαβάζει την ακολουθία εισόδου, «συνοψίζει» αυτή την πληροφορία και την αποθηκεύει σε διανύσματα εσωτερικής κατάστασης (internal state vectors). Η έξοδος του

Κωδικοποιητή συνήθως δε χρησιμοποιείται περαιτέρω. Ο Αποκωδικοποιητής αποτελείται και αυτός από ένα αναδρομικό δίκτυο, του οποίου οι εσωτερικές καταστάσεις αρχικοποιούνται από την τελική εσωτερική κατάσταση του Κωδικοποιητή. Σκοπός είναι, κατά την εκπαίδευση, ο Αποκωδικοποιητής να μάθει να παράγει την επιθυμητή ακολουθία εξόδου, δεδομένης της εσωτερικής κατάστασης που διαβάζει από τον Κωδικοποιητή. Τα μοντέλα βαθιάς μάθησης που θα εξεταστούν στα επόμενα κεφάλαια, είναι όλα μοντέλα που έχουν τη δομή Κωδικοποιητή – Αποκωδικοποιητή, όμως κάθε μοντέλο υλοποιεί με διαφορετικό τρόπο αυτά τα επιμέρους δίκτυα.

2.4 Γεννητικά μοντέλα (GANS)

Γεννητικά ονομάζονται τα μοντέλα επιβλεπόμενης μάθησης που σκοπός τους είναι η δημιουργία δεδομένων, και ακολουθούν την κατανομή των δεδομένων που χρησιμοποιούνται κατά την εκπαίδευσή τους. Το 2014 προτάθηκε μια καινοτόμα αρχιτεκτονική νευρωνικών δικτύων που εκμεταλλεύονται την **ανταγωνιστική** μάθηση για την παραγωγή δεδομένων [17]. Τα μοντέλα αυτά ονομάζονται Γεννητικά Ανταγωνιστικά Δίκτυα και έχουν πετύχει αξιοθαύμαστα αποτελέσματα στη δημιουργία διάφορων τύπων δεδομένων, όπως μουσική, φωτογραφίες ανθρώπων, ζωγραφική και άλλα.

Ο όρος ανταγωνιστική μάθηση δηλώνει τον τρόπο με τον οποίο επιτυγχάνεται η εκπαίδευση αυτών των δικτύων. Στην πραγματικότητα πρόκειται για δύο διαφορετικά νευρωνικά δίκτυα που εκπαιδεύονται παράλληλα. Το πρώτο ονομάζεται Γεννήτορας (Generator) και παίρνοντας ως είσοδο θόρυβο, δίνει έξοδο με τη δομή και τις διαστάσεις των δεδομένων που θέλουμε να δημιουργήσουμε. Το δεύτερο δίκτυο, που ονομάζεται Διαχωριστής (Discriminator) δέχεται ως είσοδο δεδομένα είτε από το σύνολο εκπαίδευσης είτε που έχουν προκύψει από το Generator και τα διαχωρίζει, δηλαδή να ταξινομεί σε πραγματικά και τεχνητά. Η όλη διαδικασία αποτελεί ένα παίγνιο δύο αντιπάλων με αντικειμενική συνάρτηση:

$$\min_G \max_D V(G, D) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p(z)} \left[\log \left(1 - D(G(z)) \right) \right].$$

Είναι φανερό ότι η συνάρτηση σφάλματος του ενός δικτύου είναι άμεσα εξαρτημένη από τη συνάρτηση σφάλματος του άλλου, δηλαδή όσο μειώνεται το σφάλμα του Generator αυξάνεται το σφάλμα του Discriminator, και το αντίστροφο. Η διαδικασία σταματά όταν οι δύο συναρτήσεις συγκλίνουν σε κάποιο σημείο ισορροπίας, ιδανικά όταν ο Discriminator έχει σφάλμα 50%, δηλαδή δεν μπορεί να διαχωρίσει τα πραγματικά δεδομένα από αυτά που έχουν δημιουργηθεί από τον Generator, οπότε και η εκπαίδευση φτάνει στο τέλος της.

2.5 Ο μηχανισμός Προσοχής (Attention Mechanism)

Την τελευταία δεκαετία οι αναδρομικές αρχιτεκτονικές είχαν κυριαρχήσει σε όσα προβλήματα αφορούσαν ανάλυση κι επεξεργασία σειριακών δεδομένων, καθώς ήταν η μόνη αρχιτεκτονική στη βαθιά μάθηση που μπορούσε να λάβει υπόψη τη χρονική διάσταση των δεδομένων κατά την εκπαίδευση ή την πρόβλεψη. Αυτό άλλαξε όταν προτάθηκε ο μηχανισμός της προσοχής (attention mechanism) [18]. Ο μηχανισμός προσοχής σχεδιάστηκε ακριβώς για να λύσει το πρόβλημα της απώλειας πληροφορίας σε μεγάλες ακολουθίες, όπου οι μακροπρόθεσμες συσχετίσεις των όρων που βρίσκονται μακριά στην ακολουθία είναι πιθανό να χαθούν. Η βασική ιδέα του μηχανισμού της προσοχής, είναι κατά την εκπαίδευση, το μοντέλο να μάθει να ποσοτικοποιεί την αλληλεξάρτηση πρώτον, των στοιχείων του διανύσματος εισόδου με τα στοιχεία του διανύσματος εξόδου (general attention) και δεύτερον των στοιχείων του διανύσματος εισόδου μεταξύ τους (self-attention).

Μια συνάρτηση προσοχής μπορεί να περιγραφεί ως μια αντιστοίχιση ενός ερωτήματος (query) κι ενός συνόλου από ζεύγη κλειδιά – τιμών (key – value pairs) σε ένα αποτέλεσμα, όπου το ερώτημα, το κλειδί, η τιμή και το αποτέλεσμα είναι όλα διανύσματα. Το αποτέλεσμα υπολογίζεται ως το σταθμισμένο άθροισμα των τιμών, όπου τα βάρη κάθε τιμής υπολογίζονται από μια συνάρτηση συμβατότητας του ερωτήματος με το αντίστοιχο κλειδί. Υπάρχουν πολλοί τρόποι για να υπολογιστεί ο μηχανισμός Προσοχής. Ένας από τους πιο αποδοτικούς υπολογιστικά και αυτός που θα χρησιμοποιηθεί στο πλαίσιο αυτής της εργασίας, είναι μέσω του εσωτερικού γινομένου, που απαιτεί διανύσματα ίδιας διάστασης, έστω d . Έστω ότι τα στοιχεία των διανυσμάτων Ερωτήματος και Κλειδιού είναι τυχαίες μεταβλητές με μέση τιμή 0 και διακύμανση 1. Τότε το εσωτερικό γινόμενο μεταξύ των διανυσμάτων θα έχει μέση τιμή 0 και διακύμανση d . Για να εξασφαλιστεί ότι η διακύμανση του εσωτερικού γινομένου θα παραμείνει 1, η συνάρτηση Προσοχής σταθμισμένου εσωτερικού γινομένου υπολογίζεται ως εξής:

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

Στην πραγματικότητα, ο μηχανισμός προσοχής προσφέρει έναν εύκολο τρόπο να ποσοτικοποιηθεί η αλληλεξάρτηση μεταξύ των όρων μιας χρονοσειράς εισόδου και μιας χρονοσειράς εξόδου κατά τη φάση της εκπαίδευσης. Έτσι, ένα μοντέλο μπορεί να γνωρίζει σε ποιους όρους της ακολουθίας εισόδου πρέπει να δώσει μεγαλύτερη έμφαση (προσοχή - attention), ενώ κατασκευάζει την ακολουθία εξόδου κατά το στάδιο της πρόβλεψης. Επειδή η συνάρτηση συμβατότητας υπολογίζεται για κάθε ζεύγος όρων των ακολουθιών εισόδου – εξόδου, δεν υπάρχει πρόβλημα απώλειας πληροφορίας σε μεγάλες ακολουθίες, όπως στα αμιγώς αναδρομικά μοντέλα. Η τετραγωνική πολυπλοκότητα ως προς το μήκος της ακολουθίας εισόδου του μηχανισμού, αντισταθμίζεται από το γεγονός ότι οι υπολογισμοί μπορούν να παραλληλοποιηθούν πλήρως για κάθε ζεύγος τιμών, αφού είναι ανεξάρτητοι. Όλα αυτά συνετέλεσαν ώστε τα μοντέλα που αξιοποιούν μηχανισμούς προσοχής να κυριαρχήσουν σε προβλήματα επεξεργασίας εικόνας, φυσικής γλώσσας και γενικά πρόβλεψης χρονοσειρών.

Κεφάλαιο 3 Μεθοδολογία

Στο παρόν κεφάλαιο θα παρουσιαστεί η συνολική μεθοδολογία της εργασίας. Αρχικά θα αναλυθούν οι αρχιτεκτονικές σύγκρισης, Social GAN και Transformer καθώς και η προτεινόμενη αρχιτεκτονική GRU with Attention (GRU για συντομία στο εξής). Έπειτα θα περιγραφούν τα σύνολα δεδομένων επάνω στα οποία θα εκπαιδευτούν και θα αξιολογηθούν οι συγκρινόμενες αρχιτεκτονικές. Τέλος, θα αναλυθεί η πειραματική διαδικασία που θα ακολουθηθεί για την συγκριτική αξιολόγηση των μοντέλων.

3.1 Μοντέλα Βαθιάς Μάθησης

3.1.1 Social GAN

Από τις διάφορες εναλλακτικές προσεγγίσεις που έχουν προταθεί για το πρόβλημα της πρόβλεψης πορείας – τροχιάς, μια σημαντική κατηγορία είναι τα κοινωνικά ενήμερα (social aware) μοντέλα. Η ιδιαιτερότητα αυτών των μοντέλων είναι ότι προσπαθούν να μοντελοποιήσουν τις αλληλεπιδράσεις μεταξύ των πρακτόρων που κινούνται στην ίδια σκηνή. Μία από τις πρώτες προσπάθειες προς αυτή την κατεύθυνση έγινε το 1995 [5]. Έκτοτε πολλές αρχιτεκτονικές έχουν προταθεί, όπως η [6], που πρότεινε τον όρο «κοινωνική ευαισθησία» ως μια συνάρτηση ενέργειας για τη μοντελοποίηση των κοινωνικών αλληλεπιδράσεων. Στη συνέχεια, το μοντέλο Social LSTM [7], που μπορεί να θεωρηθεί ως άμεσος πρόγονος του Social GAN, εισήγαγε το μηχανισμό του Social Pooling, για τη μοντελοποίηση αυτών των αλληλεπιδράσεων μέσω των αποστάσεων όλων των πρακτόρων εντός συγκεκριμένης ακτίνας.

Το Social GAN [8] αποτελεί το πρώτο μοντέλο που προτάθηκε για το πρόβλημα της πρόβλεψης της πορείας πεζών που χρησιμοποιεί GAN αρχιτεκτονική. Παρακάτω θα αναλυθούν τα κυριότερα σημεία του.

Το δίκτυο του Generator είναι ένα μοντέλο Κωδικοποιητή - Αποκωδικοποιητή. Και τα δύο αυτά συστατικά του μοντέλου αποτελούνται από LSTM επίπεδα. Η καινοτομία του Social GAN είναι ότι οι εσωτερικές καταστάσεις του Κωδικοποιητή δεν αρχικοποιούνται αυτούσιες στον Αποκωδικοποιητή, αλλά περνάνε μέσα από μια μονάδα συγκέντρωσης (pooling module), μέσω της οποίας ποσοτικοποιείται η κοινωνική αλληλεπίδραση μεταξύ των πρακτόρων που κινούνται στη σκηνή. Έτσι ο Αποκωδικοποιητής, που είναι υπεύθυνος για τη δημιουργία μονοπατιών, έχει στη διάθεσή του πληροφορία που αφορά εκτός από τον ίδιο τον πράκτορα και το περιβάλλον στο οποίο κινείται, κάτι που του δίνει τη δυνατότητα να επιλέξει τη σωστή κατεύθυνση κίνησης.

Το δίκτυο του Discriminator αποτελείται από έναν και μόνο Κωδικοποιητή. Ο Discriminator δέχεται ως είσοδο τόσο το πραγματικό μονοπάτι όσο και την έξοδο του Generator και τα διαχωρίζει σε πραγματικά ή συνθετικά. Με αυτό τον τρόπο, ωθεί τον Generator να κατασκευάζει αληθοφανή και κοινωνικά αποδεκτά μονοπάτια, δηλαδή μονοπάτια που ταιριάζουν με το περιβάλλον της σκηνής, εξ ου και η ονομασία της αρχιτεκτονικής.

Ας δούμε τώρα αναλυτικότερα τα δομικά συστατικά της αρχιτεκτονικής. Αρχικά το διάνυσμα εισόδου περνάει από ένα στάδιο ενσωμάτωσης (embedding) με τη βοήθεια ενός μονό – επίπεδου MLP (Multi Layer Perceptron). Αυτό το βήμα είναι απαραίτητο ώστε όλα τα διανύσματα εισόδου να έχουν ίδιο και σταθερό μήκος. Τα ενσωματωμένα διανύσματα τροφοδοτούνται στην κατάσταση πυρήνα του Κωδικοποιητή τη στιγμή t εκκινώντας την ακόλουθη αναδρομή:

$$e^t_i = \phi(x^t_i, y^t_i; W_{ee})$$

$$h^t_{ei} = LSTM(h^{t-1}_{ei}, e^t_i; W_{encoder})$$

όπου $\phi(\cdot)$ είναι η συνάρτηση ενσωμάτωσης με συνάρτηση ενεργοποίησης τη ReLU (Rectified Linear Unit) και W_{ee} είναι τα βάρη για τη συνάρτηση ενσωμάτωσης. Τα βάρη $W_{encoder}$ είναι κοινά για όλους τους πράκτορες της σκηνής και βοηθούν στην ποσοτικοποίηση της κοινωνικής αλληλεπίδρασης των πρακτόρων.

Ο Αποκωδικοποιητής, που είναι υπεύθυνος για την κατασκευή των μονοπατιών, αρχικοποιείται με την κρυμμένη κατάσταση του Κωδικοποιητή ως εξής:

$$c^t_i = \gamma(P_i, h^t_{ei}; W_c)$$

$$h^t_{di} = [c^t_i, z]$$

όπου $\gamma(\cdot)$ είναι ένα MLP με ReLU ενεργοποίηση και W_c είναι τα βάρη της ενσωμάτωσης. Μετά την αρχικοποίηση του Αποκωδικοποιητή, οι προβλέψεις προκύπτουν ως εξής:

$$e^t_i = \phi(x^{t-1}_i, y^{t-1}_i; W_{ed})$$

$$P_i = PM(h^{t-1}_{d1}, \dots, h^{t-1}_{dn})$$

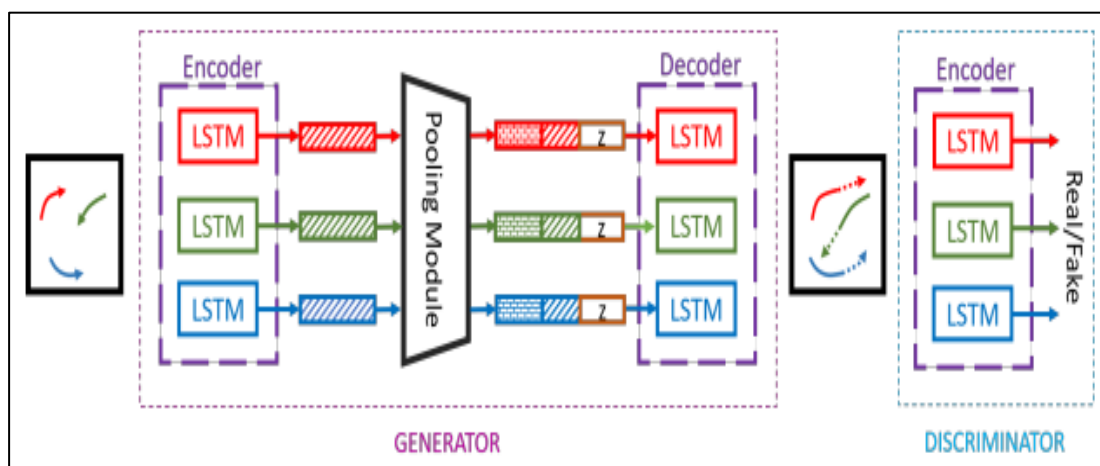
$$h^t_{di} = LSTM(\gamma(P_i, h^{t-1}_{di}), e^t_i; W_{decoder})$$

$$(\hat{x}^t, \hat{y}^t) = \gamma(h^t_{di})$$

Όπου $\phi(\cdot)$ είναι η συνάρτηση ενσωμάτωσης με ReLU ενεργοποίηση και W_{ed} τα βάρη της ενσωμάτωσης. Οι παράμετροι του LSTM αποκωδικοποιητή συμβολίζονται με $W_{decoder}$ και γ είναι ένα μονό – επίπεδο MLP.

Ο Discriminator αποτελείται από έναν LSTM Κωδικοποιητή, αντίστοιχο με αυτόν του Κωδικοποιητή, στον οποίο εφαρμόζεται ένα απλό επίπεδο εμπρόσθιας προώθησης (single layer perceptron) με συνάρτηση ενεργοποίησης Softmax. Κατά την εκπαίδευση του δικτύου ο Discriminator τιμωρεί τον Generator με μεγάλο σφάλμα, όταν τα μονοπάτια που κατασκευάζει δεν είναι αληθοφανή ή κοινωνικά αποδεκτά με βάση το περιβάλλον της σκηνής. Η συνάρτηση σφάλματος του Generator είναι η L2 νόρμα και του Discriminator η δυαδική διασταυρούμενη εντροπία (binary cross entropy).

Η μονάδα συγκέντρωσης είναι το βασικό συστατικό της αρχιτεκτονικής του Social GAN. Τα διανύσματα εισόδου επαυξάνονται με τη σχετική θέση όλων των υπόλοιπων πρακτόρων της σκηνης και δίνονται ως είσοδο στη μονάδα συγκέντρωσης, η οποία αποτελείται από ένα μονό – επίπεδο MLP που ακολουθείται από μια συμμετρική συνάρτηση Μέγιστης Συγκέντρωσης (Max Pooling). Με αυτό τον τρόπο, ενισχύονται οι διευθύνσεις κατά τις οποίες οι σχετικές αποστάσεις του πράκτορα προς εξέταση και των υπόλοιπων πρακτόρων αυξάνονται, με σκοπό να αποφεύγονται συγκρουόμενα μονοπάτια. Στην εικόνα 3.1 φαίνεται η συνολική αρχιτεκτονική του Social GAN.



Εικόνα 3. 1 Η αρχιτεκτονική του Social GAN

3.1.2 Το μοντέλο Transformer

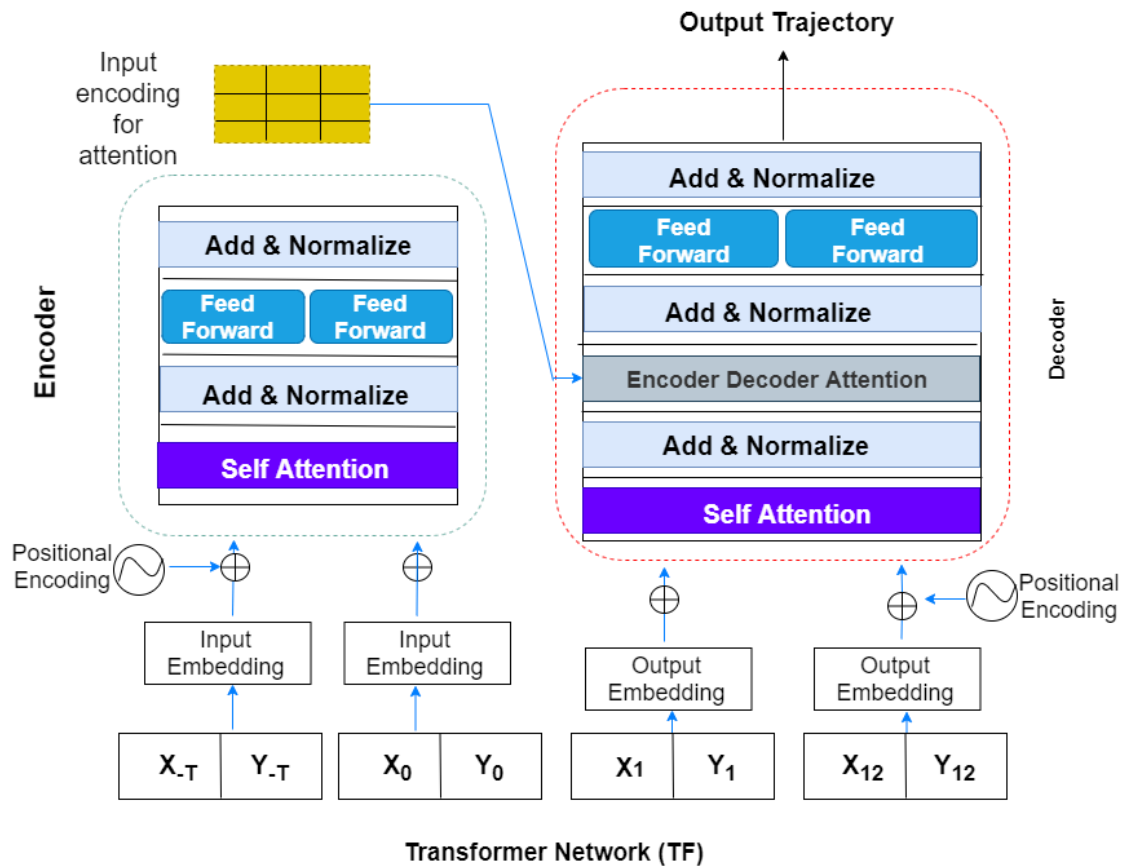
Στο κεφάλαιο 2 παρουσιάστηκαν τα αναδρομικά δίκτυα και ο μηχανισμός της Προσοχής, ο οποίος όπως αναφέρθηκε είναι πλήρως παραλληλοποιήσιμος. Για το λόγο αυτό, έχει χρησιμοποιηθεί εκτενώς στη βιβλιογραφία, αρχικά σε συνδυασμό είτε με αναδρομικά είτε με συνελκτικά επίπεδα, κυρίως για την είσοδο και έξοδο της αρχιτεκτονικής. Η καινοτομία που εισήγαγε το μοντέλο Transformer [9] έγκειται στο ότι βασίζεται σε μηχανισμούς Προσοχής ως δομικά μπλοκ, χωρίς να περιλαμβάνει καθόλου αναδρομικά ή άλλα στοιχεία. Αν και χρησιμοποιήθηκε αρχικά για προβλήματα Ακολουθίας σε Ακολουθία στον τομέα της αναγνώρισης φυσικής γλώσσας, στη συνέχεια η αρχιτεκτονική εφαρμόστηκε με επιτυχία σε προβλήματα που έχουν να κάνουν με εικόνα και ήχο [[10], [11]]. Το 2020 δοκιμάστηκε με επιτυχία και στο πρόβλημα με το οποίο καταπιάνεται αυτή η εργασία, στην πρόβλεψη της πορείας ενός πράκτορα κίνησης [12].

Όπως φαίνεται στην εικόνα 3.2, η αρχιτεκτονική του Transformer αποτελείται από έναν Κωδικοποιητή και έναν Αποκωδικοποιητή, όπως όλες οι αρχιτεκτονικές Ακολουθίας σε Ακολουθία, που όμως διαθέτει ορισμένα παραπάνω στοιχεία. Πριν την είσοδο ενός διανύσματος στο μοντέλο, αυτό επαυξάνεται (embedded) για να αποκτήσει τις απαιτούμενες διαστάσεις και αμέσως περνάει από το στάδιο της Κωδικοποίησης Θέσης. Αυτά τα δύο προ-επεξεργαστικά στάδια εξασφαλίζουν ότι πρώτον, όλα τα διανύσματα έχουν ίδιες διαστάσεις, ακόμα και αν κάποια βήματα της χρονοσειράς εισόδου λείπουν και δεύτερον, ότι η χρονική

σειρά των βημάτων διατηρείται καθόλη τη διαδικασία της επεξεργασίας που θα ακολουθήσει, αφού ενσωματώνεται στο διάνυσμα εισόδου ως μια παραπάνω διάσταση.

Στη συνέχεια τα διανύσματα τροφοδοτούνται στον Κωδικοποιητή και τον Αποκωδικοποιητή, οι οποίοι αποτελούνται από στοιβάδες επιπέδων με βασικό στοιχείο το μηχανισμό Προσοχής (Self - Attention). Κάθε επίπεδο τόσο του Κωδικοποιητή όσο και του Αποκωδικοποιητή αποτελείται από δύο υπό – επίπεδα. Το πρώτο είναι ένα επίπεδο πολύ επίπεδης Προσοχής (Multi head Self – Attention), και το δεύτερο ένα επίπεδο εμπρόσθιας τροφοδότησης κατά θέση (Positionwise feed-forward network). Συγκεκριμένα στον Κωδικοποιητή, τα διανύσματα του Ερωτήματος (Query), του Κλειδιού (Key) και της Τιμής (Value) προέρχονται όλα από την έξοδο του προηγούμενου επιπέδου Κωδικοποίησης. Χρησιμοποιούνται συνδέσεις υπολοίπων (Residual Connections) που προσθέτουν το διάνυσμα εισόδου ενός επιπέδου Κωδικοποίησης στο διάνυσμα εξόδου του. Στο τέλος κάθε επιπέδου εφαρμόζεται κανονικοποίηση της εξόδου (layer normalization). Αποτέλεσμα όλων αυτών, είναι ότι η τελική έξοδος του Κωδικοποιητή είναι ένα διάνυσμα αναπαράστασης διάστασης d για κάθε βήμα του μονοπατιού εισόδου. Αυτός είναι και ο λόγος που η αρχιτεκτονική είναι ιδιαίτερα απαιτητική ως προς τη μνήμη που χρειάζεται για να εκπαιδευτεί.

Ο Αποκωδικοποιητής αποτελείται και αυτός από μια στοίβα πανομοιότυπων επιπέδων με συνδέσεις υπολοίπων και κανονικοποίηση επιπέδου κατά την έξοδο. Η μόνη διαφορά είναι ότι σε ένα επίπεδο του Αποκωδικοποιητή προστίθεται ένα τρίτο υπό – επίπεδο, που ονομάζεται Προσοχή Κωδικοποίησης – Αποκωδικοποίησης (Encoder Decoder Attention). Σε αυτό το στάδιο, τα διανύσματα του Ερωτήματος (Query) προέρχονται από το προηγούμενο επίπεδο Αποκωδικοποίησης, ενώ τα διανύσματα του Κλειδιού (Key) και της Τιμής (Value) προέρχονται από την έξοδο του Κωδικοποιητή. Εδώ γίνεται η βασική συσχέτιση μεταξύ της χρονοσειράς εισόδου και της χρονοσειράς εξόδου. Σε όλα τα υπόλοιπα επίπεδα, τα διανύσματα του Ερωτήματος (Query), του Κλειδιού (Key) και της Τιμής (Value) προέρχονται από την έξοδο του προηγούμενου επιπέδου Αποκωδικοποίησης, με τη διαφορά ότι εφαρμόζεται στα διανύσματα μια μάσκα, για να εξασφαλιστεί ότι η πρόβλεψη προκύπτει μόνο από παρελθοντικά βήματα ή βήματα που έχουν προβλεφθεί.



Εικόνα 3. 2 Η αρχιτεκτονική του Trajectory Transformer

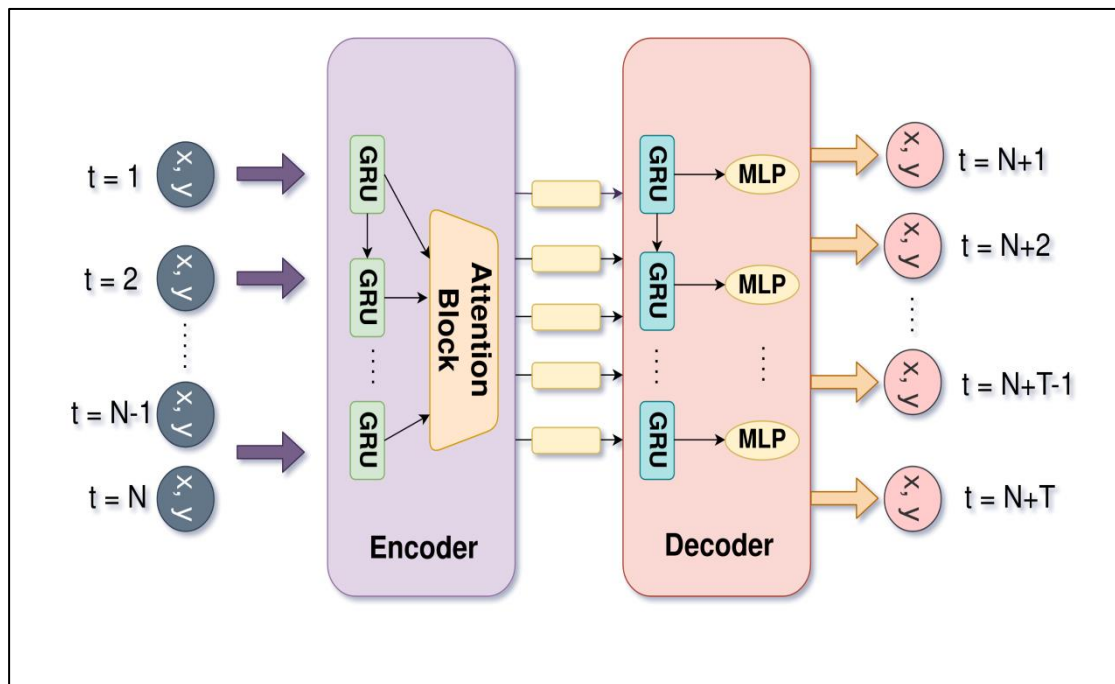
3.1.3 Το μοντέλο GRU with Attention

Η αρχιτεκτονική που παρουσιάζεται σε αυτή την παράγραφο αποτελεί την προτεινόμενη μεθοδολογία αυτής της εργασίας. Σκοπός της μεθοδολογίας είναι να ενσωματώσει τις βασικές δομές των αρχιτεκτονικών που έχουν παρουσιαστεί, ώστε να συνδυάσει τα στοιχεία αυτά που συνεισφέρουν στην αποτελεσματική πρόβλεψη του μονοπατιού εξόδου. Ένας άλλος βασικός σκοπός της προτεινόμενης μεθοδολογίας είναι η κατασκευή ενός μοντέλου το οποίο να είναι πολύ πιο «ελαφρύ» υπολογιστικά, δηλαδή να μην απαιτεί πολλή μνήμη και υπέρογκη κατανάλωση επεξεργαστικών πόρων κατά την εκπαίδευση, όπως συμβαίνει με τα μοντέλα σύγκρισης και άλλων προτεινόμενων από τη βιβλιογραφία αρχιτεκτονικών.

Για το σκοπό αυτό, σχεδιάστηκε ένα απλό Δίκτυο Κωδικοποιητή Αποκωδικοποιητή, με αναδρομικές μονάδες ως βασικό συστατικό. Η βασική λειτουργία του μοντέλου, λοιπόν, είναι αναδρομική. Η επιλογή αυτή έγινε για να αξιοποιηθούν τα χρονικά χαρακτηριστικά των δεδομένων εισόδου, χωρίς να χρειαστεί κάποιο επιπλέον επίπεδο εισόδου ή κάποια επιπλέον προ – επεξεργασία των δεδομένων που θα επιβάρυνε υπολογιστικά τη μεθοδολογία, καθώς, όπως έχει τονιστεί στο κεφάλαιο 2, τα αναδρομικά δίκτυα είναι παραδοσιακά πολύ πετυχημένα στη μοντελοποίηση χρονοσειρών. Ως βασική αναδρομική μονάδα τόσο του Κωδικοποιητή όσο και του Αποκωδικοποιητή, επιλέχθηκαν πύλες GRU, καθώς διαθέτουν λιγότερες παραμέτρους προς εκπαίδευση σε σχέση με τα LSTM, ενώ μετά από λίγα πειράματα διαπιστώθηκε ότι δεν υστερούν σε απόδοση.

Για την περαιτέρω βελτίωση της αρχιτεκτονικής, αξιοποιήθηκε ο Μηχανισμός Προσοχής, όπως έχει περιγραφεί στο κεφάλαιο 2. Για την κατασκευή του Μηχανισμού Προσοχής, απαιτούνται τα διανύσματα του Ερωτήματος (Query), του Κλειδιού (Key) και της Τιμής (Value), τα οποία μπορούν να εξαχθούν απευθείας από το GRU επίπεδο του Κωδικοποιητή. Συγκεκριμένα, χρησιμοποιείται έξοδος του επιπέδου ως Query και η κρυφή κατάσταση και ως Key και ως Value. Η μόνη διαφορά σε σχέση με το μηχανισμό Προσοχής του Trajectory Transformer που παρουσιάστηκε στην προηγούμενη παράγραφο, είναι ότι η παράμετρος στάθμισης για τον υπολογισμό του σταθμισμένου εσωτερικού γινομένου (scaled dot product), είναι μία παραπάνω παράμετρος της αρχιτεκτονικής και καθορίζεται κατά τη διαδικασία της εκπαίδευσης, όπως όλες οι άλλες υπερ- παράμετροι.

Η έξοδος του Μηχανισμού Προσοχής για κάθε χρονικό βήμα του μονοπατιού εισόδου, τροφοδοτείται στον Αποκωδικοποιητή, ο οποίος αποτελείται επίσης από ένα επίπεδο GRU που ακολουθείται από ένα Πυκνό επίπεδο εμπρόσθιας τροφοδότησης. Η έξοδος αυτού του τελευταίου επιπέδου αποτελεί και την τελική έξοδο του δικτύου, δηλαδή το προβλεπόμενο μονοπάτι εξόδου. Για την εκπαίδευση χρησιμοποιήθηκε το Μέσο Τετραγωνικό Σφάλμα ως συνάρτηση Κόστους. Στην εικόνα 3.3 παρουσιάζεται σχηματικά η αρχιτεκτονική της προτεινόμενης μεθοδολογίας.



Εικόνα 3.3 Η αρχιτεκτονική της προτεινόμενης μεθοδολογίας GRU with Attention

3.2 Σύνολα Δεδομένων

Το πρόβλημα πρόβλεψης πορείας είναι ένα από τα κρισιμότερα σε μια σειρά από εφαρμογές, όπως είναι τα αυτό – οδηγούμενα αυτοκίνητα, τα ρομπότ οικιακοί βοηθοί και πολλά άλλα. Μεγάλο κομμάτι τις επιστημονικής κοινότητας σε τομείς από την όραση υπολογιστών μέχρι τη δυναμική πληθυσμών έχει επιδείξει σημαντική δραστηριότητα πάνω στο θέμα, με εξαιρετικά αποτελέσματα τόσο από μεθόδους κινηματικής – κοινωνικής δυναμικής όσο και από μεθόδους οδηγούμενες από τα δεδομένα. Παράλληλα, έχει σημειωθεί συντονισμένη προσπάθεια ώστε να υπάρξει ένας κατάλληλος τρόπος συγκριτικής αξιολόγησης των μεθόδων που αναπτύσσονται. Αυτή η προσπάθεια οδήγησε στη δημιουργία αρκετών δεδομένων κίνησης ή την επαναχρησιμοποίηση συνόλων δεδομένων που είχαν δημιουργηθεί για άλλους σκοπούς, όπως την Παρακολούθηση Πολλαπλών Αντικειμένων (Multiple Object Tracking).

3.2.1 ETH/UCY Datasets

Ένα από τα πλέον γνωστά υπερ – σύνολα δεδομένων, προέκυψε από το TrajNet Challenge και αναπαριστά ένα συνδυασμό σεναρίων κίνησης αποτελώντας ορόσημο για τα προβλήματα πρόβλεψης τροχιάς. Ο διαγωνισμός αυτός περιέχει 3161 ανθρώπινα μονοπάτια, με 8 βήματα παρατήρησης (3.2 s) ως είσοδο και 12 βήματα (4.8 s) για πρόβλεψη.

Τα δύο σύνολα δεδομένων του TrajNet που έχουν χρησιμοποιηθεί κατά κόρον από πολλές ερευνητικές ομάδες για την αξιολόγηση των μοντέλων τους είναι τα σύνολα δεδομένων ETH [28] και UCY [29]. Τα δύο αυτά σύνολα δεδομένων αποτελούνται από πραγματικά μονοπάτια πεζών και είναι πλούσια σε σενάρια όπου πολλοί πράκτορες αλληλοεπιδρούν στην ίδια σκηνή. Για την καταγραφή των δεδομένων αξιοποιήθηκαν στιγμιότυπα συχνότητας 2.5Hz ($\Delta t = 0.4s$). Συνολικά, υπάρχουν 5 διαφορετικά στιγμιότυπα, σε 4 διαφορετικές σκηνές και 1535 μοναδικοί πράκτορες – πεζοί. Περιέχουν συμπεριφορές κίνησης που αποτελούν πρόκληση επί του θέματος, όπως ζεύγη πεζών που κινούνται μαζί και ομάδες πεζών που αλληλοεπιδρούν με διάφορους τρόπους, γι' αυτό και έχουν αποτελέσει σημείο αναφοράς όσον αφορά τη σύγκριση μεθόδων για το πρόβλημα της πρόβλεψης τροχιάς. Παρόλα αυτά, περιέχουν μόνο μονοπάτια από πεζούς πράκτορες, γεγονός που είναι περιοριστικό όσον αφορά την επέκταση του προβλήματος και για άλλες κατηγορίες κινούμενων πρακτόρων, όπως οχήματα.

3.2.2 Σύνολο Δεδομένων Προσομοίωσης

Για να επεκταθεί η μοντελοποίηση του προβλήματος και στην κατηγορία οχημάτων, στο πλαίσιο της παρούσας διπλωματικής εργασίας, δημιουργήθηκε ένα ακόμη σύνολο δεδομένων, που προέκυψε από διαδικασία προσομοίωσης και περιλαμβάνει τόσο πεζούς όσο και οχήματα, που κινούνται στο πραγματικό περιβάλλον του εμπορικού κέντρου

McArthurGlen. Για την κατασκευή του συνόλου δεδομένων, χρησιμοποιήθηκε ένα μοντέλο κίνησης που βασίστηκε στα [19][20][21] και στηρίζεται σε 3 βασικά συστατικά: α) έναν πράκτορα κίνησης που αποτελεί το στόχο του μοντέλου και περιγράφεται από ένα διάνυσμα θέσης από πραγματικές συντεταγμένες (καθώς και σχετικές x,y συντεταγμένες) και ένα διάνυσμα ταχύτητας, β) μια γεωμετρική Περιοχή που περιγράφεται από ένα κυρτό πολύγωνο, και γ) ένα γεωμετρικό Μονοπάτι που περιγράφεται από μια μη κλειστή περιοχή σημείων και δημιουργεί τα μονοπάτια που ακολουθούν οι χρήστες για να μετακινηθούν από μια Περιοχή σε μια άλλη. Η προσομοίωση παράγει σενάρια κίνησης σε μικτούς εσωτερικούς – εξωτερικούς χώρους, όπως εδώ [22][23][24]

Αφού επιλεχθούν χειρωνακτικά οι περιοχές ενδιαφέροντος (Περιοχές και Μονοπάτια), με το εργαλείο που είναι διαθέσιμο στον προσομοιωτή, δίνονται ως είσοδος στο μοντέλο κίνησης για να ξεκινήσει η προσομοίωση. Το μοντέλο κίνησης είναι ένα μοντέλο με μνήμη που βασίζεται σε επαναλήψεις και στηρίζεται στις εξής αρχές: α) Ένας κινούμενος κόμβος (mobile node) μπορεί να είναι είτε πεζός είτε όχημα σε χώρο πάρκινγκ είτε όχημα σε ανοιχτό δρόμο. Αυτό έχει ως αποτέλεσμα τα μονοπάτια να χαρακτηρίζονται από ποικίλες ταχύτητες που προκύπτουν από μια ομοιόμορφη κατανομή με μέση τιμή και τυπική απόκλιση που δίνονται ως είσοδοι στον προσομοιωτή. Β) Σε κάθε χρονική στιγμή, ένας κόμβος είτε κινείται προς μια Περιοχή είτε περιμένει σε μια Περιοχή, με χρόνο αναμονής που προκύπτει από μια κανονική κατανομή με μέση τιμή και τυπική απόκλιση που εξαρτάται από την Περιοχή και σε κάθε περίπτωση μπορούν να δοθούν ως είσοδοι στον προσομοιωτή. Όποτε ένας κόμβος επιλέξει ένα συγκεκριμένο μονοπάτι, το κάνει επιλέγοντας τυχαία εσωτερικά σημεία του μονοπατιού προσθέτοντας λευκό γκαουσιανό θόρυβο (Additive White Gaussian Noise), με μέση τιμή μηδέν και τυπική απόκλιση ένα μέτρο, ώστε να λαμβάνονται υπόψη στοχαστικές μεταβολές στον τρόπο που οι κόμβοι κινούνται. γ) Όποτε ένας κόμβος φτάσει στην Περιοχή – προορισμό, υπολογίζει ένα χρόνο αναμονής καθώς και το νέο προορισμό του. Ο προορισμός επιλέγεται από ένα σταθμισμένο μηχανισμό ρουλέτας με βάση το βάρος κάθε Περιοχής, το οποίο επίσης δίνεται ως είσοδος στον προσομοιωτή για κάθε μία από τις Περιοχές. Επιπρόσθετα, μια Περιοχή δεν μπορεί να επιλεγεί εάν ο τρέχων αριθμός επισκεπτών της έχει φτάσει το μέγιστο αριθμό, μεταβλητή που εξαρτάται από την Περιοχή. Το μοντέλο κίνησης επαναξιολογεί την κατάστασή του κάθε 100ms και καταλήγει σε μια πλούσια, σε πυκνότητα κόμβων στις διάφορες ζώνες κίνησης, προσομοίωση που μπορεί εύκολα να χρησιμοποιηθεί ως ρεαλιστική είσοδος για μοντέλα μηχανικής μάθησης. Παρακάτω παρουσιάζονται μερικά στιγμιότυπα από τον προσομοιωτή κατά την παραγωγή των δεδομένων.



Εικόνα 3.4 Στιγμιότυπα από τον προσομοιωτή με τις περιοχές κίνησης(δρόμοι, πάρκινγκ, σημεία συγκέντρωσης πεζών)

3.2.3 Τεχνικές Προ-επεξεργασίας Δεδομένων

Ένα απαραίτητο βήμα κατά την επεξεργασία των δεδομένων πριν την τροφοδότησή τους στα νευρωνικά δίκτυα είναι η εξαγωγή των μονοπατιών από τα σύνολα δεδομένων. Επειδή απαιτούνται μονοπάτια με τουλάχιστον 20 βήματα, διατηρήθηκαν μόνο μονοπάτια που έχουν τουλάχιστον 17 συνεχόμενα βήματα. Για τη συμπλήρωση των υπόλοιπων, τριών το πολύ βημάτων ανά μονοπάτι, χρησιμοποιήθηκε η τεχνική της γραμμικής παρεμβολής.

Ένα άλλο προ-επεξεργαστικό βήμα ήταν η διαδικασία επαύξησης των μονοπατιών με τη μέθοδο του κυλιόμενου παραθύρου, για τη δημιουργία περισσότερων δεδομένων. Για να γίνει κατανοητό πώς λειτουργεί αυτή η τεχνική, έστω ότι ένας πράκτορας έχει κινηθεί σε μονοπάτι 25 βημάτων. Επειδή τα μονοπάτια που θα χρησιμοποιηθούν κατά την εκπαίδευση πρέπει να έχουν ακριβώς 20 βήματα, από το αρχικό μονοπάτι θα προκύψουν 6 νέα μονοπάτια, το πρώτο από το βήμα 1 έως το βήμα 20, το δεύτερο από το βήμα 2 έως το βήμα 21 και ούτω καθεξής.

3.3 Μετρικές Αξιολόγησης και Πειραματική Διαδικασία

Στο παρόν υπο-κεφάλαιο θα παρουσιαστούν οι μετρικές που θα χρησιμοποιηθούν για την αξιολόγηση της διαδικασίας εκπαίδευσης των μοντέλων, θα περιγραφεί η πειραματική διαδικασία που ακολουθήθηκε και θα παρατεθούν ορισμένες λεπτομέρειες για την υλοποίηση και την εκπαίδευση των μοντέλων

3.3.1 Μετρικές αξιολόγησης

Για την αξιολόγηση των μοντέλων θα χρησιμοποιηθούν δύο μετρικές σφάλματος που βασίζονται στην ευκλείδεια απόσταση, παραδοσιακές σε προβλήματα πρόβλεψης θέσης, το Μέσο Σφάλμα μετατόπισης (1) και το Τελικό Σφάλμα μετατόπισης (2), που ορίζονται ως εξής:

- **Average Displacement Error (ADE)**, το μέσο ευκλείδειο σφάλμα για μεταξύ του πραγματικού και εκτιμώμενου μονοπατιού, για όλα τα βήματα:

$$ADE(true, pred) = \frac{\sum_{t=1}^n \sqrt{(x_t - \hat{x}_t)^2 + (y_t - \hat{y}_t)^2}}{n} \quad (1)$$

- **Final Displacement Error (FDE)**, ευκλείδεια απόσταση ανάμεσα στο πραγματικό και εκτιμώμενο σημείο προορισμού, δηλαδή στο τελευταίο βήμα:

$$FDE(p_n, \hat{p}_n) = \sqrt{(x_n - \hat{x}_n)^2 + (y_n - \hat{y}_n)^2} \quad (2)$$

Στο πρόβλημα της πρόβλεψης τροχιάς, το Μέσο Σφάλμα μετατόπισης είναι μια ένδειξη του πόσο το προβλεπόμενο μονοπάτι ακολουθεί κατά μέσο όρο την τροχιά του πραγματικού μονοπατιού, ενώ το Τελικό Σφάλμα μετατόπισης δείχνει πόσο απέχει ο πραγματικός τελικός προορισμός του πράκτορα κίνησης από την τελευταία πρόβλεψη του μοντέλου.

3.3.2 Πειραματική Διαδικασία

Η διαδικασία που θα ακολουθηθεί περιγράφεται περιληπτικά σε αυτή την παράγραφο.

Τα μοντέλα που παρουσιάστηκαν σε αυτό το κεφάλαιο - δηλαδή τα δύο μοντέλα σύγκρισης Social GAN και Trajectory Transformer και το μοντέλο της προτεινόμενης μεθοδολογίας GRU - θα εκπαιδευτούν τόσο στο δημόσιο σύνολο δεδομένων ETH/UCY όσο και στο σύνολο δεδομένων προσομοίωσης InCelliSim. Θα υλοποιηθούν δύο διαφορετικά πειραματικά σενάρια, ένα κατά το οποίο το σύνολο δεδομένων εκπαίδευσης (train set) θα αποτελείται από μονοπάτια 8 βημάτων και το σύνολο δεδομένων αξιολόγησης (test set) θα αποτελείται από μονοπάτια 12 βημάτων. Στο δεύτερο σενάριο θα αντιστραφεί η διαδικασία, και τα μοντέλα θα εκπαιδεύονται σε μονοπάτια 12 βημάτων και θα προβλέπουν μονοπάτια 8 βημάτων. Τα αποτελέσματα θα επικεντρωθούν στο πρώτο σενάριο, καθώς είναι και το πιο δύσκολο για τα μοντέλα.

Στη συνέχεια, για την αξιολόγηση των αρχιτεκτονικών και για να διαπιστωθεί εάν η προτεινόμενη μεθοδολογία είναι κατάλληλη για το πρόβλημα και ανταγωνιστική σε σχέση

με τις αρχιτεκτονικές σύγκρισης, θα καταγραφούν τα αποτελέσματα κυρίως με βάση τις μετρικές αξιολόγησης σφάλματος. Έπειτα, θα γίνει μια διδιάστατη αναπαράσταση μερικών προβλεπόμενων μονοπατιών για να γίνει μια ποιοτική σύγκριση των μοντέλων. Επιπλέον, θα γίνει ανάλυση των αποτελεσμάτων της προτεινόμενης μεθοδολογίας, ώστε να εξεταστούν τα πλεονεκτήματα και τα μειονεκτήματά της.

Τέλος, θα γίνει ποσοτική σύγκριση της υπολογιστικής πολυπλοκότητας των διαφορετικών αρχιτεκτονικών, όπως αυτή αντιπροσωπεύεται από το συνολικό αριθμό των υπερπαραμέτρων εκπαίδευσης.

3.3.3 Λεπτομέρειες Εκπαίδευσης

Για την εκπαίδευση των δύο baseline μοντέλων χρησιμοποιήθηκαν τα επίσημα repositories από το github. Ο κώδικας για το μοντέλο Social GAN βρίσκεται [εδώ](#) και για το Transformer [εδώ](#). Οι υλοποιήσεις έχουν γίνει σε ρυθμό ενώ για την κατασκευή και εκπαίδευση των μοντέλων χρησιμοποιήθηκε η βιβλιοθήκη pytorch. Αξίζει να σημειωθεί ότι τόσο για την εκπαίδευση όσο και την παραγωγή προβλέψεων απαιτείται η χρήση σύγχρονης τεχνολογίας κάρτας γραφικών (GPU), καθώς τα μοντέλα είναι αρκετά βαθιά και δεν μπορούν να υλοποιηθούν σε ένα συμβατικό υπολογιστή λόγω υπερχείλισης μνήμης. Ενδεικτικά, σε μηχάνημα με 64GB RAM και GPU Nvidia GeForce GTX 980 Ti με χωρητικότητα μνήμης 6GB και ταχύτητα επεξεργαστή 1140MHz το μοντέλο Transformer χρειάζεται περίπου 24 και 60 ώρες για την ολοκλήρωση 200 εποχών εκπαίδευσης σε καθένα από τα σύνολα δεδομένων που χρησιμοποιήθηκαν.

Το μοντέλο της προτεινόμενης μεθοδολογίας μας GRU with Attention υλοποιήθηκε εξ ολοκλήρου για τις ανάγκες της εργασίας. Η κατασκευή και εκπαίδευση του μοντέλου έγινε επίσης σε ρυθμό και με τη χρήση της βιβλιοθήκης σε tensorflow και όλες οι υλοποιήσεις έγιναν σε ρυθμό. Η εκπαίδευση του μοντέλου έγινε σε συμβατικό υπολογιστή με 16GB RAM, χωρίς χρήση κάρτας γραφικών, με επεξεργαστή Intel i7 8550U συχνότητας 1.8GHz, και χρειάζεται περίπου 30 λεπτά για την ολοκλήρωση 200 εποχών εκπαίδευσης.

Κεφάλαιο 4 Αποτελέσματα

Στο κεφάλαιο αυτό παρουσιάζονται τα αποτελέσματα των διαφορετικών υλοποιήσεων που παρουσιάστηκαν στη ενότητα 4. Συνοπτικά, αναλύεται η αποδοτικότητα του εκάστοτε μοντέλου όσον αφορά την επίλυση του προβλήματος πρόβλεψης μονοπατιού, καθώς και μια σύγκριση της υπολογιστικής πολυπλοκότητας τους.

4.1 Ποσοτική αξιολόγηση με βάση τις μετρικές

Σε αυτό το κεφάλαιο θα παρουσιαστούν τα βασικά αποτελέσματα για την αξιολόγηση της επίδοσης των τριών μοντέλων από την πειραματική διαδικασία. Οι μετρικές που χρησιμοποιήθηκαν αφορούν στο Τελικό Σφάλμα Μετατόπισης (Final Displacement Error - FDE) και Μέσο Σφάλμα Μετατόπισης (Average Displacement Error - ADE), που έχουν οριστεί στο κεφάλαιο της μεθοδολογίας. Ακόμη, υπολογίζεται το Μέσο σφάλμα (MDE), το οποίο είναι απλώς η μέση τιμή των δύο προαναφερθέντων μετρικών σφάλματος.

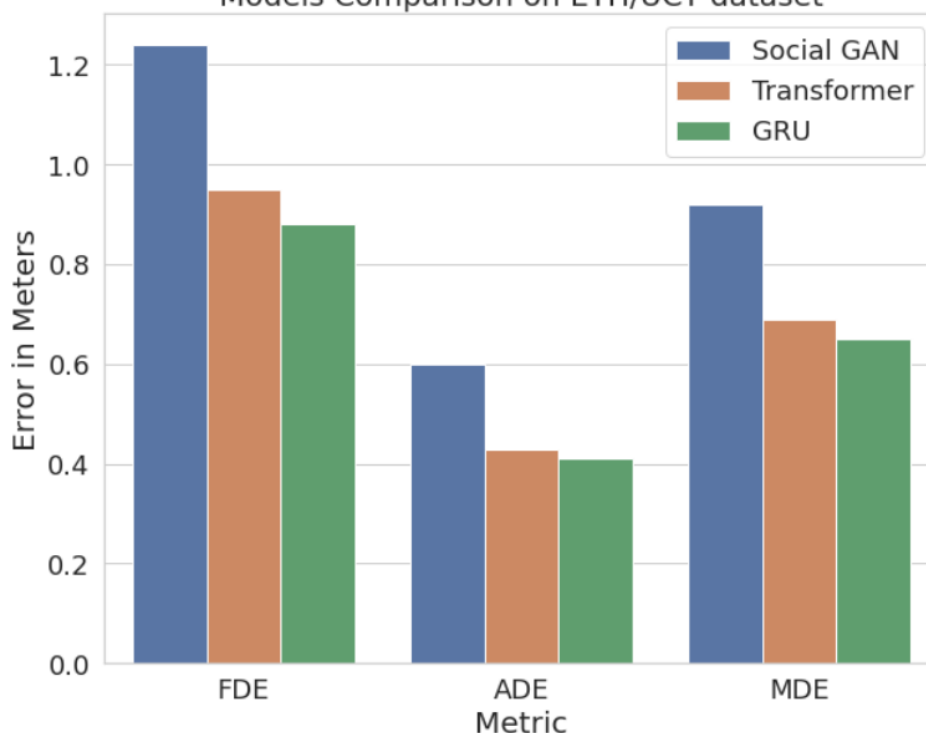
Ο πίνακας 4.1 δείχνει τα αποτελέσματα των τριών συγκρινόμενων αρχιτεκτονικών για το πρώτο σύνολο δεδομένων προς εξέταση, το ETH/UCY.

Μοντέλο	FDE	ADE	MDE
Social GAN	1.24	0.60	0.92
Transformer	0.95	0.43	0.69
GRU	0.88	0.41	0.64

Πίνακας 4. 1 Αποτελέσματα στο δημόσιο dataset ETH/UCY

Παρατηρείται ότι το Social GAN πετυχαίνει εμφανώς χειρότερη επίδοση τόσο σχέση με την προτεινόμενη αρχιτεκτονική όσο και από τον Transformer. Αντιθέτως, οι άλλες δυο υλοποιήσεις έχουν παρόμοια αποτελέσματα, με το μοντέλο της GRU να είναι ελαφρώς καλύτερο. Τα ίδια αριθμητικά αποτελέσματα παρουσιάζονται και στην εικόνα 10 σε μορφή bar-plot.

Barplot: Models' Loss per Metric
Models Comparison on ETH/UCY dataset




Εικόνα 4.1 Αποτελέσματα στο δημόσιο dataset ETH/UCY (bar-plot)

Στον πίνακα 4.2 παρουσιάζονται τα αποτελέσματα των τριών συγκρινόμενων αρχιτεκτονικών για το δεύτερο σύνολο δεδομένων προς εξέταση, το σύνολο δεδομένων προσομοίωσης.

Μοντέλο	FDE	ADE	MDE
Social GAN	6.96	3.54	5.25
Transformer	1.5	0.62	1.06
GRU	0.77	0.44	0.61

Πίνακας 4. 2: Αποτελέσματα στο δημόσιο dataset ETH/UCY

Και πάλι τα αριθμητικά αποτελέσματα παρουσιάζονται σε μορφή bar-plot στην εικόνα 11.



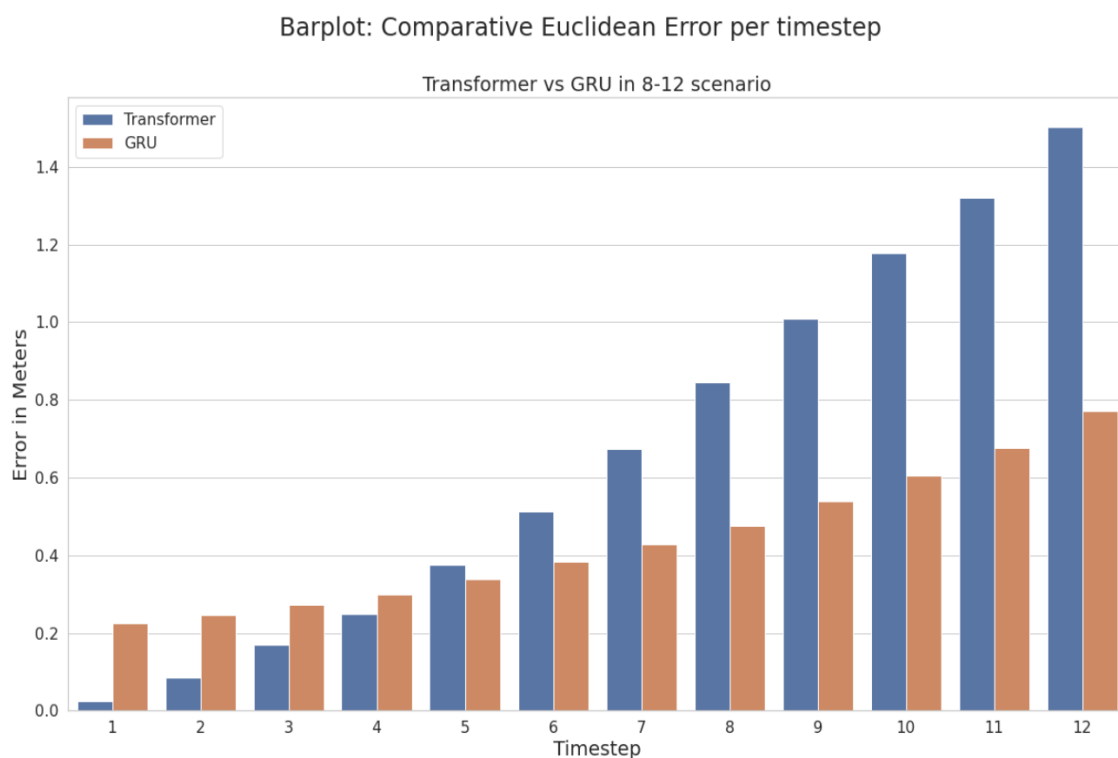
Εικόνα 4. 2 Αποτελέσματα στο simulated dataset (bar plot)

Παρατηρείται και εδώ, ότι τα μοντέλα Transformer και GRU έχουν συγκρίσιμες επιδόσεις, ενώ το Social GAN έχει σαφώς χειρότερη επίδοση από τα άλλα δύο. Αυτό είναι κάτι αναμενόμενο, καθώς όπως έχει τονιστεί και σε προηγούμενο κεφάλαιο, το Social GAN κατά τη διαδικασία της εκπαίδευσής του λαμβάνει υπόψη του και τις αλληλεπιδράσεις των πρακτόρων κίνησης, με σκοπό την παραγωγή μονοπατιών που είναι κοινωνικά αποδεκτά, δηλαδή να αποφεύγονται οι συγκρούσεις μεταξύ τους. Αυτό είναι μια παραπάνω παράμετρος που περιλαμβάνεται στις συναρτήσεις σφάλματος του μοντέλου, με αποτέλεσμα να κάνει το συνολικό πρόβλημα που καλείται να λύσει πιο δύσκολο, σε σχέση με τα άλλα δύο μοντέλα.

4.2 Σύγκριση επικρατέστερων αρχιτεκτονικών στα διαφορετικά σενάρια

4.2.1 Σενάριο A – 8 βήματα εισόδου, 12 βήματα εξόδου

Σε αυτό το υπο - κεφάλαιο περιγράφεται αναλυτικότερα η σύγκριση των επιδόσεων των αρχιτεκτονικών **Transformer** και **GRU**, ως τις δύο επικρατέστερες αρχιτεκτονικές. Το παρακάτω διάγραμμα δείχνει το μέσο σφάλμα μετατόπισης των προβλέψεων των δύο επικρατέστερων μοντέλων για κάθε ένα από τα βήματα του μονοπατιού εξόδου. Τα αποτελέσματα αναφέρονται στο σύνολο δεδομένων προσομοίωσης του Incellisim.



Εικόνα 4.3 Σφάλμα προβλέψεων των 2 επικρατέστερων μοντέλων για το σενάριο 8/12

Στην εικόνα 12 φαίνεται ότι η υπεροχή του μοντέλου της προτεινόμενης μεθοδολογίας υπερέρχει σημαντικά στα τελευταία βήματα της πρόβλεψης, όπου το κέρδος σε σχέση με την επίδοση του Transformer είναι της τάξης του 50%. Δεν ισχύει το ίδιο όμως και στα πρώτα βήματα του μονοπατιού εξόδου, όπου το Transformer πετυχαίνει περίπου 10 φορές καλύτερη ακρίβεια πρόβλεψης της τοποθεσίας σε σχέση με το δικό μας μοντέλο. Παρόλα αυτά, στη συνέχεια το σφάλμα του αυξάνεται εκθετικά με τα βήματα. Αντίθετα, το μοντέλο της μεθοδολογίας μας καταφέρνει να έχει μικρή απόκλιση μεταξύ πρώτου και τελευταίου βήματος (σφάλμα στο πρώτο βήμα: 0.22 m, σφάλμα στο τελευταίο βήμα 0.77 m),

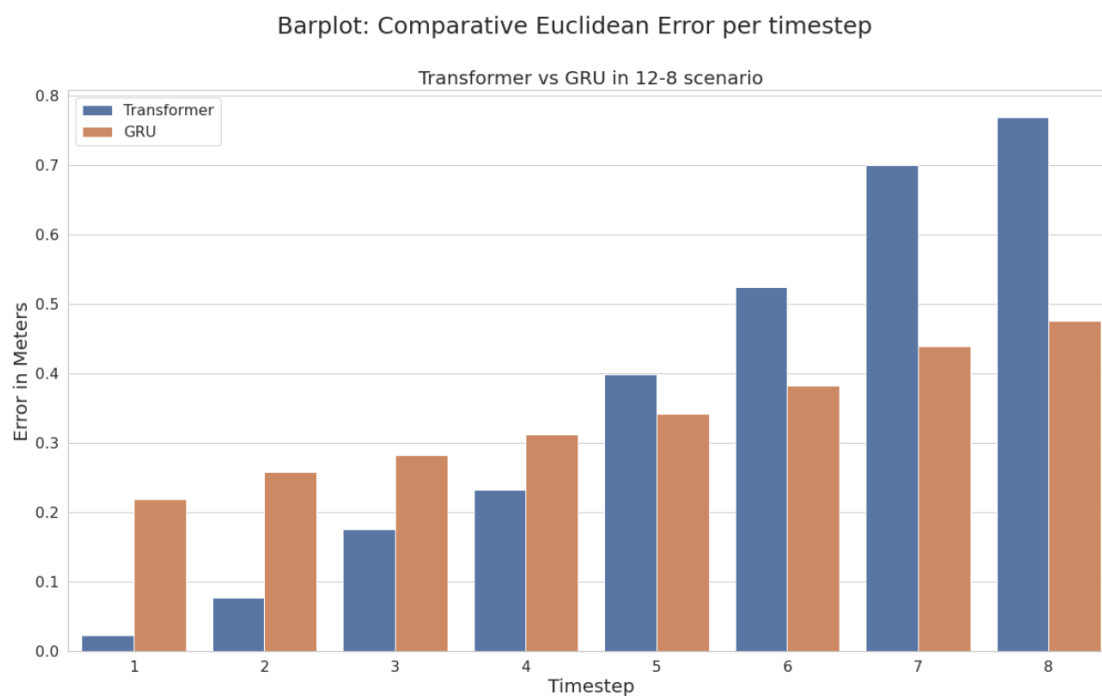
πετυχαίνοντας έτσι περίπου 30% βελτίωση στο μέσο σφάλμα πρόβλεψης για όλα τα βήματα σε σχέση με το Transformer.

4.2.2 Σενάριο B – 12 βήματα εισόδου, 8 βήματα εξόδου

Παρόμοια συμπεριφορά παρατηρείται και στα παρακάτω αποτελέσματα, όπου συγκρίνεται η επίδοση των δύο επικρατέστερων μοντέλων για το δεύτερο και πιο εύκολο σενάριο, έχοντας 12 βήματα μονοπατιού ως είσοδο και 8 ως έξοδο. Στον πίνακα 3, φαίνονται οι μετρικές όπως υπολογίστηκαν για την τελική πρόβλεψη ενώ η εικόνα 13 δείχνει την απόκλιση του κάθε μοντέλου σε κάθε ένα από τα 8 σημεία πρόβλεψης.

Model	FDE	ADE	MDE
Transformer	0.76	0.39	0.58
GRU	0.48	0.33	0.41

Πίνακας 4. 3 Αποτελέσματα των 2 επικρατέστερων μοντέλων στο Incellisim dataset για το σενάριο 12/8



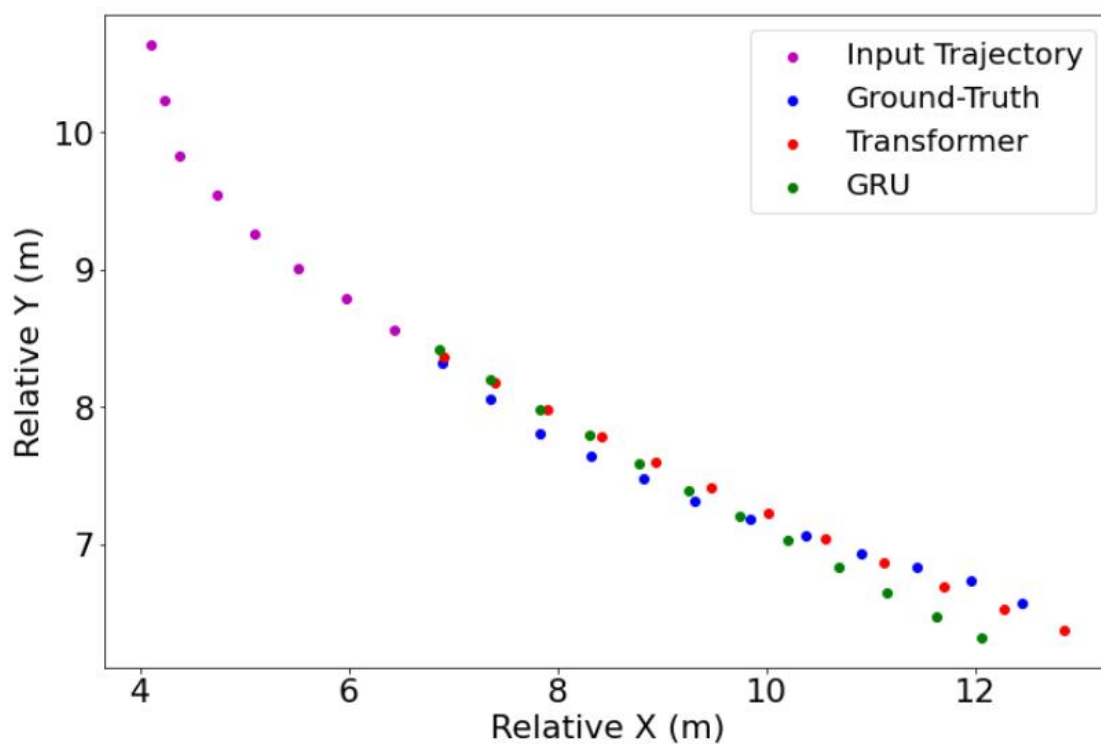
Εικόνα 4.4 Σφάλμα προβλέψεων των 2 επικρατέστερων μοντέλων για το σενάριο 12/8

Και πάλι το Transformer κυριαρχεί κατά τα πρώτα 4 βήματα, αλλά υστερεί σημαντικά κατά τα τελευταία 4, αφού το σφάλμα μεγαλώνει σχεδόν εκθετικά με το πέρας των βημάτων. Αντίθετα, το προτεινόμενο μοντέλο της μεθοδολογίας μας, αν και υστερεί αρκετά στα πρώτα βήματα, έχει πολύ πιο σταθερή επίδοση όσο περνάνε τα χρονικά βήματα.


4.3 Διδιάστατη απεικόνιση αποτελεσμάτων

Σε αυτήν την ενότητα παρουσιάζεται μια οπτικοποίηση των παραπάνω αποτελεσμάτων σε διδιάστατη μορφή για να υπάρχει μια ποιοτική εποπτεία της επίδοσης των διαφορετικών αρχιτεκτονικών.


Στις εικόνες 14,15,16 φαίνονται κάποια παραδείγματα μονοπατιών τα οποία και τα δύο επικρατέστερα μοντέλα καταφέρνουν προβλέψεις με χαμηλό σφάλμα μετατόπισης.



Εικόνα 4.5 Ενδεικτικό μονοπάτι με επιτυχημένες προβλέψεις και από τα 2 επικρατέστερα μοντέλα




Εικόνα 4.6 Ενδεικτικό μονοπάτι με επιτυχημένες προβλέψεις και από τα 2 επικρατέστερα μοντέλα




Εικόνα 4.7 Ενδεικτικό μονοπάτι με επιτυχημένες προβλέψεις και από τα 2 επικρατέστερα μοντέλα

Στις παραπάνω εικόνες φαίνονται μερικά χαρακτηριστικά παραδείγματα τυπικών μονοπατιών, με την έννοια ότι η πορεία που ακολουθούν οι πράκτορες είναι σχετικά ομαλές, χωρίς να παρουσιάζουν ασυνήθιστα χαρακτηριστικά. Παρατηρείται ότι και τα δύο μοντέλα καταφέρνουν να προβλέψουν με σχετική επιτυχία τέτοιου είδους μονοπάτια. Αξίζει να σημειωθεί, όπως θα φαίνεται και παρακάτω, ότι μεγάλο μέρος του συνόλου δεδομένων αποτελείται από τέτοια “ομαλά” μονοπάτια, όπως άλλωστε είναι και αναμενόμενο.


Οι εικόνες 17,18 και 19 αντιθέτως δείχνουν περιπτώσεις όπου τα μοντέλα αποτυγχάνουν να προβλέψουν σωστά την πορεία των αντικειμένων.



Εικόνα 4.8 Ενδεικτικό μονοπάτι με αποτυχημένες προβλέψεις και από τα 2 επικρατέστερα μοντέλα




Εικόνα 4.9 Ενδεικτικό μονοπάτι με αποτυχημένες προβλέψεις και από τα 2 επικρατέστερα μοντέλα



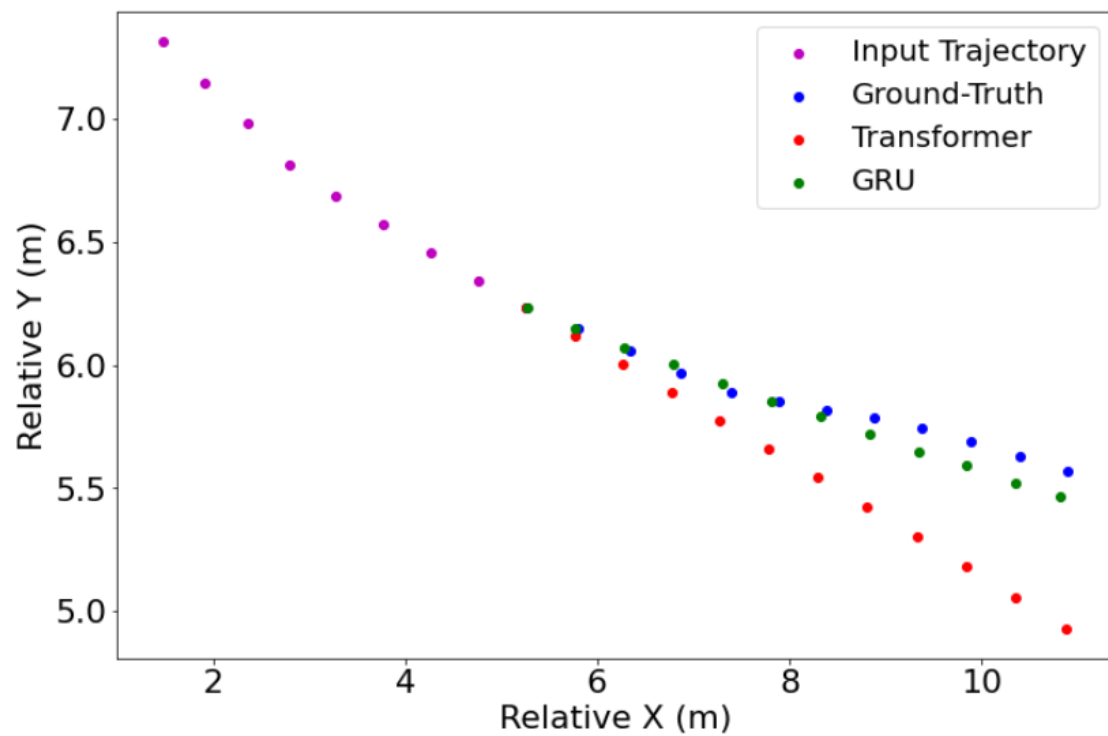
Εικόνα 4.10 Ενδεικτικό μονοπάτι με αποτυχημένες προβλέψεις και από τα 2 επικρατέστερα μοντέλα

Οι παραπάνω εικόνες αφορούν σε μονοπάτια με κάπως ασυνήθιστη κίνηση του πράκτορα, αφού υπάρχει σημαντική αλλαγή στην κατεύθυνση κίνησης, η οποία μάλιστα συμβαίνει στο πραγματικό μονοπάτι εξόδου (groundtruth) και δεν αποτυπώνεται με κάποιο τρόπο στο μονοπάτι εισόδου, με βάση το οποίο τα μοντέλα κατασκευάζουν την πρόβλεψή τους. Είναι λοιπόν λογικό ότι σε τέτοιες περιπτώσεις μονοπατιών, οι οποίες δεν είναι τόσο συχνές, τα μοντέλα όχι μόνο πετυχαίνουν σημαντικό σφάλμα, αλλά δεν μπορούν καν να εντοπίσουν σωστά την κατεύθυνση κατά την οποία θα κινηθεί ο πράκτορας. Αυτό παρατηρείται όχι σε όλες, αλλά σε πολλές από αυτές τις ειδικές περιπτώσεις μονοπατιών με τις οποίες θα ασχοληθούμε περισσότερο παρακάτω.


Τέλος, στις παρακάτω εικόνες αναδεικνύονται περιπτώσεις μονοπατιών στα οποία υστερεί είτε το ένα, είτε το άλλο από τα δύο εξεταζόμενες υλοποιήσεις.



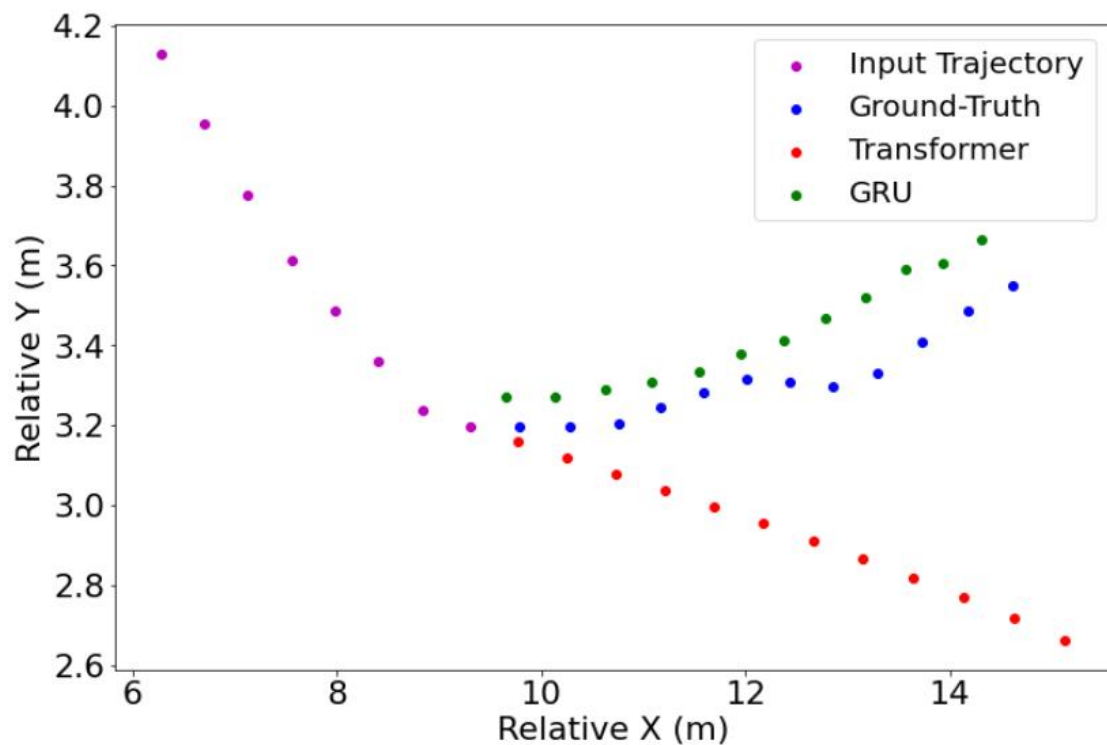
Εικόνα 4.11 Ενδεικτικό μονοπάτι όπου το Transformer προβλέπει καλύτερα το μονοπάτι εξόδου από το προτεινόμενο μοντέλο



Εικόνα 4.12 Ενδεικτικό μονοπάτι όπου το προτεινόμενο μοντέλο προβλέπει καλύτερα το μονοπάτι εξόδου από το Transformer



Εικόνα 4.13 Ενδεικτικό μονοπάτι όπου το προτεινόμενο μοντέλο προβλέπει καλύτερα το μονοπάτι εξόδου από το Transformer



Εικόνα 4.14 Ενδεικτικό μονοπάτι όπου το προτεινόμενο μοντέλο προβλέπει καλύτερα το μονοπάτι εξόδου από το Transformer

Σαν γενικές παρατηρήσεις. Σαν γενικές παρατηρήσεις, από τα μονοπάτια στις εικόνες 20,21,22 και 23 φαίνεται ότι το Transformer εντοπίζει σαφώς καλύτερα την κατεύθυνση της κίνησης στα πρώτα βήματα και δημιουργεί πιο “σταθερά” μονοπάτια, που δεν έχουν απόκλιση από τη διεύθυνση της κίνησης του πράκτορα όπως αυτή ορίζεται από τα τελευταία βήματα του μονοπατιού εισόδου. Από την άλλη, το μοντέλο της προτεινόμενης αρχιτεκτονικής, δημιουργεί πιο “ασταθή” μονοπάτια, με αποτέλεσμα να έχει σημαντικό σφάλμα στα πρώτα βήματα, που όμως ακολουθούν γενικά την τροχιά του μονοπατιού

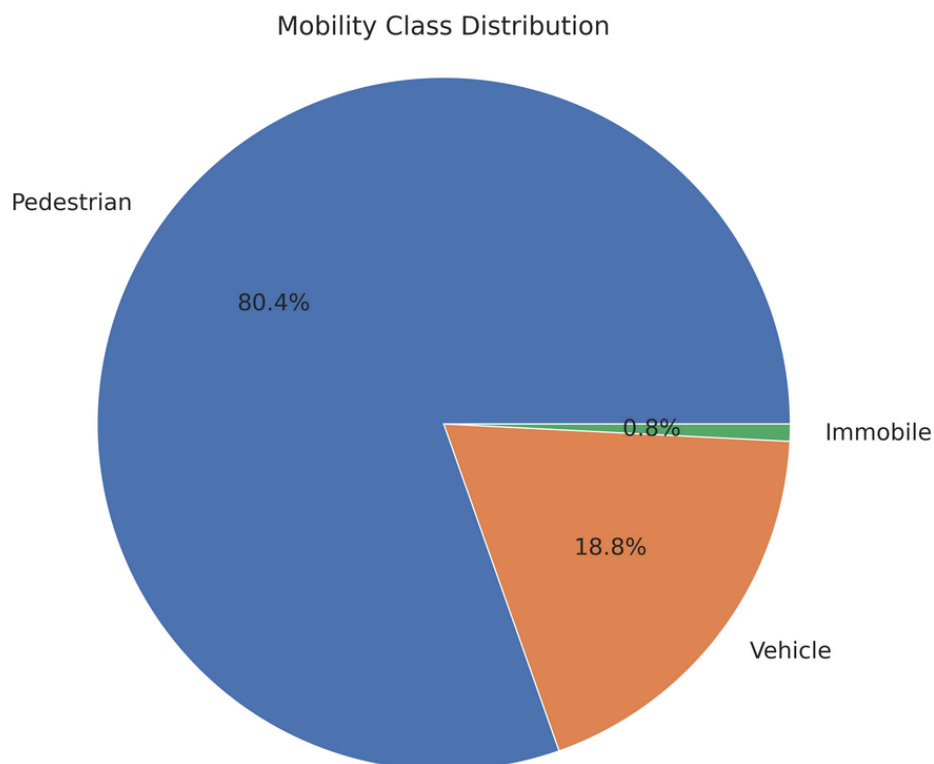
εξόδου, έτσι ώστε το συνολικό μέσο σφάλμα και το σφάλμα τελικού προορισμού να είναι μικρότερα από αυτά του ανταγωνιστή του. Η συμπεριφορά αυτή μπορεί να εξηγήσει ποιοτικά και τα αποτελέσματα του κεφαλαίου 5.2, ότι δηλαδή, το Transformer υπερτερεί στα πρώτα βήματα πρόβλεψης ενώ το GRU στα επόμενα.

4.4 Ανάλυση αποτελεσμάτων GRU

Στο παρόν υπο-κεφάλαιο εξετάζονται μερικές παράμετροι που μπορεί να επηρεάζουν την επίδοση και το σφάλμα πρόβλεψης.


4.4.1 Η επίδραση της κατηγορίας του πράκτορα κίνησης

Έχει αναφερθεί το σύνολο δεδομένων προσομοίωσης περιέχει και οχήματα εκτός από πεζούς. Στην εικόνα 24 φαίνεται η κατανομή των δεδομένων σε αυτές τις κλάσεις.



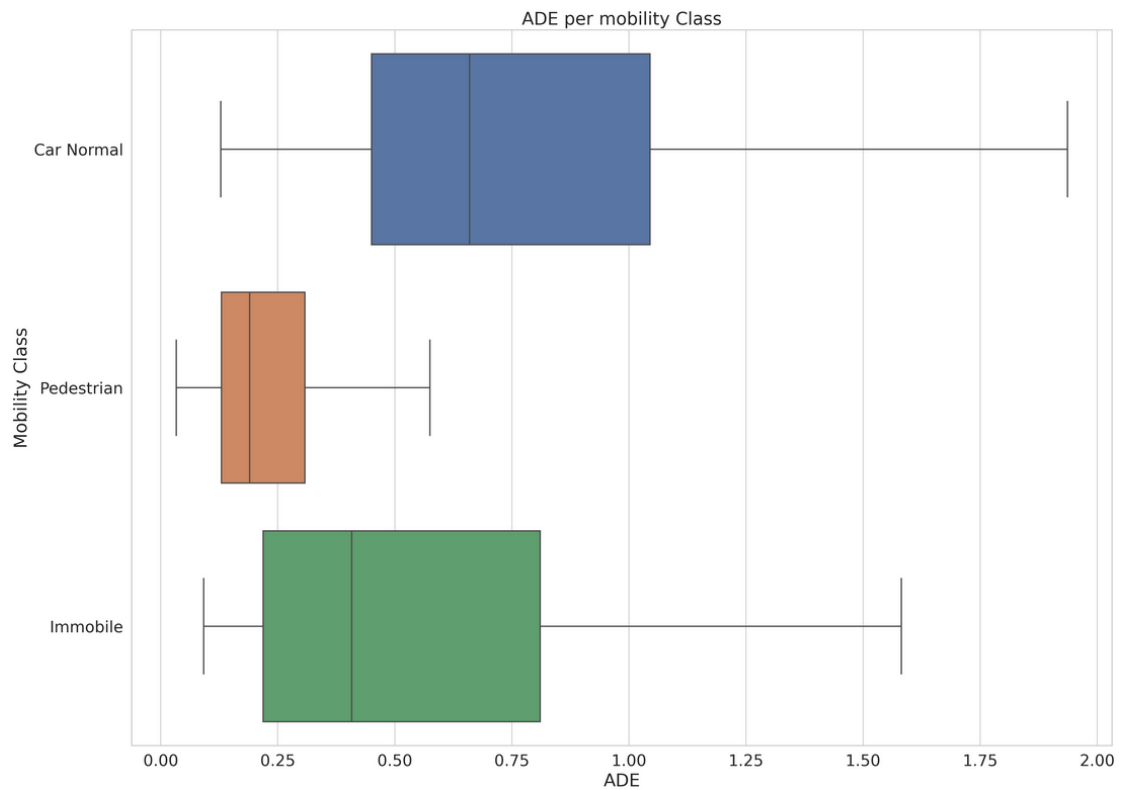
Εικόνα 4. 15 Κατανομή πρακτόρων κίνησης σε πεζούς, οχήματα και ακίνητους

Το ποσοστό, λοιπόν, των οχημάτων σε κίνηση είναι το 18.8% του συνόλου των δεδομένων μας, ενώ υπάρχει κι ένα 0.8% των μονοπατιών που αποτελείται από ακίνητους πράκτορες. Τα υπόλοιπα δεδομένα (80.4% του συνόλου) αποτελούνται από πεζούς. Στην παρακάτω εικόνα παρουσιάζεται το σφάλμα τελικού προορισμού (FDE) στο σύνολο των μονοπατιών, ομαδοποιημένα στις προαναφερθείσες κλάσεις.



Εικόνα 4. 16 Σφάλμα τελικού προορισμού ανά κατηγορία κίνησης

Παρατηρείται ότι το μοντέλο έχει σαφή προτίμηση στην κατηγορία των πεζών, όπου η κατανομή του σφάλματος τελικού προορισμού είναι πολύ πιο κοντά στο μηδέν σε σχέση με τις δύο άλλες κλάσεις. Το ίδιο συμβαίνει και για το μέσο σφάλμα του μονοπατιού εξόδου (ADE).



Εικόνα 4. 17 Μέσο Σφάλμα πρόβλεψης μονοπατιού ανά κατηγορία κίνησης

Στον πίνακα 4.4 βλέπουμε συγκεντρωτικά τις μετρικές σφάλματος ανά κατηγορία κίνησης

Κατηγορία	Σφάλμα προορισμού (FDE)	Μέσο Σφάλμα (ADE)
Πεζοί	0.47	0.28
Οχήματα	1.94	1.09
Ακίνητοι	1.91	1.04

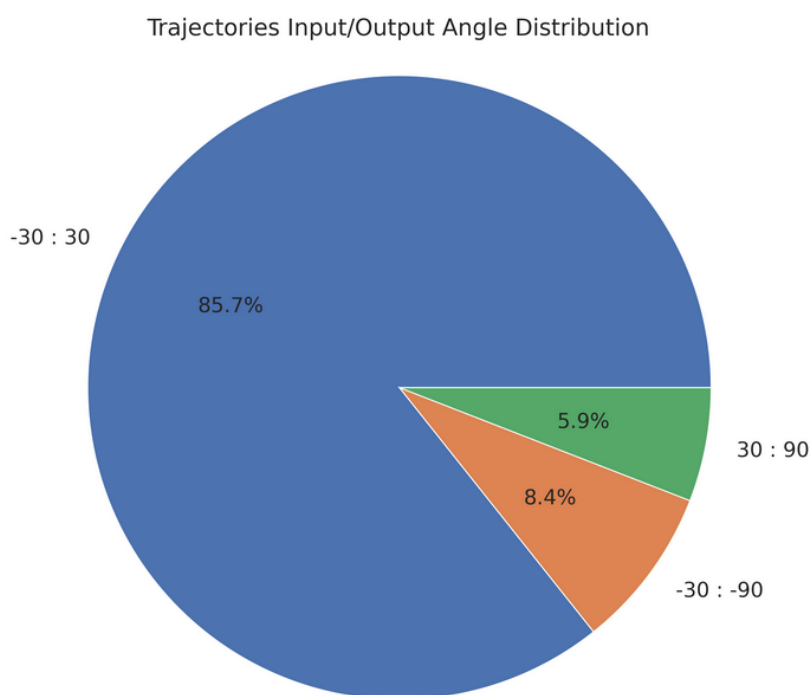
Πίνακας 4. 4 Μετρικές αξιολόγησης ανά κατηγορία κίνησης

Γίνεται, λοιπόν, αντιληπτό ότι η κατηγορία κίνησης ενός πράκτορα (πεζός, όχημα, ακίνητος) είναι καθοριστικός παράγοντας για την επίδοση του μοντέλου. Αξιοσημείωτο είναι δε, ότι το σφάλμα στην κατηγορία των ακίνητων (immobiles) είναι αυξημένο σε σχέση με την κατηγορία των πεζών, παρόλο που είναι θεωρητικά πιο εύκολο να προβλεφθεί ένα ακίνητο μονοπάτι. Μια πιθανή εξήγηση για αυτό, είναι ότι αυτά τα στιγμιότυπα υπο - εκπροσωπούνται στο σύνολο δεδομένων, καταλαμβάνοντας λιγότερο από 1% του συνόλου.

4.4.2 Η επίδραση της αλλαγής κατεύθυνσης

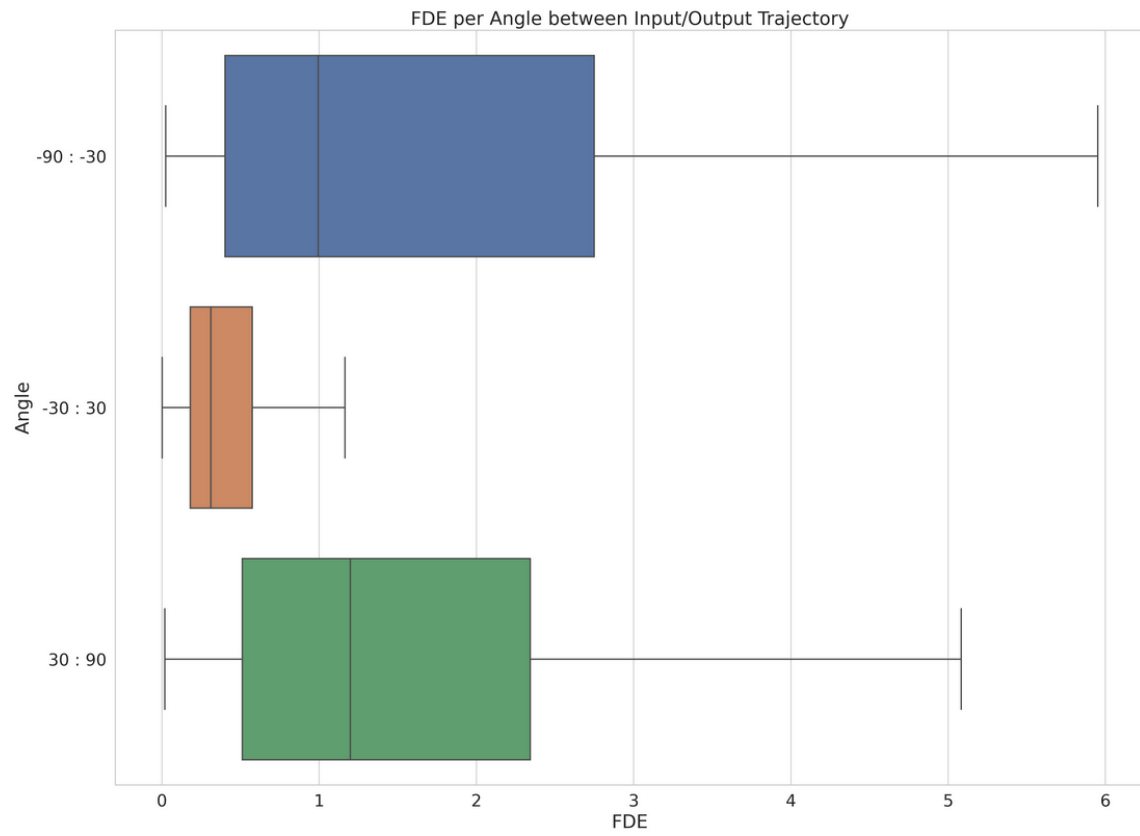
Ένας άλλος παράγοντας που φάνηκε να επηρεάζει την επίδοση των μοντέλων, είναι η απότομες αλλαγές κατεύθυνσης που παρουσιάζουν τα μονοπάτια. Συγκεκριμένα, και όπως είναι αναμενόμενο να συμβεί, όταν το μονοπάτι εισόδου παρουσιάζει μεγάλη αλλαγή πορείας με το μονοπάτι εξόδου, το μοντέλο δυσκολεύεται να προβλέψει σωστά, καθώς το μονοπάτι εισόδου δεν μπορεί να προϋδεάσει ότι θα ακολουθήσει στροφή στα επόμενα βήματα.

Το παρακάτω γράφημα αποδεικνύει ακριβώς πόσο σημαντικός είναι αυτός ο παράγοντας, παρουσιάζοντας την κατανομή των σφαλμάτων, όχι ανά κατηγορία κίνησης, αλλά ως προς τη γωνία αυτή. Δημιουργούνται για αυτό το σκοπό τρεις “κλάσεις” γωνιών, μία από -90 έως -30 μοίρες, μία από -30 έως 30 και μία από 30 έως 90. Στην παρακάτω εικόνα φαίνεται η κατανομή των μονοπατιών σε αυτές τις κλάσεις.




Εικόνα 4. 18 Κατανομή μονοπατιών ανάλογα τη μεταβολή στη διεύθυνση κίνησης

Όπως αναμένεται, τα μονοπάτια με μεγάλη γωνία (μεγαλύτερη από 30 μοίρες ανεξαρτήτως κατεύθυνσης) είναι σαφώς τα λιγότερα και καταλαμβάνουν κάτω από 15% του συνόλου. Τα αποτελέσματα για το σφάλμα τελικού προορισμού παρουσιάζονται στην εικόνα 28.



Εικόνα 4. 19 Σφάλμα πρόβλεψης τελικού προορισμού ανάλογα τη γωνία

Στην εικόνα 29 βλέπουμε την αντίστοιχη κατανομή για το μέσο σφάλμα του μονοπατιού εξόδου (ADE).



Εικόνα 4. 20 Μέσο Σφάλμα πρόβλεψης μονοπατιού ανάλογα τη γωνία

Στον πίνακα 4.5 παρουσιάζονται συγκεντρωτικά οι μετρικές σφάλματος για ανά κλάση.

Γωνία (μοίρες)	Σφάλμα προορισμού (FDE)	Μέσο Σφάλμα (ADE)
-90: -30	2.67	1.32
30: 90	2.12	1.07
-30: 30	0.52	0.32

Πίνακας 4. 5 Μετρικές αξιολόγησης ανά κατηγορία γωνίας

Είναι φανερό και σε αυτή την περίπτωση, ότι το μοντέλο ευνοείται πολύ περισσότερο από μονοπάτια της κατηγορίας που υπερσχύει, δηλαδή για γωνίες έως 30 μοίρες, παρά το γεγονός πως οι άλλες δύο κλάσεις αντιπροσωπεύουν σημαντικό ποσοστό του συνόλου (14%). Αυτό συμβαίνει διότι το μονοπάτι εισόδου, το οποίο είναι το μόνο που διαθέτει το μοντέλο για να προβεί σε πρόβλεψη, δεν περιέχει κάποιου είδους πληροφορία για την αλλαγή κατεύθυνσης που πρόκειται να συμβεί.

4.5 Υπολογιστική πολυπλοκότητα

Σε αυτή την παράγραφο συγκρίνονται οι αρχιτεκτονικές ως προς τον αριθμό των παραμέτρων εκπαίδευσης. Είναι ευνόητο ότι ο αριθμός των παραμέτρων επηρεάζει τόσο τη μνήμη που καταναλώνει το μοντέλο κατά την εκπαίδευση, όσο και το χρόνο που θα διαρκέσει η διαδικασία της εκπαίδευσης (αν και η τελευταία εξαρτάται και από τα χαρακτηριστικά του μηχανήματος στο οποίο εκτελείται). Το μεγάλο πλεονέκτημα της προτεινόμενης μεθοδολογίας, είναι ότι μπορεί να υλοποιηθεί σε σύγχρονο υπολογιστή και να εκπαιδευτεί σε διάστημα λίγων λεπτών, ενώ οι άλλες δύο αρχιτεκτονικές έχουν μεγάλες απαιτήσεις σε μνήμη και χρειάζεται τουλάχιστον μια κάρτα Γραφικών (GPU) σύγχρονης τεχνολογίας για να ολοκληρωθεί η διαδικασία της εκπαίδευσης σε διάστημα λίγων ημερών. Αυτό παρουσιάζεται στον πίνακα 4.6.

Model	Number of parameters	Ratio to GRU
GRU	43.736	1x
Social GAN	4.008.387	92x
Transformer	44.156.667	1010x

Πίνακας 4. 6 Σύγκριση αριθμού παραμέτρων των αρχιτεκτονικών

Όπως φαίνεται στον πίνακα 6, η προτεινόμενη αρχιτεκτονική μειώνει την υπολογιστική πολυπλοκότητα όπως μετράται από τον αριθμό των παραμέτρων κατά παράγοντα 100 και 1000 από το Social GAN και το Transformer αντίστοιχα.

Κεφάλαιο 5 Συμπεράσματα

Ο στόχος της παρούσας διπλωματικής ήταν να μελετηθούν τεχνικές βαθιάς μάθησης για το πρόβλημα της πρόβλεψης της πορείας ενός πράκτορα κίνησής. Εξετάστηκαν δυο state-of-the-art αρχιτεκτονικές καθώς και μια προτεινόμενη της οποίας βασικός στόχος ήταν η μείωση της υπολογιστικής πολυπλοκότητας χωρίς απώλεια στην προβλεπτική ικανότητα. Μετά την παρουσίαση των αποτελεσμάτων και την πειραματική αξιολόγηση των τριών διαφορετικών αρχιτεκτονικών, μπορούμε να συνοψίσουμε τα συμπεράσματα που εξήχθησαν από όλη τη διαδικασία.

Αρχικά, μπορούμε να συμπεράνουμε ότι η προτεινόμενη μεθοδολογία είναι **κατάλληλη** για το συγκεκριμένο πρόβλημα. Είναι σημαντικό ότι και στα δύο σύνολα δεδομένων καταφέρνει να εκπαιδεύεται σωστά και να έχει παρόμοια επίδοση. Ακόμα πιο σημαντικό είναι ότι καταφέρνει να έχει αυτή την επίδοση μειώνοντας δραματικά την **υπολογιστική πολυπλοκότητα** της υλοποίησης, με τις συνολικές υπερ- παραμέτρους να είναι ένα κλάσμα των παραμέτρων εκπαίδευσης των άλλων δύο συγκρινόμενων αρχιτεκτονικών (βλέπε πίνακα 6) αλλά και όλων των σύγχρονων βαθιών αρχιτεκτονικών που προτείνονται για αυτό το πρόβλημα, με αποτέλεσμα η διαδικασία εκπαίδευσης να είναι εντυπωσιακά **ταχύτερη**. Αυτό είναι ένα αξιολογικό χαρακτηριστικό της μεθοδολογίας, καθώς της προσφέρει τεράστιο πλεονέκτημα σε εφαρμογές που απαιτούν συχνές επανεκπαιδεύσεις του μοντέλου πρόβλεψης με τη συσσώρευση όλο και περισσότερων νέων δεδομένων.

Επιπρόσθετα, συμπεραίνουμε ότι το πρώτο μοντέλο σύγκρισης, το Social GAN, δεν πετυχαίνει συγκρίσιμα αποτελέσματα στα δύο σύνολα δεδομένων, γεγονός που μαρτυρά ότι πέρα από επανεκπαίδευση χρειάζεται και εκ νέου πειραματισμό για τη βελτιστοποίηση των παραμέτρων στα νέα δεδομένα. Αντίθετα, το μοντέλο Transformer πετυχαίνει συγκρίσιμα αποτελέσματα και στα δύο σύνολα δεδομένων, γεγονός που καταδεικνύει ότι είναι μια πιο «στιβαρή» αρχιτεκτονική.

Όσον αφορά τη σύγκριση του Transformer και του GRU, παρατηρούμε, τόσο από το συγκεντρωτικό διάγραμμα της εικόνας 3, όσο και από τη διδιάστατη απεικόνιση των μονοπατιών στο υπο- κεφάλαιο 5.3, ότι το Transformer υπερσχύει και μάλιστα σημαντικά στις προβλέψεις του κατά τα πρώτα βήματα του μονοπατιού εξόδου. Στη συνέχεια, όμως, το σφάλμα του αυξάνεται σημαντικά. Αντίθετα, η προτεινόμενη υλοποίηση, αν και στα πρώτα βήματα έχει σημαντικό σφάλμα (~20cm το μέσο σφάλμα πρόβλεψης του πρώτου βήματος), έχει πολύ πιο σταθερή επίδοση στα επόμενα βήματα, πετυχαίνοντας σημαντικά μικρότερο σφάλμα τελικής μετατόπισης (48% βελτίωση στο σύνολο δεδομένων προσομοίωσης) αλλά και μέσο σφάλμα μετατόπισης (29% βελτίωση στο σύνολο δεδομένων προσομοίωσης).

Τέλος, μέσα από την ανάλυση των αποτελεσμάτων το προτεινόμενου μοντέλου, έχουμε μια πιο σαφή εικόνα όσον αφορά την επίδραση των δεδομένων και της κατανομής τους στην τελική επίδοση του μοντέλου (βλέπε παράγραφο 5.4). Συγκεκριμένα, το σφάλμα που πετυχαίνει στα μονοπάτια που αφορούν την κλάση των πεζών (80.4% των δεδομένων) είναι αισθητά μικρότερο σε σχέση με την κλάση των αυτοκινήτων. Το ίδιο φαινόμενο παρατηρείται και εάν κατηγοριοποιήσουμε τα μονοπάτια με ένα άλλο χαρακτηριστικό, αυτό της γωνίας

που σχηματίζουν οι διευθύνσεις του αρχικού και τελικού σημείου των μονοπατιών εισόδου και εξόδου. Συγκεκριμένα, μονοπάτια στα οποία δε μεταβάλλεται περισσότερο από 30 μοίρες η διεύθυνση κίνησης του μονοπατιού εξόδου σε σχέση με αυτό της εισόδου (85.7% των δεδομένων), το μοντέλο καταφέρνει να προβλέψει το μονοπάτι εξόδου με πολύ μεγαλύτερη επιτυχία, από μονοπάτια που παρουσιάζουν σημαντική στροφή (>30 μοίρες) από την είσοδο στην έξοδο.

Βιβλιογραφία

- [1] S. Becker, R. Hug, W. Hübner and M. Arens, *An evaluation of trajectory prediction approaches and notes on the trajnet benchmark*. Fraunhofer Institute for Optronics, System Technologies, and Image Exploitation IOSB Gutleuthausstr, 2018.
- [2] K. Cho, D. Bahdanau, B. van Merriënboer, F. Bougares, Y. Bengio and C. Gulcehre, *Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation*, EMNLP, 2014, doi: 1406.1078v3.
- [3] H. Jiang, L. Chang, Q. Li and D. Chen, *Trajectory Prediction of Vehicles Based on Deep Learning*, 4th International Conference on Intelligent Transportation Engineering (ICITE), 2019, pp. 190-195, doi: 10.1109/ICITE.2019.8880168
- [4] Hochreiter, Sepp and Jürgen Schmidhuber. “LSTM can Solve Hard Long Time Lag Problems.” NIPS (1996).
- [5] D. Helbing and P. Molnar, *Social force model for pedestrian dynamics*. Physical review E, 1995, 51(5):4282.
- [6] A. Robicquet, A. Sadeghian, A. Alahi, S. Savarese et al, *Learning Social Etiquette: Human Trajectory Understanding In Crowded Scenes*. ECCV, 2016.
- [7] A. Alahi et al., *Social LSTM: Human Trajectory Prediction in Crowded Spaces*. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) : 961-971, 2016.
- [8] A. Gupta, J. Johnson, L. Fei-Fei, S. Savarese, A. Alahi, *Social GAN: Socially Acceptable Trajectories with Generative Adversarial Networks*, IEEE/CVF Conference on Computer Vision and Pattern Recognition: 2255-2264, 2018.
- [9] A. Vaswani et al., *Attention is All you Need*, NIPS, 2017
- [10] J. Devlin, M. Chang, K. Lee, K. Toutanova, *BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding.* NAACL-HLT, 2019
- [11] S. Khan, et al, *Transformers in Vision: A Survey*, arXiv:2101.01169, 2021
- [12] F. Giuliari, I. Hasan, M. Cristani, F. Galasso, *Transformer Networks for Trajectory Forecasting*. 25th International Conference on Pattern Recognition (ICPR), 2021, doi: 10335-10342.
- [13] C. Yu, X. Ma, J. Ren, H. Zhao, S. Yi, *Spatio-Temporal Graph Transformer Networks for Pedestrian Trajectory Prediction*. ECCV, 2020
- [14] K. Choet et al, *Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation*. EMNLP: 1724-1734, 2014
- [15] R. Jozefowicz, W. Zaremba, I. Sutskever, *An Empirical Exploration of Recurrent Network Architectures*. ICML, 2015
- [16] J. Chung, C. Gulcehre, K. Cho, Y. Bengio, *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling*, NIPS, Deep Learning and Representation Learning Workshop, 2014
- [17] Goodfellow, Ian J. et al. “Generative Adversarial Nets.” NIPS (2014).
- [18] Bahdanau, D., Cho, K., & Bengio, Y. (2015). Neural Machine Translation by Jointly Learning to Align and Translate. CoRR, abs/1409.0473.
- [19] D. Krajzewicz, G. Hertkorn, P. Wagner, C. Rossel, *SUMO (Simulation of Urban Mobility) – An open source traffic simulation*, 4th Middle East Symposium on Simulation and Modelling, 2002
- [20] P. Lopez, M. Behrish, L. Bieker-Walz, J. Erdmann, Y. Flotterod, R. Hilbrich, L. Lucken, J. Rummel, P. Wagner, E. Wiesner, *Microscopic Traffic Simulation using SUMO*. ITSC, 2018
- [21] K. Maeda, T. Umedu, H. Yamaguchi, K. Yasumoto, T. Higashino, *MobiREAL: Scenario Generation and Toolset ofr MANET Simulation with Realistic Node Mobility*. IEEE MDM, 2006
- [22] D. Towsley, *Mobility Models for Wireless Networks: Challenges, Pitfalls, Successes*, IEEE Workshop on Principles of Advanced and Distributed Simulation, 2008

- [23] M.G. Beiro, L. Bravo, D. Caro, C. Cattuto, L.Ferres, E. Graells-Garrido, *Shopping mall attraction and social mixing at a city scale*, EPJ Data Science 7-28, 2018
- [24] A.Galati, K. Djemame, C.Greenhalgh, *A mobility model for shopping mall environments founded on real traces*, NetSci, 2013
- [25] "IncellisIM" [Computer software], Retrieved from <http://www.incelligent.net>, 2021
- [26] Lu, Zhiping & Qu, Yunying & Qiao, Shubo, *Reference Ellipsoid and the Geodetic Coordinate System*, Geodesy. Springer, Berlin, Heidelberg, 2014. https://doi.org/10.1007/978-3-642-41245-5_5
- [27] H. Butler, M. Daly, A. Doyle, S. Gillies, S. Hagen, T. Schaub, "The GeoJSON Format", RFC 7946, 2016
- [28] Andreas Ess, Bastian Leibe, Luc Van Gool, *Depth and Appearance for Mobile Scene Analysis*. IEEE 11th International Conference on Computer Vision (2007): 1-8.
- [29] A. Lerner, Y. Chrysanthou, D. Lischinski, *Crowds by Example*. Computer Graphics Forum 26, 2007

Κατάλογος Πινάκων

Πίνακας 4. 1 Αποτελέσματα στο δημόσιο dataset ETH/UCY	31
Πίνακας 4. 2: Αποτελέσματα στο δημόσιο dataset ETH/UCY	32
Πίνακας 4. 3 Αποτελέσματα των 2 επικρατέστερων μοντέλων στο Incellisim dataset για το σενάριο 12/8	35
Πίνακας 4. 4 Μετρικές αξιολόγησης ανά κατηγορία κίνησης.....	46
Πίνακας 4. 5 Μετρικές αξιολόγησης ανά κατηγορία γωνίας	49
Πίνακας 4. 6 Σύγκριση αριθμού παραμέτρων των αρχιτεκτονικών	50

Κατάλογος Εικόνων

Εικόνα 2.1 Σχηματική αναπαράσταση του νευρώνα ενός αναδρομικού δικτύου	13
Εικόνα 2.2 Η αναδρομική μονάδα ενός απλού RNN	14
Εικόνα 2.3 Η αναδρομική μονάδα ενός LSTM.....	15
Εικόνα 2. 4 Η αναδρομική μονάδα ενός GRU	16
Εικόνα 2.5 Η αρχιτεκτονική Κωδικοποιητή – Αποκωδικοποιητή	17
Εικόνα 3. 1 Η αρχιτεκτονική του Social GAN	22
Εικόνα 3 2 Η αρχιτεκτονική του Trajectory Transformer	24
Εικόνα 3.3 Η αρχιτεκτονική της προτεινόμενης μεθοδολογίας GRU with Attention	25
Εικόνα 3.4 Στιγμιότυπα από τον προσομοιωτή με τις περιοχές κίνησης(δρόμοι, πάρκινγκ, σημεία συγκέντρωσης πεζών)	28
Εικόνα 4.1 Αποτελέσματα στο δημόσιο dataset ETH/UCY (bar plot)	32
Εικόνα 4. 2 Αποτελέσματα στο simulated dataset (bar plot)	33
Εικόνα 4.3 Σφάλμα προβλέψεων των 2 επικρατέστερων μοντέλων για το σενάριο 8/12.....	34
Εικόνα 4.4 Σφάλμα προβλέψεων των 2 επικρατέστερων μοντέλων για το σενάριο 12/8.....	35
Εικόνα 4.5 Ενδεικτικό μονοπάτι με επιτυχημένες προβλέψεις και από τα 2 επικρατέστερα μοντέλα	37
Εικόνα 4.6 Ενδεικτικό μονοπάτι με επιτυχημένες προβλέψεις και από τα 2 επικρατέστερα μοντέλα	38
Εικόνα 4.7 Ενδεικτικό μονοπάτι με επιτυχημένες προβλέψεις και από τα 2 επικρατέστερα μοντέλα	38
Εικόνα 4.8 Ενδεικτικό μονοπάτι με αποτυχημένες προβλέψεις και από τα 2 επικρατέστερα μοντέλα	39
Εικόνα 4.9 Ενδεικτικό μονοπάτι με αποτυχημένες προβλέψεις και από τα 2 επικρατέστερα μοντέλα	39
Εικόνα 4.10 Ενδεικτικό μονοπάτι με αποτυχημένες προβλέψεις και από τα 2 επικρατέστερα μοντέλα	40
Εικόνα 4.11 Ενδεικτικό μονοπάτι όπου το Transformer προβλέπει καλύτερα το μονοπάτι εξόδου από το προτεινόμενο μοντέλο	41
Εικόνα 4.12 Ενδεικτικό μονοπάτι όπου το προτεινόμενο μοντέλο προβλέπει καλύτερα το μονοπάτι εξόδου από το Transformer	41
Εικόνα 4.13 Ενδεικτικό μονοπάτι όπου το προτεινόμενο μοντέλο προβλέπει καλύτερα το μονοπάτι εξόδου από το Transformer	42

Εικόνα 4. 14 Ενδεικτικό μονοπάτι όπου το προτεινόμενο μοντέλο προβλέπει καλύτερα το μονοπάτι εξόδου από το Transformer	42
Εικόνα 4. 15 Κατανομή πρακτόρων κίνησης σε πεζούς, οχήματα και ακίνητους.....	44
Εικόνα 4. 16 Σφάλμα τελικού προορισμού ανά κατηγορία κίνησης.....	45
Εικόνα 4. 17 Μέσο Σφάλμα πρόβλεψης μονοπατιού ανά κατηγορία κίνησης.....	46
Εικόνα 4. 18 Κατανομή μονοπατιών ανάλογα τη μεταβολή στη διεύθυνση κίνησης.....	47
Εικόνα 4. 19 Σφάλμα πρόβλεψης τελικού προορισμού ανάλογα τη γωνία	48
Εικόνα 4. 20 Μέσο Σφάλμα πρόβλεψης μονοπατιού ανάλογα τη γωνία.....	49