

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ
Σχολή Χρηματοοικονομικής και Στατιστικής



Τμήμα Στατιστικής και Ασφαλιστικής Επιστήμης

**ΜΕΤΑΠΤΥΧΙΑΚΟ ΠΡΟΓΡΑΜΜΑ ΣΠΟΥΔΩΝ
ΣΤΗΝ ΕΦΑΡΜΟΣΜΕΝΗ ΣΤΑΤΙΣΤΙΚΗ**

**ΠΡΟΣΟΜΟΙΩΣΗ ΠΟΛΥΔΙΑΣΤΑΤΩΝ
ΔΕΔΟΜΕΝΩΝ ΚΙΝΗΣΗΣ ΜΕ
ΤΕΧΝΙΚΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ**

Θεόδωρος Γκότσε

Διπλωματική Εργασία

που υποβλήθηκε στο Τμήμα Στατιστικής και
Ασφαλιστικής Επιστήμης του Πανεπιστημίου Πειραιώς
ως μέρος των απαιτήσεων για την απόκτηση του
Μεταπτυχιακού Διπλώματος Ειδίκευσης στην
Εφαρμοσμένη Στατιστική

Πειραιάς
Μάρτιος 2026

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ
Σχολή Χρηματοοικονομικής και Στατιστικής



Τμήμα Στατιστικής και Ασφαλιστικής Επιστήμης

ΜΕΤΑΠΤΥΧΙΑΚΟ ΠΡΟΓΡΑΜΜΑ ΣΠΟΥΔΩΝ
ΣΤΗΝ ΕΦΑΡΜΟΣΜΕΝΗ ΣΤΑΤΙΣΤΙΚΗ

ΠΡΟΣΟΜΟΙΩΣΗ ΠΟΛΥΔΙΑΣΤΑΤΩΝ
ΔΕΔΟΜΕΝΩΝ ΚΙΝΗΣΗΣ ΜΕ
ΤΕΧΝΙΚΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

Θεόδωρος Γκότσε

Διπλωματική Εργασία

που υποβλήθηκε στο Τμήμα Στατιστικής και
Ασφαλιστικής Επιστήμης του Πανεπιστημίου Πειραιώς
ως μέρος των απαιτήσεων για την απόκτηση του
Μεταπτυχιακού Διπλώματος Ειδίκευσης στην
Εφαρμοσμένη Στατιστική

Πειραιάς
Μάρτιος 2026

Η παρούσα Διπλωματική Εργασία εγκρίθηκε ομόφωνα από την Τριμελή Εξεταστική Επιτροπή που ορίστηκε από τη ΓΣΕΣ του Τμήματος Στατιστικής και Ασφαλιστικής Επιστήμης του Πανεπιστημίου Πειραιώς στην υπ' αριθμ. συνεδρίασή του σύμφωνα με τον Εσωτερικό Κανονισμό Λειτουργίας του Προγράμματος Μεταπτυχιακών Σπουδών στην Εφαρμοσμένη Στατιστική

Τα μέλη της Επιτροπής ήταν:

- Καθηγητής Πελέκης Νικόλαος (Επιβλέπων)
- Καθηγητής Θεοδωρίδης Ιωάννης
- Αναπληρωτής Καθηγητής Πικράκης Άγγελος

Η έγκριση της Διπλωματικής Εργασίας από το Τμήμα Στατιστικής και Ασφαλιστικής Επιστήμης του Πανεπιστημίου Πειραιώς δεν υποδηλώνει αποδοχή των γνώμων του συγγραφέα.

UNIVERSITY OF PIRAEUS
School of Finance and Statistics



Department of Statistics and Insurance Science

**POSTGRADUATE PROGRAM IN
APPLIED STATISTICS**

**SIMULATION OF MULTIPLE-ASPECT
TRAJECTORIES WITH MACHINE
LEARNING METHODS**

By

Theodoros Gkotse

MSc Dissertation

submitted to the Department of Statistics and
Insurance Science of the University of Piraeus in
partial fulfilment of the requirements for the degree of
Master of Science in Applied Statistics

Piraeus, Greece
March 2026

Ευχαριστίες

Το τέλος της συγκεκριμένης εργασίας συμπίπτει με το τέλος των μεταπτυχιακών μου σπουδών και σηματοδοτεί το κλείσιμο ενός μεγάλου κεφαλαίου για εμένα, καθώς έθεσε τις βάσεις για την επαγγελματική μου σταδιοδρομία.

Θα ήθελα να ευχαριστήσω όλους τους καθηγητές του πανεπιστημίου, που μου πρόσφεραν ο καθένας ξεχωριστά ένα σημαντικό κομμάτι γνώσεων. Θα ήθελα επίσης να ευχαριστήσω ιδιαίτερα τον επιβλέποντα καθηγητή μου, κ. Νικόλαο Πελέκη, ο οποίος μου έδωσε την ευκαιρία να ασχοληθώ με ένα αντικείμενο με ενδιαφέρουσες εφαρμογές και σημαντικές πληροφορίες.

Τέλος, θα ήθελα να ευχαριστήσω όλους τους συγγραφείς των βιβλιογραφικών πηγών, που μου προσέφεραν μια βαθύτερη και πιο καθαρή ματιά στον κόσμο των δεδομένων.

Περίληψη

Η ραγδαία αύξηση στη συλλογή και αξιοποίηση δεδομένων κίνησης, όπως δεδομένων από GPS, αισθητήρες και εφαρμογές κινητών συσκευών, έχει δημιουργήσει την ανάγκη για την παραγωγή συνθετικών, αλλά και ρεαλιστικών δεδομένων που αναπαριστούν την ανθρώπινη ή αντικειμενική κινητικότητα στον χώρο και τον χρόνο.

Η παρούσα διπλωματική εργασία επικεντρώνεται στη μελέτη και πειραματική αξιολόγηση τεχνικών μηχανικής μάθησης για την προσομοίωση πολυδιάστατων, σημασιολογικά επαυξημένων δεδομένων κίνησης.

Συγκεκριμένα, εξετάζονται μέθοδοι που στοχεύουν στη δημιουργία συνθετικών δεδομένων τροχιάς με ρεαλιστικά χαρακτηριστικά, διατηρώντας τόσο τη χωρική και χρονική συνοχή όσο και τις σημασιολογικές ιδιότητες που συχνά συνοδεύουν τέτοια δεδομένα (όπως ο τύπος οντότητας, δραστηριότητες ή σημεία ενδιαφέροντος).

Η εργασία εστιάζει στην αποδοτικότητα, την ακρίβεια και τη γενικευσιμότητα των μοντέλων προσομοίωσης, με στόχο την υποστήριξη ερευνητικών σεναρίων, δοκιμών και ανάλυσης κινητικότητας χωρίς εξάρτηση από πραγματικά, ευαίσθητα ή δυσεύρετα δεδομένα τροχιάς.

Abstract

The rapid growth in the collection and utilization of trajectory data, such as data derived from GPS, sensors, and mobile applications, has created the need for the generation of synthetic yet realistic data that represent human or object mobility across space and time.

This diploma thesis focuses on the study and experimental evaluation of machine learning techniques for the simulation of multidimensional, semantically enriched movement data. More specifically, it examines methods that aim to generate synthetic trajectory data with realistic characteristics, while preserving both spatial and temporal coherence as well as the semantic properties that often accompany such data, such as entity type, activities, or points of interest.

The thesis emphasizes the efficiency, accuracy, and generalizability of simulation models, with the objective of supporting research scenarios, testing procedures, and mobility analysis without relying on real, sensitive, or hard-to-obtain trajectory data.

Περιεχόμενα

Κεφάλαιο 1: Εισαγωγή.....	17
1.1 Σημασία παραγωγής δεδομένων τροχιάς.....	17
1.2 Περιγραφή και στόχοι εφαρμογών	17
1.3 Δομή Εργασίας.....	18
Κεφάλαιο 2: Δεδομένα Τροχιάς.....	20
2.1 Ορισμός δεδομένων τροχιάς.....	20
2.2 Τύποι Δεδομένων Τροχιάς: Dense, Sparse, Aggregated	21
2.3 Χαρακτηριστικά Τροχιών: Χωρικά, Χρονικά, Θεματικά.....	23
2.4 Πηγές και Μέθοδοι Συλλογής Δεδομένων τροχιάς.....	25
2.5 Προκλήσεις στην Άμεση Χρήση Δεδομένων Τροχιάς.....	28
Κεφάλαιο 3: Παραδοσιακές Τεχνικές Προσομοίωσης Δεδομένων Τροχιάς.....	31
3.1 Εισαγωγή.....	31
3.2 Στοχαστικά Μοντέλα: Οι πρώτες προσεγγίσεις.....	32
3.2.1 Ο αλγόριθμος GSTD.....	32
3.2.1.2 GSTD2: Semantics-based trajectories.....	35
3.2.2 Oporto: γεννήτρια ρεαλιστικών σεναρίων κίνησης.....	38
3.3 Προσομοιώσεις με Περιορισμούς Δικτύου.....	42
3.3.1 Ο Brinkhoff Generator (Network-based moving objects)	42
3.3.2 BerlinMOD.....	46
3.3.3 Hermoupolis.....	47
3.4 MMC (Mobility Markov Chain)	52
ΚΕΦΑΛΑΙΟ 4 : Μοντέλα Παραγωγής Συνθετικών Τροχιών με Βάση τη Μηχανική Μάθηση....	55
4.1 Knowledge-driven vs data-driven.....	55
4.2 Generative Adversarial Network (GAN).....	56
4.2.1 Συνθετικές Τροχιές με GANs.....	58
4.2.2 IGMM-GAN.....	62
4.2.3 Two-Stage GAN.....	65
4.2.4 LSTM-TrajGAN	71
4.2.5 TS-TrajGen: Παραγωγή συνεχών τροχιών με Two-Stage GAN	75
4.3 Mobility GPT	78
4.4 TrajGail.....	82
4.5 EETG-SVAE.....	89

ΚΕΦΑΛΑΙΟ 5 Εφαρμογή	94
5.1.Dataset.....	94
5.2. Προεπεξεργασία για Pretraining.....	95
5.3 1ο Στάδιο:Προεκπαίδευση road-level generator.....	98
5.4 2ο Στάδιο Region Level generator.....	104
5.5 Adversarial Learning.....	111
5.6 Τελική παραγωγή τροχιών στο test set.....	115
ΚΕΦΑΛΑΙΟ 6 Συμπεράσματα και Προτάσεις για Μελλοντική Έρευνα	118
6.1 Συμπεράσματα.....	118
6.2 Μελλοντικές Κατευθύνσεις.....	119
Αναφορές.....	120

ΚΑΤΑΛΟΓΟΣ ΣΧΗΜΑΤΩΝ

Σχήμα 1 Πλεονεκτήματα και Μειονεκτήματα για Dense Τροχιές	22
Σχήμα 2 Πλεονεκτήματα και Μειονεκτήματα για Sparse Τροχιές	23
Σχήμα 3 Πλεονεκτήματα και Μειονεκτήματα για Aggregated Τροχιές	23
Σχήμα 4: Παράδειγμα ρύθμισης παραμέτρων του GSTD	33
Σχήμα 5: Υποδομή (Infrastructure)	37
Σχήμα 6: Κίνηση με εμπόδια: πυκνή υποδομή (dense infrastructure)	38
Σχήμα 7: Αλληλεπιδράσεις έλξης/άπωσης στο σενάριο Oporto	40
Σχήμα 8: Παράδειγμα οπτικοποίησης εξόδου του Brinkhoff generator	45
Σχήμα 9: Δομή πίνακα αναφοράς (report table) για semantic trajectories στο Hermoupolis.	51
Σχήμα 10: Βασική αρχιτεκτονική GAN:	57
Σχήμα 11: Σύγκριση GANS με προηγούμενα μοντέλα.....	60
Σχήμα 12: Αξιολόγηση Σχετικής Σημασιολογίας Τροχιών	61
Σχήμα 13: Συνολική αρχιτεκτονική του IGMM-GAN.....	62
Σχήμα 14: Σύγκριση πραγματικών και συνθετικών τροχιών IGMM-GAN.	64
Σχήμα 15: Παραδείγματα ανώμαλων τροχιών που ανιχνεύονται μέσω της Mahalanobis	65
Σχήμα 16: Διάγραμμα της αρχιτεκτονικής Two-Stage GAN	66
Σχήμα 17: Διαδικασία εξαγωγής χωρικών χαρακτηριστικών του οδικού δικτύου.....	68
Σχήμα 18: Αρχιτεκτονική συμμετρικού LSTM στο δευτερο στάδιο GAN	69
Σχήμα 19: Κατανομή μήκους ακολουθίας διαδρομών	70
Σχήμα 20: Εξέλιξη της Jensen–Shannon Divergence (JSD)	71
Σχήμα 21: Κωδικοποίηση χωροχρονικών δεδομένων τροχιάς σε πίνακα.....	72
Σχήμα 22: Η αρχιτεκτονική νευρωνικού δικτύου του μοντέλου LSTM-TrajGAN.....	73
Σχήμα 23: Αρχιτεκτονική TS-TrajGen	76
Σχήμα 24: Επισκόπηση του πλαισίου MobilityGPT για παραγωγή συνθετικών τροχιών	79
Σχήμα 25: Σχήμα κατασκευής του fine-tuning dataset για Reinforcement Learning.....	81
Σχήμα 26 POMDP	84
Σχήμα 27: Πλαίσιο μοντέλου TrajGAIL	85
Σχήμα 28: Σχήμα backpropagation του TrajGAIL	87
Σχήμα 29 Αρχιτεκτονική EETG-SVAE	91
Σχήμα 30: Map Matched Dataset Porto Taxi	95
Σχήμα 31: Οδικό δίκτυο .geo και .rel.....	96
Σχήμα 32: adjacent list και rid_gps.....	97
Σχήμα 33: Pretraining δεδομένα	98
Σχήμα 34: Χαρακτηριστικά δρόμου	99
Σχήμα 35: Accuracy/Loss GAT-FC	101
Σχήμα 36: Accuracy/Loss GFC	103
Σχήμα 37: Region Δεδομένα	107
Σχήμα 38: Region Pretrain Inputs	108
Σχήμα 39: Χαρακτηριστικά Regions	109
Σχήμα 40: Region Μετρικές Accuracy/Loss	110
Σχήμα 41: Μετρικές 1 ^ο Σταδίου GAN	113
Σχήμα 42: Μετρικές 2 ^ο Σταδίου GANS	114

Σχήμα 43: Ενδεικτική οπτική σύγκριση πραγματικής και παραγόμενης τροχιάς.....	117
---	-----

Κεφάλαιο 1: Εισαγωγή

1.1 Σημασία παραγωγής δεδομένων τροχιάς

Διάφοροι αισθητήρες GPS και φορητές συσκευές συλλέγουν συνεχώς τεράστιες ποσότητες δεδομένων τοποθεσίας, γεγονός που έχει στρέψει την προσοχή σε δεδομένα χωροχρονικού τύπου όπως οι τροχίες (trajectories). Αυτά τα δεδομένα χρησιμοποιούνται για ανάλυση κυκλοφοριακής συμφόρησης, ανάλυση συμπεριφοράς διαδρομών, εξατομικευμένες συστάσεις διαδρομής κ.ά. Επιπλέον, στον τομέα της αυτόνομης οδήγησης, η συνθετική δημιουργία πορειών χρησιμοποιείται ευρέως στον σχεδιασμό διαδρομών και την πρόβλεψη πιθανών μελλοντικών κινήσεων.

Ωστόσο, η απόκτηση μεγάλων συνόλων δεδομένων παραμένει δύσκολη λόγω των θεμάτων προστασίας της ιδιωτικότητας για εταιρείες και ιδιώτες, παρόλο που παράγεται τεράστιος όγκος δεδομένων πορείας με διάφορους τρόπους. Γι' αυτό τον λόγο, έχουν γίνει προσπάθειες για τη δημιουργία δεδομένων τροχιάς με παρόμοια χαρακτηριστικά.

1.2 Περιγραφή και στόχοι εφαρμογών

Οι εφαρμογές των συνθετικών τροχιών (τεχνικά παραγόμενα δεδομένα κίνησης) είναι εξαιρετικά χρήσιμες για την αξιολόγηση και δοκιμή αλγορίθμων, την εξομοίωση συμπεριφορών σε μεγάλης κλίμακας σενάρια απαντώντας σε ερωτήματα όπως τι θα συνέβαινε στην κυκλοφορία αν άλλαζε κάτι σε έναν δρόμο και την προστασία της ιδιωτικότητας των χρηστών καθώς αποφεύγονται τα δεδομένα που μπορούν να ταυτοποιήσουν πραγματικά πρόσωπα. Ιδιαίτερο ενδιαφέρον παρουσιάζουν τα πολυδιάστατα, σημασιολογικά εμπλουτισμένα συνθετικά δεδομένα, τα οποία περιλαμβάνουν χωρικά, χρονικά και θεματικά χαρακτηριστικά και επιτρέπουν πιο ακριβή και ευέλικτη ανάλυση της κινητικότητας.

Η παρούσα εργασία επικεντρώνεται στη μελέτη και στην πειραματική αξιολόγηση τεχνικών μηχανικής μάθησης για την παραγωγή ρεαλιστικών συνθετικών δεδομένων κίνησης. Η προσομοίωση στοχεύει να αναπαράγει τόσο τα φυσικά χαρακτηριστικά της κίνησης (όπως χωρικές μετατοπίσεις και χρονικές ακολουθίες) όσο και τις σημασιολογικές

πληροφορίες που συνδέονται με αυτή, όπως τον τύπο της δραστηριότητας ή το σημείο ενδιαφέροντος στο οποίο αυτή σχετίζεται.

Στο πλαίσιο αυτό, θα αναλυθούν και θα συγκριθούν διαφορετικές αρχιτεκτονικές παραγωγικών μοντέλων (generative models), με έμφαση σε σύγχρονες τεχνικές όπως τα γενετικά νευρωνικά δίκτυα (GANs), τα αναδρομικά δίκτυα (LSTM), καθώς και χρονικά ευαίσθητα μοντέλα, οι Transformers. Η συγκριτική μελέτη στοχεύει να αποτιμήσει την ακρίβεια, τη χρησιμότητα και τις δυνατότητες των παραγόμενων δεδομένων σε σχέση με πραγματικές τροχιές.

1.3 Δομή Εργασίας

Προχωρώντας στη δομή της εργασίας, αρχικά γίνεται εισαγωγή στο αντικείμενο της μελέτης και παρουσιάζεται το βασικό πρόβλημα. Αναλύονται οι εφαρμογές των συνθετικών τροχιών, διατυπώνονται οι στόχοι καθώς περιγράφεται συνοπτικά και η δομή της εργασίας.

Το Κεφάλαιο 2 επικεντρώνεται στα δεδομένα τροχιάς (trajectories): παρουσιάζονται οι ορισμοί και οι κύριοι τύποι τους (dense, sparse, aggregated), τα χωρικά/χρονικά/θεματικά χαρακτηριστικά, οι πηγές και μέθοδοι συλλογής, καθώς και οι βασικές προκλήσεις που προκύπτουν κατά την άμεση αξιοποίησή τους σε εφαρμογές.

Το Κεφάλαιο 3 καλύπτει τις παραδοσιακές τεχνικές προσομοίωσης και τους γεννήτορες με περιορισμούς οδικού δικτύου. Παρουσιάζονται ενδεικτικά στοχαστικές/σεναριακές προσεγγίσεις (GSTD/GSTD2, Oporto), network-constrained generators (Brinkhoff, BerlinMOD, Hermoupolis) και η προσέγγιση MMC (Mobility Markov Chain), με έμφαση στις υποθέσεις, στα πλεονεκτήματα και στους περιορισμούς κάθε μεθόδου.

Στο Κεφάλαιο 4 παρουσιάζονται μοντέλα παραγωγής συνθετικών τροχιών με βάση τη Μηχανική Μάθηση και τη Βαθιά Μάθηση. Αρχικά συζητείται η διάκριση knowledge-driven και data-driven προσεγγίσεων, και στη συνέχεια αναλύονται αντιπροσωπευτικές κατηγορίες και μοντέλα όπως GAN-based μέθοδοι (π.χ. Two-Stage GAN, TS-TrajGen), ακολουθιακά μοντέλα, Transformers (MobilityGPT), adversarial imitation learning (TrajGAIL) και υβριδικές αρχιτεκτονικές (EETG-SVAE).

Το Κεφάλαιο 5 αποτελεί την εφαρμοσμένη μελέτη (case study) και περιγράφει την υλοποίηση του pipeline TS-TrajGen στο dataset Porto-Taxi: παρουσιάζονται τα δεδομένα και τα βήματα προεπεξεργασίας, η προεκπαίδευση του road-level generator, το region-level στάδιο, το adversarial learning, καθώς και η τελική παραγωγή τροχιών στο test set και η αξιολόγηση των παραγόμενων δειγμάτων με κατάλληλες μετρικές ομοιότητας.

Κεφάλαιο 2: Δεδομένα Τροχιάς

2.1 Ορισμός δεδομένων τροχιάς

Τα δεδομένα κίνησης, γνωστά και ως δεδομένα τροχιάς (trajectory data), αναφέρονται σε πληροφορίες που περιγράφουν την κίνηση ενός φυσικού αντικειμένου ή ατόμου στον χώρο και στον χρόνο. Κάθε τέτοιο σύνολο δεδομένων αποτελείται από μια ακολουθία χωροχρονικών σημείων, τα οποία περιλαμβάνουν γεωγραφικές συντεταγμένες όπως, γεωγραφικό πλάτος και μήκος, αλλά και χρονικές σημάνσεις (ημερομηνία και ώρα). Για παράδειγμα, μπορούμε να φανταστούμε τη διαδρομή που ακολουθεί ένα αυτοκίνητο στην πόλη: κάθε φορά που το GPS του καταγράφει τη θέση του, δημιουργείται ένα σημείο τροχιάς. Όλα αυτά τα σημεία μαζί, με τη σωστή σειρά, σχηματίζουν την τροχιά του.

Πιο συγκεκριμένα, μια τροχιά μπορεί να αναπαρασταθεί γενικά ως:

$$T = p_1, p_2, \dots, p_n$$

όπου κάθε σημείο p_k (με $k = 1, 2, \dots, n$) αντιστοιχεί σε μια καταγραφή της θέσης σε κάποια χρονική στιγμή.

Κάθε σημείο p_k αποτελείται από τέσσερα βασικά στοιχεία:

$$p_k = (id_k, loc_k, t_k, A_k)$$

- id_k : Ένα μοναδικό αναγνωριστικό για το σημείο, ώστε να μπορούμε να το ξεχωρίσουμε από τα υπόλοιπα.
- loc_k (location): Η χωρική θέση του σημείου, δηλαδή οι γεωγραφικές συντεταγμένες. Αυτές μπορεί να είναι συντεταγμένες πλάτους και μήκους από GPS (π.χ. (38.245, 21.735)), ή άλλα είδη αναφοράς όπως cellID από GSM δίκτυο κινητής τηλεφωνίας.
- t_k (timestamp): Η χρονική στιγμή κατά την οποία έγινε η καταγραφή του σημείου, π.χ. 2025-07-29 14:35:00.
- A_k (attributes): Προαιρετικά πρόσθετα χαρακτηριστικά που συνοδεύουν το σημείο. Αυτά μπορεί να είναι η ταχύτητα του αντικειμένου, η κατεύθυνση, αν υπήρξε

στάση, ακόμα και πληροφορίες όπως ο τύπος του οχήματος ή η δραστηριότητα του χρήστη εκείνη τη στιγμή.

Αξίζει να σημειωθεί ότι η συγκεκριμένη δομή έχει υιοθετηθεί ευρέως στη διεθνή βιβλιογραφία γιατί επιτρέπει την οργάνωση των τροχιακών δεδομένων με τρόπο που να είναι εύκολος στην ανάλυση, την επεξεργασία και την αξιοποίηση από αλγορίθμους μηχανικής μάθησης. Τέτοιου είδους δεδομένα χρησιμοποιούνται πλέον σε ένα ευρύ φάσμα εφαρμογών, όπως στην πλοήγηση (π.χ. Google Maps), στην ανάλυση κυκλοφορίας, στη μελέτη τουριστικών συμπεριφορών, ακόμα και στην παρακολούθηση άγριων ζώων για οικολογικούς σκοπούς.

Συνολικά, τα δεδομένα τροχιάς αποτελούν τον πυρήνα για τη μελέτη της κινητικότητας, τόσο σε ατομικό όσο και σε συλλογικό επίπεδο. Η δυνατότητα καταγραφής και ανάλυσής τους παρέχει στις σύγχρονες τεχνολογίες ένα πολύ ισχυρό εργαλείο για την κατανόηση της κίνησης μέσα στον φυσικό και κοινωνικό χώρο.

2.2 Τύποι Δεδομένων Τροχιάς: Dense, Sparse, Aggregated

Η ταξινόμηση των δεδομένων τροχιάς γίνεται συνήθως με βάση το πόσο συχνά και πόσο αναλυτικά καταγράφονται οι πληροφορίες σχετικά με την κίνηση. Με άλλα λόγια, έχει να κάνει με τη χωρική και χρονική πυκνότητα των σημείων που συνθέτουν την τροχιά. Ανάλογα με αυτή την πυκνότητα, στη βιβλιογραφία διακρίνονται τρεις βασικές κατηγορίες τροχιακών δεδομένων: dense (πυκνά), sparse (αραιά) και aggregated (συγκεντρωτικά).

a) Dense Δεδομένα Τροχιάς (Πυκνά):

Τα dense ή πυκνά δεδομένα τροχιάς χαρακτηρίζονται από υψηλή χωροχρονική ανάλυση. Αυτό σημαίνει ότι η καταγραφή των σημείων γίνεται σε πολύ μικρά χρονικά διαστήματα (π.χ. κάθε 1–5 δευτερόλεπτα) και με υψηλή γεωγραφική ακρίβεια (μέσω GPS). Τέτοια δεδομένα συνήθως συλλέγονται από συσκευές που διαθέτουν δέκτη GPS, όπως:

- smartphones με ενεργοποιημένη λειτουργία τοποθεσίας,
- συσκευές παρακολούθησης σε οχήματα (π.χ. ταξί, φορτηγά),
- wearables (π.χ. smartwatches, fitness trackers).

Παράδειγμα χρήσης: Μια εφαρμογή καταγραφής ποδηλασίας (όπως το Strava) μπορεί να καταγράφει κάθε 2 δευτερόλεπτα τη θέση του χρήστη. Έτσι δημιουργείται μια λεπτομερής απεικόνιση της διαδρομής, με πληροφορίες όπως ταχύτητα, ύψος και διάρκεια. Αυτά τα δεδομένα είναι πολύ χρήσιμα για εφαρμογές που απαιτούν μεγάλη ακρίβεια, όπως:

- ανάλυση κυκλοφορίας σε πραγματικό χρόνο,
- ανίχνευση μοτίβων καθημερινής μετακίνησης,
- πλοήγηση και χαρτογράφηση οδικού δικτύου.

Πλεονεκτήματα	Μειονεκτήματα
✓ Υψηλή ακρίβεια	✗ Απαιτούν μεγάλο αποθηκευτικό χώρο
✓ Πλήρης αναπαράσταση κίνησης	✗ Ενεργοβόρα για τις συσκευές
✓ Ιδανικά για ανάλυση συμπεριφοράς	✗ Περιορισμένη κάλυψη (συνήθως για λίγους χρήστες)

Σχήμα 1 Πλεονεκτήματα και Μειονεκτήματα για Dense Τροχιές

b) Sparse Δεδομένα Τροχιάς (Αραιά):

Σε αντίθεση με τα dense, τα sparse (αραιά) δεδομένα τροχιάς περιλαμβάνουν πολύ πιο αραιές καταγραφές, δηλαδή, τα σημεία της τροχιάς απέχουν χρονικά περισσότερο μεταξύ τους (π.χ. κάθε 15–30 λεπτά ή ακόμα και ώρες). Επιπλέον, τα σημεία ενδέχεται να προέρχονται από διαφορετικές τεχνολογίες, όπως:

- δίκτυα κινητής τηλεφωνίας (GSM/4G/5G), όπου η θέση εκτιμάται με βάση την κεραία κινητής στην οποία συνδέεται η συσκευή,
- Wi-Fi access points, που μπορούν να εντοπίσουν την παρουσία συσκευών,
- RFID ή Bluetooth beacons, που καταγράφουν τη διέλευση ατόμων ή αντικειμένων,
- check-ins ή γεω-εντοπισμένες αναρτήσεις σε μέσα κοινωνικής δικτύωσης (π.χ. Twitter, Facebook, Foursquare).

Πλεονεκτήματα	Μειονεκτήματα
✓ Χαμηλότερες απαιτήσεις αποθήκευσης	✗ Χαμηλή ακρίβεια θέσης
✓ Καλή κάλυψη σε μεγάλο πληθυσμό	✗ Δεν αποτυπώνεται πλήρως η διαδρομή
✓ Ιδανικά για μακρο-ανάλυση	✗ Περιορισμένη πληροφορία για την κίνηση

Σχήμα 2 Πλεονεκτήματα και Μειονεκτήματα για Sparse Τροχιές

c) Aggregated Δεδομένα Τροχιάς (Συγκεντρωτικά):

Η τρίτη κατηγορία είναι τα aggregated ή συγκεντρωτικά δεδομένα τροχιάς. Σε αυτή την περίπτωση δεν εξετάζουμε μεμονωμένες τροχιές, αλλά ομαδοποιημένες πληροφορίες από πολλούς χρήστες ή αντικείμενα. Η σύνοψη αυτή μπορεί να γίνει με διάφορους τρόπους:

- Κατά γεωγραφικά πλέγματα (π.χ. πόσοι πέρασαν από ένα συγκεκριμένο τετράγωνο της πόλης),
- Κατά χρονικά διαστήματα (π.χ. μέση ταχύτητα στην Εγνατία Οδό ανά ώρα),
- Κατά διαδρομές ή κατευθύνσεις (π.χ. ροές επιβατών από/προς σταθμούς μετρό).

Πλεονεκτήματα	Μειονεκτήματα
✓ Ανωνυμία και προστασία ιδιωτικότητας	✗ Απώλεια χωροχρονικής λεπτομέρειας
✓ Χρήσιμα για στατιστική και σχεδιασμό υποδομής	✗ Δεν επιτρέπουν εξατομικευμένη ανάλυση
✓ Μικρότερος όγκος δεδομένων	✗ Περιορισμένες εφαρμογές σε μικρή κλίμακα

Σχήμα 3 Πλεονεκτήματα και Μειονεκτήματα για Aggregated Τροχιές

2.3 Χαρακτηριστικά Τροχιών: Χωρικά, Χρονικά, Θεματικά

Η φύση των τροχιακών δεδομένων είναι πολυδιάστατη, καθώς κάθε τροχιά δεν καταγράφει μόνο τη θέση ενός αντικειμένου στον χώρο και στον χρόνο, αλλά περιλαμβάνει και ένα πλήθος από πρόσθετες πληροφορίες που μας βοηθούν να κατανοήσουμε καλύτερα τη συμπεριφορά του κινούμενου υποκειμένου.

Στη βιβλιογραφία, τα χαρακτηριστικά αυτά ομαδοποιούνται σε τρεις κύριες κατηγορίες: χωρικά, χρονικά και θεματικά. Κάθε μία από αυτές προσφέρει μια διαφορετική οπτική για την κίνηση, και η συνδυαστική τους ανάλυση οδηγεί σε πολύτιμα συμπεράσματα για πλήθος εφαρμογών, από έξυπνη κινητικότητα μέχρι κοινωνική ανάλυση.

a) Χωρικά Χαρακτηριστικά (Spatial Features): Τα χωρικά χαρακτηριστικά αφορούν τα γεωγραφικά δεδομένα της τροχιάς, δηλαδή το "πού" κινήθηκε ένα αντικείμενο.

Εδώ περιλαμβάνονται πληροφορίες όπως:

- Η διαδρομή που ακολουθήθηκε, η οποία μπορεί να αναπαρασταθεί ως μια σειρά από σημεία πάνω σε χάρτη.
- Το συνολικό μήκος της τροχιάς, δηλαδή η απόσταση που διανύθηκε από το πρώτο μέχρι το τελευταίο σημείο.
- Η μέση ταχύτητα, η οποία προκύπτει από τον λόγο της συνολικής απόστασης προς τον χρόνο διαδρομής.
- Η επιτάχυνση και επιβράδυνση, που δείχνουν αν και πώς αλλάζει η ταχύτητα καθ' όλη τη διάρκεια της κίνησης.
- Η γωνία στροφής, χρήσιμη για την ανάλυση οχημάτων (π.χ. αν ένα όχημα κάνει απότομες ή ομαλές στροφές).

b) Χρονικά Χαρακτηριστικά (Temporal Features):

Τα χρονικά χαρακτηριστικά επικεντρώνονται στο "πότε" πραγματοποιήθηκε η κίνηση και πώς εξελίχθηκε στον χρόνο. Περιλαμβάνουν:

- Το συνολικό χρονικό διάστημα της διαδρομής – από την αρχική καταγραφή έως την τελική.
- Οι στάσεις (stop events), δηλαδή τα χρονικά διαστήματα όπου το αντικείμενο δεν κινήθηκε (π.χ. το αυτοκίνητο ήταν παρκαρισμένο ή ο πεζός σταμάτησε σε καφετέρια).
- Η διάρκεια μεταξύ διαδοχικών σημείων, που επιτρέπει να εντοπίσουμε τυχόν καθυστερήσεις ή αλλαγές στον ρυθμό κίνησης.
- Περιοδικά μοτίβα, όπως μετακινήσεις που επαναλαμβάνονται σε συγκεκριμένες ώρες ή ημέρες της εβδομάδας (π.χ. πρωινή μετακίνηση προς εργασία, κυριακάτικη βόλτα).

c) Θεματικά Χαρακτηριστικά (Semantic/Contextual Features):

Τα θεματικά χαρακτηριστικά (ή σημασιολογικά/συμφραζόμενα) σχετίζονται με το "ποιος", "τι" και "γιατί" κινείται. Δεν αφορούν τη θέση ή τον χρόνο, αλλά το πλαίσιο στο οποίο συμβαίνει η μετακίνηση. Μπορεί να περιλαμβάνουν:

- Το είδος του κινούμενου αντικειμένου (άνθρωπος, ταξί, φορτηγό, ποδήλατο κ.λπ.).
- Την ταυτότητα ή το προφίλ του χρήστη, όπου είναι διαθέσιμο (π.χ. ηλικία, φύλο, ομάδα χρήστη).
- Τον σκοπό της μετακίνησης – αν πρόκειται για εργασία, ψυχαγωγία, ψώνια, σχολείο κ.ά.
- Το μέσο μεταφοράς (με τα πόδια, με αυτοκίνητο, με ποδήλατο, με λεωφορείο).
- Το κοινωνικό-οικονομικό ή πολιτιστικό πλαίσιο, όπως οι ώρες αιχμής, οι διακοπές ή εκδηλώσεις που επηρεάζουν τη μετακίνηση.

Η πλήρης αξιοποίηση των δεδομένων τροχιάς επιτυγχάνεται όταν τα χωρικά, χρονικά και θεματικά χαρακτηριστικά αναλύονται συνδυαστικά. Αυτή η ολιστική προσέγγιση επιτρέπει:

- Την κατανόηση της πραγματικής συμπεριφοράς των κινούμενων οντοτήτων,
- την βελτίωση του σχεδιασμού των πόλεων και των υποδομών μεταφοράς,
- την ανάπτυξη έξυπνων συστημάτων πρόβλεψης, όπως recommendation engines για μετακίνηση,
- την εφαρμογή μοντέλων μηχανικής μάθησης για την κατηγοριοποίηση, ομαδοποίηση ή προσομοίωση τροχιών.

2.4 Πηγές και Μέθοδοι Συλλογής Δεδομένων τροχιάς

Η καταγραφή της ανθρώπινης ή αντικειμενικής κίνησης στον χώρο και τον χρόνο αποτελεί σήμερα μια πολύτιμη διαδικασία, που συναντάται σε ποικίλες εφαρμογές της καθημερινότητας: από τις υπηρεσίες πλοήγησης, μέχρι την οργάνωση της κυκλοφορίας στις πόλεις και την κατανόηση της συμπεριφοράς καταναλωτών. Όλα αυτά βασίζονται σε

δεδομένα τροχιάς τα οποία, για να συλλεχθούν, απαιτούν συγκεκριμένες τεχνολογίες και μεθόδους. Σε αυτό το υποκεφάλαιο, εξετάζουμε με πιο απλό και ανθρώπινο τρόπο τις κύριες πηγές και τους τρόπους με τους οποίους συλλέγονται αυτά τα δεδομένα.

Οι πηγές συλλογής δεδομένων τροχιάς είναι πολλές και διαφορετικές. Άλλες είναι πιο ακριβείς, άλλες πιο προσβάσιμες, και κάποιες λειτουργούν διακριτικά στο παρασκήνιο. Ορισμένες από τις πιο βασικές πηγές είναι:

- GPS (Global Positioning System): Ίσως η πιο γνωστή και αξιόπιστη πηγή, καθώς σχεδόν όλα τα σύγχρονα κινητά τηλέφωνα, οχήματα και "έξυπνες" συσκευές διαθέτουν δέκτη GPS. Χάρη σε αυτό, μπορούμε να καταγράψουμε με μεγάλη ακρίβεια πού βρισκόμαστε, πότε και με ποια ταχύτητα κινούμαστε. Είναι η τεχνολογία πίσω από εφαρμογές όπως το Google Maps ή οι χάρτες οδήγησης.
- Δίκτυα κινητής τηλεφωνίας: Ακόμα και χωρίς GPS, το κινητό μας τηλέφωνο "συνδέεται" διαρκώς με κοντινές κεραίες κινητής τηλεφωνίας. Έτσι, μπορούμε να εντοπίσουμε τη γενική θέση ενός ατόμου, αν και με λιγότερη ακρίβεια. Αυτή η μέθοδος χρησιμοποιείται κυρίως για την παρακολούθηση μαζικών μετακινήσεων, όπως για τη διαχείριση κυκλοφορίας ή σε περιπτώσεις κρίσεων.
- Wi-Fi και Bluetooth: Σε χώρους όπως εμπορικά κέντρα, αεροδρόμια ή μουσεία, οι συσκευές μας συνδέονται αυτόματα με Wi-Fi ή ανταλλάσσουν σήματα μέσω Bluetooth. Μέσα από αυτά τα σήματα μπορεί να εντοπιστεί με ακρίβεια η θέση μας σε εσωτερικούς χώρους, όπου το GPS συχνά αποτυγχάνει.
- RFID και NFC τεχνολογίες: Σε περιβάλλοντα όπου η ακρίβεια έχει κρίσιμη σημασία (π.χ. αποθήκες, εργοστάσια ή μέσα μεταφοράς), χρησιμοποιούνται τεχνολογίες μικρής εμβέλειας όπως RFID (ραδιοσυχνότητες) ή NFC (επαφής). Αυτές μπορούν να "διαβάζουν" την παρουσία ενός αντικειμένου ή ατόμου όταν περνά από συγκεκριμένα σημεία.

- Μέσα κοινωνικής δικτύωσης και εφαρμογές: Πολλοί άνθρωποι μοιράζονται δημόσια την τοποθεσία τους μέσω check-ins, stories ή δημοσιεύσεων. Αν και αυτά τα δεδομένα είναι πιο "αραιά" (δεν καταγράφονται συνεχώς), δίνουν πολύτιμες πληροφορίες για τα μοτίβα μετακίνησης, τον σκοπό μιας διαδρομής και το κοινωνικό της πλαίσιο.
- Οχήματα με αισθητήρες: Πολλά επαγγελματικά οχήματα, όπως ταξί, φορτηγά ή λεωφορεία, φέρουν ενσωματωμένους αισθητήρες που καταγράφουν όχι μόνο τη θέση τους, αλλά και άλλες παραμέτρους, όπως κατανάλωση καυσίμου, επιτάχυνση ή απόσταση που διανύθηκε. Τα δεδομένα αυτά χρησιμοποιούνται συχνά για βελτιστοποίηση δρομολογίων.
- Δορυφορικά δεδομένα: Για ευρύτερη παρακολούθηση, όπως σε ναυσιπλοΐα ή περιβαλλοντική παρατήρηση, χρησιμοποιούνται εικόνες και δεδομένα από δορυφόρους, που μπορούν να εντοπίσουν τη θέση πλοίων, γεωργικών μηχανημάτων ή ακόμη και μετακινήσεις πληθυσμών σε μεγάλη κλίμακα.

Η συλλογή των δεδομένων τροχιάς δεν είναι πάντα ίδια. Υπάρχουν διαφορετικοί τρόποι με τους οποίους μπορεί να καταγράφεται η κίνηση ενός ατόμου ή αντικειμένου:

- Ενεργή καταγραφή: Ο χρήστης συμμετέχει συνειδητά, π.χ. μέσω εφαρμογών γυμναστικής ή πλοήγησης, που καταγράφουν τη διαδρομή του σε πραγματικό χρόνο. Είναι ο πιο άμεσος και ακριβής τρόπος συλλογής.
- Παθητική καταγραφή: Τα δεδομένα συλλέγονται χωρίς την άμεση συμμετοχή του χρήστη, για παράδειγμα όταν μια συσκευή συνδέεται αυτόματα σε Wi-Fi ή κεραία κινητής τηλεφωνίας. Ο τρόπος αυτός είναι πιο διακριτικός, αλλά προσφέρει λιγότερη λεπτομέρεια.
- Δειγματοληψία (sampling): Μερικές φορές, για λόγους εξοικονόμησης πόρων ή μπαταρίας, η συσκευή καταγράφει δεδομένα όχι συνεχώς, αλλά ανά συγκεκριμένα

χρονικά διαστήματα (π.χ. κάθε 5 λεπτά). Αυτό δημιουργεί πιο αραιές τροχιές, αλλά μπορεί να είναι επαρκές για πολλές εφαρμογές.

- Crowdsourcing (συλλογική καταγραφή): Δεδομένα συλλέγονται από πολλούς χρήστες, συχνά εθελοντικά, όπως στις εφαρμογές Waze ή Google Maps, όπου οι χρήστες προσφέρουν πληροφορίες για την κυκλοφορία, την ταχύτητα ή τις καθυστερήσεις.

Αρχεία καταγραφής (log files): Πολλοί οργανισμοί διατηρούν βάσεις δεδομένων με πληροφορίες κίνησης, όπως οι δημόσιες συγκοινωνίες (μέσω των έξυπνων καρτών επιβίβασης), ή τα εμπορικά καταστήματα μέσω των αισθητήρων στα καταστήματα.

Η επιλογή της πηγής και της μεθόδου συλλογής επηρεάζει καθοριστικά το είδος, την ακρίβεια και τη χρησιμότητα των δεδομένων που θα προκύψουν. Για παράδειγμα:

- Τα δεδομένα GPS είναι ιδανικά για ακριβή ανάλυση της πορείας ενός ατόμου.
- Τα δεδομένα από κινητά δίκτυα είναι χρήσιμα για να μελετήσουμε την κινητικότητα σε επίπεδο πόλης ή χώρας.
- Οι check-ins στα social media αποκαλύπτουν το κοινωνικό και σημασιολογικό πλαίσιο μιας διαδρομής, κάτι που το απλό GPS δεν μπορεί να δείξει.

Η επιλογή, επομένως, εξαρτάται από τις ανάγκες της κάθε μελέτης ή εφαρμογής: ακρίβεια, ανωνυμία, συχνότητα, κόστος, σκοπός χρήσης.

2.5 Προκλήσεις στην Άμεση Χρήση Δεδομένων Τροχιάς

Αν και η τεχνολογία μάς επιτρέπει σήμερα να συλλέγουμε δεδομένα τροχιάς πιο εύκολα από ποτέ μέσω κινητών τηλεφώνων, GPS, κοινωνικών δικτύων και αισθητήρων η επεξεργασία και αξιοποίησή τους δεν είναι μια απλή υπόθεση. Αντιθέτως, συνοδεύεται από πολλές προκλήσεις που σχετίζονται τόσο με τεχνικά ζητήματα, όσο και με ηθικά και νομικά ερωτήματα.

a) Ετερογένεια Πηγών και Δυσκολίες Ενοποίησης:

Μία από τις πρώτες δυσκολίες που προκύπτει είναι η ετερογένεια των πηγών δεδομένων. Δηλαδή, τα δεδομένα τροχιάς μπορεί να προέρχονται από διαφορετικές τεχνολογίες: GPS δέκτες, δίκτυα Wi-Fi, σήματα κινητής τηλεφωνίας (GSM), RFID συσκευές ή ακόμα και αναρτήσεις σε κοινωνικά δίκτυα. Καθεμία από αυτές τις πηγές έχει τα δικά της χαρακτηριστικά όσον αφορά:

- Τη μορφή των δεδομένων (format),
- τη συχνότητα καταγραφής (πυκνότητα),
- την ακρίβεια (π.χ. μέτρα ή χιλιόμετρα απόκλιση),
- και τη χρονική συνέπεια (πόσο αξιόπιστα είναι τα timestamps).

Όταν κάποιος προσπαθεί να συγκεντρώσει δεδομένα από διαφορετικές πηγές σε ένα κοινό αρχείο για ανάλυση, συχνά συναντά εμπόδια, καθώς δεν υπάρχει ενιαία δομή. Χρειάζεται λοιπόν κανονικοποίηση των δεδομένων, δηλαδή ένας τρόπος να μετατραπούν όλα σε κοινό μορμάτ, ώστε να μπορούν να επεξεργαστούν σωστά από ένα μοντέλο ή αλγόριθμο.

b) Θόρυβος και Ελλείψεις στα Δεδομένα:

Μια άλλη συχνή πρόκληση είναι ο θόρυβος στα δεδομένα. Για παράδειγμα, μια συσκευή GPS μπορεί να δώσει για λίγα δευτερόλεπτα λανθασμένη θέση, ειδικά σε περιοχές με κτήρια ή κακή λήψη. Επίσης, μπορεί να λείπουν σημεία από την τροχιά λόγω προσωρινής απώλειας σήματος ή σφάλματος καταγραφής. Αυτά τα προβλήματα κάνουν τα δεδομένα μη αξιόπιστα αν δεν υποβληθούν πρώτα σε επεξεργασία.

Για να βελτιώσουμε την ποιότητά τους, χρησιμοποιούνται τεχνικές καθαρισμού και εξομάλυνσης. Ένα κλασικό παράδειγμα είναι το φίλτρο Kalman, το οποίο "μαλακώνει" την τροχιά ώστε να αφαιρούνται τα ακραία ή απίθανα σημεία. Επίσης, η τεχνική του map-matching βοηθά στο να ευθυγραμμιστούν τα σημεία με πραγματικούς δρόμους ή μονοπάτια, βασισμένο στους χάρτες. Έτσι, ακόμη και αν κάποια σημεία είναι ανακριβή, μπορούμε να τα "διορθώσουμε" με βάση τη λογική της διαδρομής.

c) Ζητήματα Ιδιωτικότητας και Ηθικής:

Ίσως η πιο ευαίσθητη πρόκληση αφορά την προστασία της ιδιωτικότητας των χρηστών. Ειδικά όταν μιλάμε για τροχιές ανθρώπων, το ζήτημα γίνεται πολύ σοβαρό.

Ακόμα και αν δεν καταγράφεται το όνομα ή το τηλέφωνο κάποιου, η ίδια η διαδρομή του μπορεί να αποκαλύψει πολλά: πού μένει, πού δουλεύει, τι ώρα φεύγει από το σπίτι του, ποιες διαδρομές προτιμά, κ.λπ.

Αυτό σημαίνει ότι η ανωνυμοποίηση των δεδομένων δεν είναι πάντα αρκετή. Υπάρχουν αλγόριθμοι που μπορούν να αναγνωρίσουν μοτίβα κίνησης και να εντοπίσουν την ταυτότητα ενός ατόμου μόνο από τις διαδρομές του. Γι' αυτό, η χρήση τέτοιων δεδομένων πρέπει να γίνεται με αυστηρή τήρηση κανονισμών προστασίας προσωπικών δεδομένων, όπως ο GDPR στην Ευρωπαϊκή Ένωση. Ερευνητές και εταιρείες οφείλουν να λαμβάνουν ειδική συγκατάθεση και να εφαρμόζουν τεχνικές απόκρυψης ταυτότητας, όπως spatial cloaking ή data generalization.

d) Υπολογιστικές Απαιτήσεις και Κλιμάκωση:

Τέλος, υπάρχει και το πρακτικό αλλά εξίσου σημαντικό ζήτημα της κλιμάκωσης. Τα δεδομένα τροχιάς μπορούν να είναι τεράστια σε όγκο, ειδικά όταν προέρχονται από χιλιάδες ή εκατομμύρια συσκευές (π.χ. στόλος ταξί ή όλοι οι χρήστες ενός app). Η ανάλυση αυτών των δεδομένων, ειδικά όταν εμπλέκονται ταυτόχρονα χωρικά, χρονικά και θεματικά χαρακτηριστικά, απαιτεί πολύ ισχυρά υπολογιστικά συστήματα.

Σε τέτοιες περιπτώσεις χρησιμοποιούνται συχνά καταναεμημένα υπολογιστικά περιβάλλοντα (όπως το Apache Spark ή Hadoop) που μπορούν να επεξεργαστούν μεγάλα σύνολα δεδομένων παράλληλα. Ωστόσο, αυτό απαιτεί και εξειδικευμένες γνώσεις, καθώς και σημαντικούς πόρους σε υποδομές.

Παρότι τα δεδομένα τροχιάς έχουν τεράστια δυναμική και αξία, η χρήση τους δεν είναι καθόλου αυτονόητη. Η συλλογή, ο καθαρισμός, η ενοποίηση, η προστασία της ιδιωτικότητας και η επεξεργασία σε μεγάλη κλίμακα αποτελούν σημαντικές προκλήσεις που πρέπει να αντιμετωπιστούν με υπευθυνότητα και τεχνογνωσία. Μόνο έτσι μπορούμε να αξιοποιήσουμε τα πλεονεκτήματα της κινητικότητας με τρόπο που να είναι τεχνικά ορθός, κοινωνικά δίκαιος και επιστημονικά χρήσιμος.

Κεφάλαιο 3: Παραδοσιακές Τεχνικές Προσομοίωσης Δεδομένων Τροχιάς.

3.1 Εισαγωγή

Η ανάγκη για τη μελέτη και κατανόηση της ανθρώπινης κινητικότητας υπήρχε πολύ πριν την εμφάνιση των σύγχρονων τεχνικών μηχανικής μάθησης. Πώς κινούνται άνθρωποι και αντικείμενα μέσα στον χώρο και τον χρόνο; Πώς μπορούμε να αναπαραστήσουμε αυτές τις κινήσεις με τέτοιο τρόπο ώστε να τις μελετήσουμε, να τις προβλέψουμε ή και να τις αναπαραγάγουμε τεχνητά;

Αυτά τα ερωτήματα αποτέλεσαν τον πυρήνα της επιστημονικής αναζήτησης σε διάφορους τομείς, από τις χωρικές βάσεις δεδομένων και τη γεωπληροφορική, μέχρι την τεχνητή νοημοσύνη και την επιστήμη των δεδομένων. Στην πορεία αυτής της εξέλιξης, η προσομοίωση τροχιών δεν εμφανίστηκε απλώς ως ένα εργαλείο βοηθητικό, αλλά ως απαραίτητη προϋπόθεση για την έρευνα. Όταν δεν υπάρχουν επαρκή πραγματικά δεδομένα, τα συνθετικά δεδομένα μάς δίνουν τη δυνατότητα να "πειραματιστούμε" με ασφάλεια.

Από τα τέλη της δεκαετίας του 90, με εργαλεία όπως ο GSTD, η επιστημονική κοινότητα άρχισε να πειραματίζεται με τη δημιουργία συνθετικών δεδομένων, εκεί όπου η πρόσβαση σε πραγματικές τροχιές ήταν περιορισμένη. Στην πορεία, οι απαιτήσεις άλλαξαν, δεν αρκούσε πια η κίνηση ως γεωμετρικό ίχνος, ζητήθηκε περιεχόμενο, πρόθεση και νόημα. Έτσι, αναπτύχθηκαν πιο σύνθετοι γεννήτορες όπως ο Brinkhoff, το BerlinMOD και το Hermoupolis, MMC που ενσωμάτωσαν στοιχεία συμπεριφοράς και περιβάλλοντος. Σήμερα, με τις μεθόδους της μηχανικής μάθησης, παράγονται δεδομένα που δεν προκύπτουν απλώς από προκαθορισμένους κανόνες, αλλά μαθαίνουν και διαμορφώνονται από τα ίδια τα δεδομένα.

Σκοπός του παρόντος κεφαλαίου είναι η παρουσίαση της ιστορικής εξέλιξης των τεχνικών παραγωγής συνθετικών δεδομένων τροχιάς. Μέσα από την ανάλυση χαρακτηριστικών γεννητόρων και προσεγγίσεων, επιχειρείται η κατανόηση των σταδίων ωρίμανσης του

πεδίου, καθώς και η μετάβαση από γεωμετρικά και στοχαστικά μοντέλα σε σημασιολογικά και data-driven συστήματα.

3.2 Στοχαστικά Μοντέλα: Οι πρώτες προσεγγίσεις

3.2.1 Ο αλγόριθμος GSTD

Στα τέλη της δεκαετίας του '90, η ερευνητική κοινότητα είχε αρχίσει να ασχολείται εντατικά με το ζήτημα της αποδοτικής διαχείρισης χωροχρονικών δεδομένων. Όμως ένα βασικό πρόβλημα ήταν κοινό σε όλα σχεδόν τα σχετικά έργα, δεν υπήρχαν διαθέσιμα ανοιχτά σύνολα δεδομένων που να επιτρέπουν πειραματισμό και επαναληψιμότητα των αποτελεσμάτων.


Για την αξιολόγηση τεχνικών πρόσβασης σε χωροχρονικές βάσεις δεδομένων, οι Theodoridis et al. [**Error! Reference source not found.**] προτείνουν τον GSTD (Generate Spatio Temporal Data), μια γεννήτρια συνθετικών χωροχρονικών συνόλων δεδομένων. Χωρίς κοινά και ελεγχόμενα datasets, είναι δύσκολο να συγκρίνουμε με σταθερό και επαναλήψιμο τρόπο διαφορετικές δομές δεικτοδότησης και αλγορίθμους ανάκτησης για δεδομένα κίνησης.

Οι συγγραφείς υιοθετούν διακριτό ορισμό χωροχρονικού αντικειμένου ως σύνολο από στιγμιότυπα (instances) της μορφής (o_id, s_i, t_i) , όπου o_id είναι το αναγνωριστικό του αντικειμένου (object id), s_i είναι το spacestamp (η χωρική πληροφορία) και t_i το timestamp (η χρονική στιγμή). Με βάση αυτή τη διακριτή αναπαράσταση, ένας κινούμενος 2D point αντιστοιχεί σε γραμμή στον χώρο (x, y, t) , ενώ μια κινούμενη περιοχή, που περιγράφεται με MBR, αντιστοιχεί σε ένα “στερεό” σώμα στον ίδιο χώρο.

Ο GSTD παράγει για κάθε αντικείμενο tuples της μορφής:

$$(o_id, t, p_l, p_u)$$

όπου p_l και p_u είναι τα κάτω-αριστερά / πάνω-δεξιά σημεία του MBR (Minimum Bounding Rectangle). Σε ορισμένες περιγραφές/υλοποιήσεις εμφανίζεται και flag εγκυρότητας (validity flag) για περιπτώσεις εκτός ορίων.



Σχήμα 4: Παράδειγμα ρύθμισης παραμέτρων του GSTD και ενδεικτικά snapshots της παραγόμενης κίνησης.[Error! Reference source not found.]

- $distr_init = \text{Gaussian}(0.5, 0.1)$: Οι αρχικές θέσεις (κέντρα) δειγματοληπτούνται κοντά στο κέντρο του workspace, με μικρή διασπορά.
- $interval = \text{Gaussian}(0, 0.5)$ (με περιορισμό σε $[\min_t, \max_t]$): Το χρονικό βήμα Δt μεταξύ διαδοχικών instances ακολουθεί κανονική κατανομή (με αποκοπή στα επιτρεπτά όρια).
- $\Delta center[x] = \text{Uniform}(0, 0.3)$: Μετατόπιση στον άξονα x από 0 έως 0.3 ανά βήμα.
- $\Delta center[y] = \text{Uniform}(0, 0)$: Μηδενική μετατόπιση στον $y \rightarrow$ κίνηση μόνο οριζόντια (προς $+x$).
- $\Delta extent[x], \Delta extent[y] = \text{Uniform}(0, 0)$: Σταθερό μέγεθος (ή $extent=0$ στην περίπτωση point dataset).

Ρυθμίζοντας τα όρια/κατανομές του $\Delta center[]$ ελέγχουμε την κατεύθυνση, ενώ ο ρυθμός εξέλιξης στον χρόνο επηρεάζεται από το $interval$. Έτσι ο GSTD επιτρέπει τη σύνθεση ελεγχόμενων κινητικών σεναρίων για benchmarking. Στο Σχήμα 4, επειδή $\Delta center[y]=0$, τα snapshots δείχνουν νέφος σημείων που μετατοπίζεται σταδιακά προς τα δεξιά, ενώ η αρχική συγκέντρωση γύρω από το κέντρο προκύπτει από το $distr_init$.

Το παραπάνω παράδειγμα αποτυπώνει τον πυρήνα του GSTD: η τροχιά προκύπτει ως εξέλιξη ενός αρχικού instance (o_id, s_1, t_1) μέσω τριών βασικών λειτουργιών/μεταβολών:

- **duration**: μεταβολή χρόνου μεταξύ διαδοχικών instances (παραμέτρος $interval$)
- **shift**: μετατόπιση χωρικής θέσης (παραμέτρος $\Delta center$)
- **resizing**: μεταβολή μεγέθους (παραμέτρος $\Delta extent$, εφαρμόσιμη σε regions)

Εννοιολογικά, οι σχέσεις εξέλιξης γράφονται ως:

$$t_i = t_{i-1} + \text{interval}_i, \quad s_i.\text{center} = s_{i-1}.\text{center} + \Delta\text{center}_i, \quad s_i.\text{extent} = s_{i-1}.\text{extent} + \Delta\text{extent}_i.$$

Οι τιμές των `interval`, `Δcenter[ ]`, `Δextent[ ]` παράγονται από τυχαίους αριθμούς της μορφής `RNG(distr, min, max)`: δειγματοληψία σε προκαθορισμένα όρια `[min,max]` ακολουθώντας μια επιλεγμένη κατανομή (π.χ. `uniform`, `gaussian`, `skewed`)

Το `workspace` ορίζεται τυπικά ως μοναδιαίο τετράγωνο $[0,1]^2$ και ο χρόνος στο $[0,1]$. Ο χρήστης ρυθμίζει (μεταξύ άλλων) την αρχική πληθικότητα `N`, την “πυκνότητα” `D` (για `rectangles`), το `numsnapshots`, καθώς και τα `min/max` για `interval`, `Δcenter`, `Δextent` και τις αντίστοιχες κατανομές. Έτσι, ο `GSTD` μπορεί να παράγει διαφορετικά σενάρια (κατευθυνόμενα ή τυχαία, πιο “αργά” ή πιο “γρήγορα”, `points` ή `moving rectangles`) απλώς αλλάζοντας τις κατανομές και τα όρια δειγματοληψίας.

Κατά την εξέλιξη μπορεί να προκύψουν θέσεις εκτός του `workspace`. Ο `GSTD` εισάγει τρεις εναλλακτικές πολιτικές χειρισμού `invalid instances`:

- `radar`: διατηρεί συντεταγμένες (αν και εκτός ορίων) και επισημαίνει την `invalidity`· η επόμενη εξέλιξη βασίζεται σε αυτές, άρα ο αριθμός “ορατών” αντικειμένων σε `snapshots` μπορεί να μεταβάλλεται.
- `adjustment`: προσαρμόζει τις συντεταγμένες (π.χ. με γραμμική παρεμβολή) ώστε να “χωρούν” στο `workspace`.
- `toroid`: θεωρεί το χώρο τοροειδή (`wrap-around`): όταν το αντικείμενο περνά μία πλευρά, επανεμφανίζεται από την απέναντι.

Παρότι το `interval` καθορίζει το εσωτερικό χρονικό βήμα μεταξύ `instances`, ο `GSTD` οργανώνει την έξοδο με βάση μια επιθυμητή χρονική ανάλυση μέσω του `numsnapshots` (με `step=1/numsnapshots`). Η συνάρτηση `print_instance` ελέγχει αν ο χρόνος του τρέχοντος `instance` έχει υπερβεί το `next_snapshot` και, αν ναι, εκτυπώνει το προηγούμενο `instance` (`old_instance`) με κατάλληλο `timestamp` και αναπροσαρμόζει το `next_snapshot`. Έτσι αποφεύγεται η εκτύπωση της πλήρους κατάστασης σε κάθε `snapshot` (που θα οδηγούσε σε

$T = N \cdot \text{numsnapshots tuples}$), και εκτυπώνονται μόνο τα απαραίτητα tuples ώστε να αναπαραχθεί η κίνηση, μειώνοντας τον συνολικό όγκο εξόδου ($T' \ll T$).

Ο GSTD δεν στοχεύει σε “ακρίβεια” ως προς πραγματικές τροχιές, αλλά αναδεικνύει ότι μπορεί να παράγει ποικιλία ελεγχόμενων σεναρίων μέσω ρύθμισης κατανομών/ορίων και επιλογής πολιτικών εγκυρότητας. Το βασικό του πλεονέκτημα είναι η παραμετροποίηση και η αναπαραγωγικότητα, που τον καθιστούν κατάλληλο εργαλείο benchmarking.

3.2.1.2 GSTD2: Semantics-based trajectories

Παρότι ο GSTD παρέχει ελεγχόμενη παραγωγή χωροχρονικών datasets, οι Pfoser & Theodoridis (2003) [6] επισημαίνουν ότι πολλά σενάρια πραγματικού κόσμου απαιτούν “σημασιολογικά” χαρακτηριστικά κίνησης, όπως direction, speed και agility, καθώς και χωρικούς περιορισμούς που προκύπτουν από το δομημένο περιβάλλον. Για τον σκοπό αυτό προτείνουν το GSTD2, ως επέκταση του GSTD που επιτρέπει τη δημιουργία semantics-based trajectories, δηλαδή τροχιών που προσεγγίζουν πιο ρεαλιστικές συμπεριφορές (κατευθυνόμενη κίνηση, ομαδικές ροές, αποφυγή εμποδίων).

Ο πυρήνας του GSTD παραμένει ο ίδιος ($\text{interval}, \Delta c[], \Delta \text{ext}[]$), όμως το GSTD2 οργανώνει τη ρύθμιση των παραμέτρων έτσι ώστε να “χαρτογραφεί” εννοιολογικές έννοιες κίνησης σε συγκεκριμένες επιλογές δειγματοληψίας:

- Direction: προκύπτει από το εύρος του $\Delta c[]$ (π.χ. $\Delta c[x] > 0$ και $\Delta c[y] = 0 \rightarrow$ κίνηση προς Ανατολή).
- Speed: προσεγγίζεται από τον λόγο $\text{speed} \propto \frac{\Delta c}{\text{interval}}$, δηλαδή μεγαλύτερες χωρικές μετατοπίσεις και/ή μικρότερο χρονικό βήμα οδηγούν σε “γρηγορότερη” κίνηση.
- Agility: ελέγχει το πόσο συχνά αλλάζει η γενική κατεύθυνση της κίνησης, και εισάγεται ρητά μέσω της νέας παραμέτρου d_{interval} .

Στο GSTD2 εισάγονται επιπλέον παράμετροι για τη δειγματοληψία του d_{interval} :

$$d_{\text{interval}}(\text{dist}_{dt}(), \min_{dt}, \max_{dt})$$

ώστε η σταθερότητα της κατεύθυνσης να μπορεί να ρυθμιστεί συστηματικά.


Στον βασικό GSTD, το $\Delta c[]$ μπορεί να επαναυπολογίζεται σε κάθε νέο instance, κάτι που οδηγεί είτε σε πολύ συχνές αλλαγές πορείας (όταν το $\Delta c[]$ έχει μεγάλο εύρος), είτε σε υπερβολικά μονοκατευθυντική κίνηση (όταν το εύρος είναι πολύ μικρό). Το GSTD2 εισάγει τη λογική ότι το $\Delta c[]$ διατηρείται σταθερό για ένα χρονικό διάστημα $d_{interval}$ και αλλάζει όταν το διάστημα αυτό ολοκληρωθεί. Έτσι παράγονται πιο “φυσικές” τροχιές: συνολικά κατευθυνόμενες, αλλά με αλλαγές κατεύθυνσης σε αραιότερα σημεία, όπως συμβαίνει συχνά στην πραγματική κίνηση. Το $\Delta c[]$ εκφράζεται ως συνάρτηση που εξαρτάται και από το $d_{interval}$, αντί να είναι απλή ανεξάρτητη δειγματοληψία σε κάθε βήμα:

$$\Delta c[] (d_{interval}, new_tstamp, distr_c(), min_c[], max_c[])$$

- $d_{interval}$: πόσο χρόνο κρατάς την ίδια κατεύθυνση κίνησης πριν το αλλάξεις.
- new_tstamp : ο τρέχων χρόνος.
- $distr_c(), min_c[], max_c[]$: πώς θα δειγματοληπτήσεις ένα νέο $\Delta c[]$ όταν έρθει η ώρα να αλλάξει (ποια κατανομή και σε τι όρια).

Οι συγγραφείς σημειώνουν ότι τα πραγματικά datasets συχνά περιέχουν ομάδες (clusters) με διαφορετικά κινητικά χαρακτηριστικά (κατεύθυνση/ταχύτητα/agility). Το GSTD2 το υποστηρίζει έμμεσα: παράγει ξεχωριστά clusters με διαφορετικές ρυθμίσεις παραμέτρων και στη συνέχεια τα συνενώνει σε ένα dataset, χρησιμοποιώντας διαφορετικά $starting_id$ ώστε να μην υπάρχουν επικαλύψεις στα IDs.

Τέλος, το GSTD2 εισάγει την infrastructure (Σχήμα 5) ως σύνολο στατικών εμποδίων (π.χ. κτίρια), μοντελοποιημένων ως μη επικαλυπτόμενα ορθογώνια, τα οποία τα αντικείμενα πρέπει να αποφεύγουν. Αν ένα νέο instance τέμνει εμπόδιο, εφαρμόζονται πολιτικές αντίστοιχες με τα invalid instances: radar (διατήρηση της θέσης) ή adjustment (προσαρμογή με γραμμική παρεμβολή σε πλησιέστερο επιτρεπτό σημείο). Σε αντίθεση με τον GSTD (όρια workspace: radar/adjustment/toroid), εδώ χρησιμοποιούνται μόνο radar/adjustment για συγκρούσεις με εμπόδια.




Σχήμα 5: Υποδομή (Infrastructure) [6]

Ο συνδυασμός dinterval και infrastructure επιτρέπει την παραγωγή πιο ρεαλιστικών τροχιών, όπως:

- Κατευθυνόμενη κίνηση σε περιβάλλον με εμπόδια,
- Κίνηση πεζών σε πόλη με «εμπόδια» (π.χ. κτίρια),
- Σενάρια πολυπληθών ομάδων με κοινή κατεύθυνση, που αποφεύγουν στατικά εμπόδια (clustered movement)

Τα σενάρια sparse και dense infrastructure Σχήμα 6 δείχνουν ότι τα εμπόδια αλλάζουν αισθητά τη γεωμετρία της κίνησης: οι τροχιές γίνονται πιο τεθλασμένες, ειδικά όταν χρησιμοποιείται adjustment. Η διατήρηση τόσο 2D snapshots όσο και 3D απεικόνισης (x,y,t) βοηθά να φανεί καθαρά η επίδραση των χωρικών περιορισμών στη δυναμική της κίνησης.



Σχήμα 6: Κίνηση με εμπόδια: πυκνή υποδομή (dense infrastructure) [6]

Παρότι το GSTD2 αυξάνει τον ρεαλισμό (agility μέσω dinterval και χωρικοί περιορισμοί μέσω infrastructure), παραμένει μοντέλο κανόνων/παραμέτρων: δεν μοντελοποιεί ρητούς προορισμούς σε οδικό δίκτυο, ούτε δυναμικές συνθήκες (π.χ. κυκλοφορία) ή αλληλεπιδράσεις μεταξύ αντικειμένων. Η ρεαλιστικότητα εξαρτάται άμεσα από τις επιλεγμένες κατανομές και τα όρια παραμέτρων.

3.2.2 Oporto: γεννήτρια ρεαλιστικών σεναρίων κίνησης

Σε αντίθεση με τον GSTD/GSTD2, που παράγουν κίνηση κυρίως ως distribution-driven εξέλιξη (interval/shift/resizing και απλά χωρικά constraints), το Oporto των Saglio & Moreira (2001) [2] προτείνεται ως scenario-based γεννήτρια για benchmarking

χωροχρονικών βάσεων δεδομένων: τα δεδομένα προκύπτουν από ένα ρεαλιστικό σενάριο όπου η κίνηση καθορίζεται από στόχους και περιβαλλοντικές επιδράσεις.

Το Oporto ορίζει τέσσερις τύπους αντικειμένων, σε ένα σενάριο παρακολούθησης αλιευτικών δραστηριοτήτων: ships (πλοία ως κινούμενα σημεία), shoals (κινούμενες περιοχές “κοπάδια” με μεταβαλλόμενη θέση/μέγεθος/σχήμα), spots (περιοχές με σταθερό κέντρο αλλά μεταβαλλόμενο σχήμα, καλό/κακό) και harbours (λιμάνια ως στατικά σημεία).


Τα good spots αντιστοιχούν σε ελκυστικές περιοχές (π.χ. πλαγκτόν), ενώ τα bad spots μοντελοποιούν περιοχές αποφυγής (π.χ. καταιγίδες/storms).

Η κίνηση των ships (και γενικά η δυναμική του σεναρίου) καθορίζεται από συνδυασμό έλξης προς στόχους και απώθησης από περιοχές κινδύνου. Η απώθηση υπολογίζεται ως άθροισμα διανυσμάτων από όλα τα ενεργά bad spots, με ένταση αντιστρόφως ανάλογη της απόστασης. Η έλξη ορίζεται ως διάνυσμα προς το επιλεγμένο shoal (ή προς το harbour στη φάση επιστροφής), επίσης με ένταση αντιστρόφως ανάλογη της απόστασης ($\propto 1/d$). Η τελική πορεία προκύπτει από τη σύνθεση των δύο διανυσμάτων (attraction + repulsion).

Η ενημέρωση της θέσης γίνεται με τυπικό κανόνα κίνησης σε 2D:

$$x \leftarrow x + v \cos(\theta), \quad y \leftarrow y + v \sin(\theta)$$

Όπου v είναι η μετατόπιση ανά βήμα και θ ο προσανατολισμός



Σχήμα 7: Αλληλεπιδράσεις έλξης/άπωσης στο σενάριο Oporto [2]

Το Oporto υλοποιεί ξεχωριστές διαδικασίες παραγωγής για κάθε κατηγορία αντικειμένων:

- Spots (good/bad): εμφανίζονται σε τυχαία θέση/χρόνο και ακολουθούν δύο φάσεις, επέκταση μέχρι μέγιστη επιφάνεια και στη συνέχεια συρρίκνωση μέχρι να εξαφανιστούν.
- Shoals: κινούνται ως regions και όταν υπάρχουν πολλαπλά good spots, επιλέγουν τυχαία έναν στόχο από τα κοντινότερα. Επιπλέον, το πλήθος των υποψήφιων (selectable) spots είναι στοχαστικό, ώστε να αποφεύγεται ντετερμινιστική επιλογή και επαναλαμβανόμενες, πανομοιότυπες διαδρομές.
- Harbours: είναι στατικά σημεία (συνήθως τοποθετημένα στα όρια του frame) και λειτουργούν ως σημεία εκκίνησης/επιστροφής των ships.
- Fishing ships: ακολουθούν κύκλο συμπεριφοράς με φάσεις παραμονής στο harbour (rest), fishing phase (στόχος: shoal, με αποφυγή storms) και return phase (στόχος: harbour), μέχρι τη λήξη της προσομοίωσης.

Οι περιοχές (spots και shoals) αναπαρίστανται ως ορθογώνια, όχι μόνο για απλότητα, αλλά και επειδή σε πολλές μεθόδους πρόσβασης χωρικών δεδομένων τα σύνθετα αντικείμενα προσεγγίζονται από τα Minimum Bounding Rectangles (MBR) τους.

Ο generator παράγει μια observation base (σύνολο παρατηρήσεων) σε ξεχωριστά αρχεία: κύριο αρχείο για ships και αρχεία για shoals, good spots, bad spots, καθώς και harbours. Αυτό επιτρέπει όχι μόνο να μελετηθούν οι τροχιές των ships, αλλά και να διατηρηθεί το περιβάλλον που τις προκάλεσε.

Επειδή στην αρχή της προσομοίωσης το σύστημα δεν έχει αποκτήσει ακόμα ρεαλιστική δυναμική (π.χ. αντικείμενα δεν έχουν “διασπαρεί” επαρκώς), προτείνεται warm-up περίοδος, όπου οι παρατηρήσεις από T_{begin} έως T_{warmup} αγνοούνται στην αξιολόγηση.

Το Oporto διαχωρίζει παραμέτρους που ελέγχουν το μέγεθος του dataset (sizing) από παραμέτρους που αλλάζουν τη συμπεριφορά/κατανομές χωρίς να αλλάζουν απαραίτητα τον όγκο (distribution). Ως ενδεικτική εκτίμηση πλήθους παρατηρήσεων δίνεται:

$$NbObser = NbShips \times \frac{T}{\Delta T} \times \frac{T_{mov}}{T_{mov} + T_{st}}$$

όπου NbShips ο αριθμός πλοίων, T η διάρκεια προσομοίωσης, ΔT το μέσο διάστημα μεταξύ παρατηρήσεων, T_{mov} ο μέσος χρόνος κίνησης και T_{st} ο μέσος χρόνος παραμονής στο harbour.

Για να χρησιμοποιηθεί το Oporto, ο χρήστης ορίζει παραμέτρους όγκου (sizing), όπως NbShips, διάρκεια T και ρυθμό δειγματοληψίας ΔT , καθώς και παραμέτρους σεναρίου (distribution) που καθορίζουν τη δυναμική good/bad spots, shoals και τη συμπεριφορά των ships (fishing/return phases, έλξη-απόθεση).

Το Oporto διαφοροποιείται από generators τύπου GSTD2 (preferred direction/obstacles/clustered movement), επειδή μοντελοποιεί σενάρια όπου τα κινούμενα αντικείμενα έχουν στόχους και η κίνησή τους καθορίζεται από αλληλεπιδράσεις με άλλα δυναμικά αντικείμενα (shoals) και περιοχές αποφυγής (storms). Ωστόσο, παραμένει

προσανατολισμένο σε κίνηση σε ανοικτό 2D χώρο (όχι σε οδικό δίκτυο) και η ρεαλιστικότητα εξαρτάται από το κατά πόσο οι κανόνες/παράμετροι του συγκεκριμένου σεναρίου ανταποκρίνονται στο εκάστοτε πεδίο εφαρμογής.

3.3 Προσομοιώσεις με Περιορισμούς Δικτύου

3.3.1 O Brinkhoff Generator (Network-based moving objects)

Σε αντίθεση με τους GSTD/GSTD2 (distribution-driven κίνηση σε κανονικοποιημένο 2D χώρο) και το Oporto (scenario-based κίνηση σε ανοικτό 2D περιβάλλον), ο Brinkhoff (2002) [3] εισάγει ένα generator για network-based moving objects, όπου οι τροχιές παράγονται πάνω σε ένα ρητό δίκτυο (π.χ. οδικό), κάτι που είναι κρίσιμο για εφαρμογές traffic telematics και για benchmarking συστημάτων που διαχειρίζονται τροχιές οχημάτων.

Η βασική ιδέα είναι πως η κίνηση δεν παράγεται ως απλή μετατόπιση $\Delta x, \Delta y$, αλλά ως πλοήγηση από κόμβο σε κόμβο πάνω σε γράφο. Το δίκτυο (nodes/edges) μπορεί να προέρχεται από πραγματικά δεδομένα (π.χ. TIGER/Line) και κάθε ακμή (edge) έχει ιδιότητες όπως κλάση δρόμου, μέγιστη επιτρεπτή ταχύτητα και χωρητικότητα.

Ο Brinkhoff οργανώνει το ρεαλιστικό σκέλος της προσομοίωσης γύρω από εννέα απαιτήσεις για κίνηση σε δίκτυο (network following, fast paths, road classes, congestion, re-routing, time effects κ.λπ.). Ο Πίνακας 1 συνοψίζει τα Statements 1–9 και τη λειτουργική τους σημασία για τον generator. Συνολικά, τα παραπάνω statements μεταφράζονται σε μια λογική όπου ο χώρος ισοδυναμεί με γράφο και η κίνηση προκύπτει από routing υπό περιορισμούς (ταχύτητες ανά κλάση ακμής/οχήματος, χωρητικότητα και εξωτερικές επιδράσεις).

Η προσομοίωση υλοποιείται σε διακριτό χρόνο: η περίοδος T ορίζεται στο διάστημα $[t_{\min}, t_{\max}]$ και διαιρείται σε βήματα Δt . Οι ποσότητες όπως το edge usage/φόρτος και τα reports υπολογίζονται ανά χρονικό διάστημα.

STATEMENT	ΠΕΡΙΓΡΑΦΗ
1	Τα κινούμενα αντικείμενα στον πραγματικό κόσμο κινούνται, κατά κανόνα, πάνω σε κάποιο δίκτυο μετακίνησης (π.χ. οδικό/μονοπάτια).
2	Τα αντικείμενα τείνουν να επιλέγουν ταχύτερη ή σχεδόν ταχύτερη διαδρομή προς τον προορισμό τους.
3	Οι ακμές/δρόμοι του δικτύου ανήκουν σε κλάσεις (π.χ. αυτοκινητόδρομος, τοπική οδός), οι οποίες επηρεάζουν την επιτρεπόμενη/αναμενόμενη ταχύτητα.
4	Όταν ο φόρτος κίνησης υπερβεί ένα όριο (συμφόρηση), η ταχύτητα κίνησης των αντικειμένων μειώνεται.
5	Μεταβολές στην ταχύτητα μιας ακμής/σύνδεσης (π.χ. λόγω συμφόρησης) μπορεί να οδηγήσουν σε αλλαγή διαδρομής (re-routing).
6	Ο αριθμός των κινούμενων αντικειμένων είναι χρονικά εξαρτώμενος (π.χ. ώρες αιχμής, ημέρα/νύχτα).
7	Εξωτερικοί <u>χωροχρονικοί</u> παράγοντες (π.χ. καιρός, συμβάντα) μπορούν να επηρεάζουν την ταχύτητα, ανεξάρτητα από το δίκτυο και τον φόρτο.
8	Τα αντικείμενα ανήκουν σε κλάσεις (π.χ. ΙΧ, φορτηγό) και η κλάση τους επιβάλλει διαφορετικό όριο μέγιστης ταχύτητας.
9	Η <u>χρονο</u> -προγραμματισμένη κίνηση (π.χ. δρομολόγια τρένων/πλοίων) μπορεί να επηρεάζει τόσο τις ταχύτητες όσο και τις επιλεγόμενες διαδρομές.

Πίνακας 1: Statements 1–9 για κίνηση σε δίκτυο και η σημασία τους στον Brinkhoff generator [3].

Σε κάθε χρονικό βήμα, ο generator υλοποιεί συνοπτικά τα ακόλουθα στάδια:

- Δημιουργεί νέα αντικείμενα με βάση συνάρτηση `numberOfNewObjects(t)`, επιτρέποντας χρονική μεταβλητότητα του πλήθους (π.χ. ώρες αιχμής).
- Επιλέγει starting node (π.χ. DSO / region-based / network-based προσέγγιση).
- Επιλέγει destination node, λαμβάνοντας υπόψη και την επιθυμητή κατανομή μήκους/απόστασης διαδρομών (π.χ. μέσω `computeLengthOfRoute(·)`) ώστε να ταιριάζει σε ρεαλιστικές κατανομές διαδρομών.
- Υπολογίζει διαδρομή (fast/near-fast) πάνω στο δίκτυο, τυπικά με αλγόριθμο αναζήτησης τύπου A* [16] (σε παραλλαγή κατάλληλη για το πρόβλημα).
- Ενημερώνει θέση/ταχύτητα βάσει:
 - ορίων ταχύτητας από κλάση δρόμου και κλάση οχήματος,
 - συμφόρησης (capacity/edge usage),

(iii) εξωτερικών γεγονότων/αντικειμένων (speed decrease factors).

- Προαιρετικά εκτελεί re-routing είτε ως απόκριση σε γεγονός είτε όταν παρατηρείται σημαντική απόκλιση πραγματικής έναντι αναμενόμενης ταχύτητας (π.χ. προσομοίωση traffic info/driver reaction). Σημειώνεται ότι rerouting δεν γίνεται σε κάθε timestep, ώστε να αποφεύγεται μη ρεαλιστική συμπεριφορά και υπερβολικό υπολογιστικό κόστος.

Πιο συγκεκριμένα, η στιγμιαία ταχύτητα ενός αντικειμένου περιορίζεται από δύο «οροφές»: (α) τη μέγιστη ταχύτητα της κλάσης του αντικειμένου (π.χ. επιβατικό/φορτηγό) και (β) τη μέγιστη ταχύτητα που επιτρέπει η ακμή, η οποία εξαρτάται από την κλάση δρόμου και μειώνεται δυναμικά όταν ο φόρτος (edge usage) υπερβαίνει τη χωρητικότητα (congestion). Επιπλέον, external objects μπορούν να επιβάλουν τοπικές μειώσεις ταχύτητας μέσω συντελεστών επιβράδυνσης (decreasing factors). Τα external objects μπορεί να είναι στατικά ή κινούμενα, με σταθερό ή μεταβαλλόμενο σχήμα/έκταση και με συγκεκριμένη χρονική διάρκεια (lifetime) μέσα στην προσομοίωση.


Για την εκτέλεση του generator απαιτούνται δύο κατηγορίες εισόδων:

- Δεδομένα δικτύου: γράφος (nodes/edges) από αρχεία ή βάση δεδομένων (π.χ. TIGER/Line, MIF ή Oracle Spatial).
- μέγιστος χρόνος προσομοίωσης και χρονική διακριτοποίηση ($t_{\min}$, $t_{\max}$, Δt) , αριθμός κλάσεων οχημάτων και κλάσεων external objects, ρυθμοί δημιουργίας αντικειμένων ανά χρόνο, speed scaling (π.χ. speedDivisor), πιθανότητα αναφοράς θέσης (report probability), καθώς και user-defined functions όπως:
 - computeStartingNode, computeDestNode,
 - computeLengthOfRoute,
 - computeNewRouteByEvent/computeNewRouteByComparison,
 - capacity/speed functions ανά edge class).

Σε επίπεδο υλοποίησης, το σύστημα παρέχεται ως framework (Java), όπου ο χρήστης μπορεί να καθορίσει απλές συμπεριφορές μέσω παραμέτρων, αλλά και να επεκτείνει/αντικαταστήσει λειτουργίες μέσω overriding κλάσεων/συναρτήσεων (dynamic

loading), ώστε να προσαρμόσει λεπτομέρειες όπως την επιλογή αρχής/προορισμού, τα γεγονότα, ή τις συναρτήσεις ταχύτητας/συμφόρησης.

Ο generator παράγει χρονοσειρές θέσεων για κάθε αντικείμενο και προαιρετικά πληροφορία διαδρομής (π.χ. διαδοχικά nodes/edges που διανύθηκαν). Επιπλέον, μπορεί να παράγει αναφορές και για external objects (θέση και/ή έκταση όπου ορίζονται). Η έξοδος μπορεί να εξαχθεί σε text file, σε βάση δεδομένων (μέσω JDBC) ή/και να οπτικοποιηθεί.



Σχήμα 8: Παράδειγμα οπτικοποίησης εξόδου του Brinkhoff generator σε διαδοχικά χρονικά βήματα (timestamps). [3]

Σε σύγκριση με GSTD/GSTD2 και Oporto, ο Brinkhoff εισάγει ρητά το δίκτυο και το routing και μοντελοποιεί συμφόρηση/χωρητικότητα και δυναμικό re-routing, στοιχεία που δεν προκύπτουν φυσικά σε μοντέλα ελεύθερης κίνησης στο επίπεδο. Επιπλέον, παρουσιάζει αξιολόγηση απόδοσης σε διαφορετικά δίκτυα, ενισχύοντας τη χρησιμότητά του για παραγωγή benchmark datasets.

Από την άλλη, η ρεαλιστικότητα εξαρτάται από τον σωστό ορισμό των προκαθορισμένων από τον χρήστη συναρτήσεων και ο generator είναι engineering (όχι learning-based), δηλαδή δεν μαθαίνει κατανομές από πραγματικά trajectories. Τέλος, η κίνηση είναι αυστηρά πάνω στο δίκτυο, κάτι που περιορίζει σενάρια με απόκλιση (π.χ. αέρας/θάλασσα).

3.3.2 BerlinMOD

Μετά τους “γεννήτορες” τύπου Brinkhoff, όπου η κίνηση μοντελοποιείται πάνω σε δίκτυο με routing/συμφόρηση, η ανάγκη της κοινότητας μετατοπίζεται προς κάτι πιο τυποποιημένο: όχι μόνο παραγωγή δεδομένων, αλλά και benchmarking με καθορισμένα datasets + ερωτήματα, ώστε οι συγκρίσεις μεταξύ συστημάτων να είναι επαναλήψιμες και δίκαιες. Το BerlinMOD των Düntgen, Behr & Güting (2008) [4] εισάγεται ακριβώς ως τέτοιο benchmark για trajectory databases (ιστορικά δεδομένα κίνησης) και όχι για real-time tracking.

Το BerlinMOD ορίζει (i) κλιμακώσιμο σύνολο δεδομένων και (ii) σύνολο ερωτημάτων για αξιολόγηση χωροχρονικών DBMS (Σύστημα Διαχείρισης Βάσεων Δεδομένων). Το dataset βασίζεται σε σενάριο όπου παρακολουθούμε τη θέση ενός δείγματος οχημάτων που κινούνται στο οδικό δίκτυο του Βερολίνου για μεγάλο χρονικό διάστημα (π.χ. ημέρες/μήνα), με συχνή δειγματοληψία θέσης (ενδεικτικά αναφέρεται πυκνή παρατήρηση, μέχρι και ανά λίγα δευτερόλεπτα).

Ένα κρίσιμο στοιχείο διαφοροποίησης είναι ότι οι συγγραφείς δεν υλοποιούν standalone generator, αλλά παράγουν τα δεδομένα μέσα στο DBMS Secondo, χρησιμοποιώντας scripts/εντολές (ως εκτελέσιμες αλγεβρικές εκφράσεις). Έτσι, το benchmark “δένει” την παραγωγή δεδομένων με το περιβάλλον εκτέλεσης/ερωτημάτων, και διευκολύνει την επαναληψιμότητα.

Το BerlinMOD εστιάζει σε τροχιές οχημάτων πάνω σε δρόμους, με στόχο να δημιουργήσει μεγάλα ιστορικά (long-term observation), χρήσιμα για benchmarking δικτιών και operators χωροχρονικών δεδομένων.

Σε αντίθεση με προσεγγίσεις που περιορίζονται στην παραγωγή τροχιών, το BerlinMOD ορίζει ρητά λίστα ερωτημάτων. Το paper οργανώνει τα queries σε δύο ομάδες:

- BerlinMOD/R: ερωτήματα τύπου range / spatio-temporal selection (π.χ. ποια οχήματα βρίσκονται/βρέθηκαν σε περιοχή μέσα σε χρονικό διάστημα, ή ποια τροχιά τέμνει μια περιοχή ενδιαφέροντος).

- BerlinMOD/NN: ερωτήματα nearest neighbor (NN) για ιστορικά moving objects, τα οποία οι συγγραφείς τονίζουν ότι είναι ιδιαίτερα απαιτητικά. Περιλαμβάνονται και πιο σύνθετες παραλλαγές, όπως reverse NN (ποια αντικείμενα έχουν ένα συγκεκριμένο αντικείμενο ως πλησιέστερο γείτονα) και aggregate NN (συνολικά “ποιος είναι ο πιο κοντινός” υπό ορισμό/συνάθροιση), σε διαφορετικούς συνδυασμούς στατικού/κινούμενου query object και candidate sets.

Το BerlinMOD είναι σχεδιασμένο ώστε να κλιμακώνει εύκολα το μέγεθος του dataset με ρυθμίσεις όπως αριθμός οχημάτων, διάρκεια παρατήρησης και συχνότητα δειγματοληψίας. Επιπλέον, οι συγγραφείς επισημαίνουν ότι, αφού η βασική “πρώτη ύλη” είναι ο χάρτης/οδικό δίκτυο, το σενάριο μπορεί να μεταφερθεί και σε άλλες πόλεις όπου υπάρχει αντίστοιχο map input (π.χ. shapefile). Πρακτικά, επειδή η παραγωγή γίνεται με scripts στο Secondo, ο χρήστης μπορεί να τροποποιήσει σχετικά εύκολα τόσο τις κλίμακες όσο και ορισμένες πτυχές του μοτίβου κίνησης (π.χ. παραλλαγές πιο φυσικής κίνησης ή εισαγωγή θορύβου στις θέσεις).

Παρότι το BerlinMOD αυξάνει σημαντικά την τυποποίηση και την πρακτική χρησιμότητα (benchmarking), παραμένει προσανατολισμένο σε οχήματα σε οδικό δίκτυο και κυρίως σε moving points (όχι moving regions). Επίσης, επειδή η παραγωγή γίνεται μέσω Secondo scripts, η άμεση “out-of-the-box” χρήση είναι πιο φυσική μέσα στο Secondo, ενώ για άλλα DBMS συνήθως απαιτείται εξαγωγή/μετατροπή των δεδομένων σε αντίστοιχα formats.

3.3.3 Hermoupolis

Μετά τον generator του Thomas Brinkhoff, ο οποίος έβαλε την κίνηση πάνω σε δίκτυο, το επόμενο ζητούμενο των moving object databases ήταν να παραχθούν δεδομένα που δεν είναι μόνο γεωμετρικές τροχιές, αλλά μπορούν να υποστηρίξουν σημασιολογικά ερωτήματα (π.χ. στάση σε POI για συγκεκριμένη δραστηριότητα, move episodes με τύπο δρόμου/μέσο μετακίνησης). Το Hermoupolis των Pelekis et al. (2013) [5] εισάγεται ακριβώς ως τέτοια επέκταση: ένα semantic-aware framework που πατάει πάνω στη μηχανή δικτύου του Brinkhoff και την εμπλουτίζει με mobility profiles, POIs και ρητή

μοντελοποίηση STOP/MOVE επεισοδίων, ώστε να παράγει συγχρονισμένα (i) raw/GPS-like network trajectories και (ii) semantic trajectories.

Ο πυρήνας του Hermoupolis είναι ότι η σεναριακή πληροφορία κίνησης δεν κωδικοποιείται έμμεσα (π.χ. μόνο από κατανομές ή μόνο από routing), αλλά δίνεται ως σύνολο mobility behavior profiles, τα οποία περιγράφουν αλληλουχίες από STOP και MOVE επεισόδια. Έτσι ο generator δεν παράγει απλώς μια πορεία από origin σε destination, αλλά παράγει μια πορεία που περνά από σημεία ενδιαφέροντος (POIs) και περιλαμβάνει στάσεις συγκεκριμένης διάρκειας, άρα ενσωματώνει δραστηριότητα, σκοπό.

Το Hermoupolis περιέχει 2 επίπεδα αναπαράστασης:

- Raw trajectory (τ): ορίζεται ως $(obj_id, traj_id, \langle (x_i, y_i, t_i) \rangle)$, δηλαδή μοναδικά ids τροχιάς και ακολουθία spatiotemporal σημείων. Μεταξύ διαδοχικών σημείων υποτίθεται γραμμική κίνηση.
- Semantic trajectory (τ_{sem}): ακολουθία από επεισόδια STOP/MOVE, όπου κάθε επεισόδιο αντιστοιχεί σε ένα raw sub-trajectory. Κάθε episode περιγράφεται ως tuple (type, MBB, sem, link): όπου type $\in \{STOP, MOVE\}$, MBB περιλαμβάνει χωρικό bounding rectangle και χρονικό διάστημα $[t_s, t_e]$, sem είναι semantic annotation (π.χ. POI+activity για STOP ή road-type/means-of-transport για MOVE) και link δείχνει στο αντίστοιχο τμήμα της raw τροχιάς.

Το βασικό σημείο διαφοροποίησης είναι ότι ο generator παράγει ταυτόχρονα raw και semantic outputs με ρητή αντιστοίχιση επεισοδίων $\leftrightarrow$ υποτροχιών, σε αντίθεση με προσεγγίσεις που παράγουν κυρίως network movement ή benchmark datasets/queries χωρίς συγχρονισμένο semantic layer.

Η παραγωγή κίνησης μπορεί να ιδωθεί ως pipeline δύο φάσεων: (1) αντιστοίχιση των STOPs σε πραγματικούς κόμβους του δικτύου και (2) routing προσομοίωση των MOVEs μεταξύ διαδοχικών STOPs.

1. Φόρτωση εισόδων: road network, πίνακας POIs και mobility profiles/scenario (semantic input).

2. Ανάθεση STOP nodes (κρίσιμο βήμα): για κάθε STOP επεισόδιο χρησιμοποιείται το MBB και τα utility/tags του επεισοδίου για να εντοπιστούν κατάλληλα POIs μέσα στο MBB. Στη συνέχεια εκτελείται 1-NN αντιστοίχιση από POI προς κοντινό network node αν προκύπτουν πολλαπλοί υποψήφιοι κόμβοι γίνεται τυχαία επιλογή ώστε να αποφεύγονται πλήρως ντετερμινιστικές τροχιές.
3. Routing για MOVE episodes: αφού καθοριστούν οι STOP κόμβοι, υπολογίζεται διαδρομή μεταξύ διαδοχικών STOPs μέσω της routing λειτουργικότητας του Brinkhoff (παραλλαγή A*).
4. Προσομοίωση σε διακριτό χρόνο & (προαιρετικό) re-routing: κατά το MOVE, το αντικείμενο κινείται πάνω στο route με ταχύτητα που επηρεάζεται από περιορισμούς του profile, όρια ταχύτητας της ακμής και φαινόμενα capacity/congestion, ενώ events/external factors μπορούν να μειώσουν περαιτέρω την ταχύτητα. Αν συμβεί event ή παρατηρηθεί σημαντική απόκλιση $currentSpeed - expectedSpeed$ και έχει παρέλθει αρκετός χρόνος από τον τελευταίο υπολογισμό, μπορεί να γίνει re-routing.
5. STOP: το αντικείμενο παραμένει στον STOP node για τη διάρκεια του επεισοδίου (με καταγραφή δειγμάτων ανά StopSimulationTime, όπου ορίζεται) και μετά συνεχίζει προς το επόμενο STOP.

Επειδή η κίνηση παράγεται ως ακολουθία STOP/MOVE πάνω σε road network και εξαρτάται από POI matching, routing και simulation parameters, τα inputs χωρίζονται σε: (A) δεδομένα περιβάλλοντος, (B) σημασιολογική είσοδο και (C) παραμέτρους εκτέλεσης.:

A. Δεδομένα περιβάλλοντος (environmental inputs)

- Road network: γράφος nodes/edges (σε format συμβατό με Brinkhoff) με ιδιότητες που υποστηρίζουν network-constrained κίνηση, όπως speed limits και capacity (ώστε να προκύπτουν φαινόμενα congestion).
- POIs dataset/table: χωρικός πίνακας POIs, όπου κάθε POI έχει id, point location και tags/utility. Χρησιμοποιείται για το φιλτράρισμα υποψήφιων POIs μέσα στο MBB κάθε STOP και τη μεταφορά τους σε κοντινούς κόμβους του δικτύου μέσω 1-NN.

B. Σημασιολογική είσοδος (mobility specification)

- Mobility behavior profiles / semantic scenario file: περιγράφει την ακολουθία επεισοδίων STOP/MOVE και, για κάθε επεισόδιο, δίνει:
 - MBB (spatial bounding box + temporal interval),
 - διάρκεια (ιδίως για STOP),
 - semantic tags/annotations (π.χ. utility/POI-type για STOP, transport/road-type για MOVE),
 - και movement-related χαρακτηριστικά (π.χ. speed/top/avg/variance ή αντίστοιχες παράμετροι που επηρεάζουν την expected speed/συμπεριφορά κίνησης).
- Πλήθος αντικειμένων προς προσομοίωση (συνήα ανά profile/scenario), ώστε να παράγονται πολλαπλές τροχιές με κοινό “σενάριο” αλλά διαφορετικές υλοποιήσεις (λόγω stochastic επιλογών).

C. Παράμετροι εκτέλεσης (simulation & reporting)

- Max simulation time (EndTime): ο συνολικός χρονικός ορίζοντας της προσομοίωσης.
- StopSimulationTime / stop sampling rate: ελέγχει πόσο συχνά καταγράφονται δείγματα όταν το αντικείμενο βρίσκεται σε STOP.
- (προαιρετικά/ανά υλοποίηση) Ρυθμίσεις εξόδου (π.χ. ενεργοποίηση raw/semantic reports, format αποθήκευσης).

Ο Hermoupolis στοχεύει να παράγει συγχρονισμένα δύο όψεις τροχιών:

- Raw trajectories (GPS-like spatiotemporal samples) περιορισμένες στο οδικό δίκτυο, και
- Semantic trajectories ως ακολουθίες επεισοδίων STOP/MOVE, με semantic annotations και ρητό σύνδεσμο (link) προς τις αντίστοιχες raw υποτροχιές.

Ως προς το reporting, υποστηρίζεται εξαγωγή (ενδεικτικά) raw τροχιών σε text output, semantic τροχιών σε tabular/DB-like μορφή, καθώς και ad-hoc visualization των παραγόμενων αντικειμένων/τροχιών.

Το Σχήμα 9 παρουσιάζει τη δομή του semantic report table που παράγει το Hermoupolis. Παρατηρείται ότι στο ίδιο σχήμα συνυπάρχουν raw πεδία (π.χ. TIME, X, Y, SPEED, EDGEID) και semantic/episode πεδία (π.χ. STOPEPISODEID, EPISODE_TAG, EPISODE_ACTIVITY), αποτυπώνοντας πρακτικά τον συγχρονισμό raw και semantic όψεων.

Columns							Data	Constraints	Grants	Statistics	Triggers	Flashback	Dependencies	Details	Partitions	Indexes	SQL
▼ Actions...																	
	COLUMN_NAME		DATA_TYPE		NULLABLE	DATA_DEFAULT		COLUMN_ID		COMMENTS							
1	TIME		NUMBER(30,0)		Yes	(null)		1		(null)							
2	STOPEPISODEID		NUMBER(30,0)		Yes	(null)		2		(null)							
3	ID		NUMBER(30,0)		Yes	(null)		3		(null)							
4	REPNUM		NUMBER(30,0)		Yes	(null)		4		(null)							
5	OBJCLASS		VARCHAR2(30 CHAR)		Yes	(null)		5		(null)							
6	STOPDATE		VARCHAR2(50 CHAR)		Yes	(null)		6		(null)							
7	EDGEID		NUMBER(30,0)		Yes	(null)		7		(null)							
8	X		NUMBER(30,0)		Yes	(null)		8		(null)							
9	Y		NUMBER(30,0)		Yes	(null)		9		(null)							
10	SPEED		NUMBER(30,0)		Yes	(null)		10		(null)							
11	DONEDIST		NUMBER(30,0)		Yes	(null)		11		(null)							
12	NEXTNODEID		NUMBER(30,0)		Yes	(null)		12		(null)							
13	NEXTNODEX		NUMBER(30,0)		Yes	(null)		13		(null)							
14	NEXTNODEY		NUMBER(30,0)		Yes	(null)		14		(null)							
15	REPORTPROBABILITY		NUMBER(30,0)		Yes	(null)		15		(null)							
16	STOPNUM		NUMBER(30,0)		Yes	(null)		16		(null)							
17	REPORTER_TAG		VARCHAR2(30 CHAR)		Yes	(null)		17		(null)							
18	EPISODE_ACTIVITY		VARCHAR2(30 CHAR)		Yes	(null)		18		(null)							
19	EPISODE_TAG		VARCHAR2(30 CHAR)		Yes	(null)		19		(null)							

Σχήμα 9: Δομή πίνακα αναφοράς (report table) για semantic trajectories στο Hermoupolis. [5]

Σε σχέση με distribution-based generators που δεν ενσωματώνουν ρητά network routing και επεισοδιακή (STOP/MOVE) σημασιολογική δομή, το Hermoupolis εισάγει κίνηση πάνω σε road network και activity-aware semantics μέσω profiles και POIs. Σε σχέση με τον Brinkhoff generator, διατηρεί τη ρεαλιστική network προσομοίωση (π.χ. capacity/congestion, events, re-routing), αλλά προσθέτει ρητούς στόχους/στάσεις μέσω POI-driven STOPS και mobility profiles ώστε η κίνηση να έχει “νόημα” και να υποστηρίζει αξιολόγηση semantic operators.

Σε σχέση με benchmarks τύπου BerlinMOD που εστιάζουν σε dataset+queries/workloads, το Hermoupolis λειτουργεί ως πιο γενικό framework generator, όπου η συμπεριφορά καθορίζεται από profiles και μπορεί να μεταφερθεί σε διαφορετικά δίκτυα/POIs εφόσον υπάρχουν τα αντίστοιχα inputs.

Ο Hermoupolis είναι εγγενώς rule/profile-driven, άρα η ρεαλιστικότητα της προσομοίωσης εξαρτάται σε μεγάλο βαθμό από το πόσο καλά έχουν οριστεί τα mobility profiles και από την ποιότητα της POI βάσης (tags/utility και χωρική κάλυψη). Επιπλέον, είναι network-constrained, επομένως δεν καλύπτει σενάρια “ελεύθερης” κίνησης εκτός οδικού δικτύου. Τέλος, επειδή η παραγωγή σημασιολογίας βασίζεται στην αλυσίδα αντιστοίχισης $MBB + \text{tags/utility} \rightarrow \text{POIs} \rightarrow 1\text{-NN}$ προς network node, απαιτείται επαρκής και σωστά επισημασμένη POI κάλυψη ώστε οι STOP επιλογές να μην καταλήγουν φτωχές ή τεχνητές.

3.4 MMC (Mobility Markov Chain)

Το Mobility Markov Chain (MMC) των Gambs et al. (2011) [7] είναι ένα πιθανοτικό μοντέλο κινητικότητας τύπου αλυσίδας Markov, το οποίο συνοψίζει τη συμπεριφορά μετακινήσεων ενός ατόμου με καταστάσεις που αντιστοιχούν σε Points of Interest (POIs) ή σύνολα POIs. Οι καταστάσεις προκύπτουν από clustering πάνω στο trail των καταγραφών και συνήθως είναι ταξινομημένες κατά φθίνουσα σημαντικότητα, ενώ συχνά η τελευταία κατάσταση συγκεντρώνει τα infrequent POIs.

Μια mobility Markov chain (MMC) είναι ένα σύστημα μετάβασης (P,T) όπου:

- Καταστάσεις $P = \{p_1, \dots, p_n\}$: κάθε κατάσταση p_i αντιστοιχεί σε ένα Point of Interest (POI) (ή σε σύνολο POIs), το οποίο μπορεί να εξαχθεί π.χ. με clustering πάνω στο trail των καταγραφών κινητικότητας ενός ατόμου ή εναλλακτικά social networks. Κάθε POI συνδέεται με φυσική τοποθεσία και συχνά είναι δυνατό να αποδοθούν σημασιολογικές ετικέτες (π.χ. home, work). Οι καταστάσεις είναι ταξινομημένες κατά φθίνουσα σημαντικότητα και η τελευταία κατάσταση συχνά συγκεντρώνει τα infrequent POIs (τοποθεσίες που έχουν επισκεφθεί αρκετές φορές αλλά όχι συστηματικά).
- T: εκφράζει τη μετάβαση από p_i σε p_j με πιθανότητα $\text{Pr}(p_i \rightarrow p_j)$. Οι πιθανότητες ανά κατάσταση αθροίζουν σε 1. Επιτρέπονται και self-loops (μετακίνηση που φεύγει και επιστρέφει στο ίδιο POI).
- Η αναπαράσταση μπορεί να δοθεί είτε ως κατευθυνόμενο γράφημα με βάρη, είτε ως transition matrix.

Ο αλγόριθμος εκμάθησης (Algorithm 2 [7]) ακολουθεί συνοπτικά:

- POI discovery: εφαρμόζεται clustering στο trail καταγραφών για να βρεθούν σημαντικές συγκεντρώσεις (στάσεις/σημεία συχνής επίσκεψης).
- Merge clusters: clusters με medoids/centroids σε απόσταση $< d$ συγχωνεύονται για μείωση του πλήθους POIs.
- Χαρακτηριστικά cluster: για κάθε cluster υπολογίζονται (i) time interval (ημέρες μεταξύ πρώτης, τελευταίας εμφάνισης) και (ii) density (με βάση την πυκνότητα).
- Frequent vs infrequent: με κατώφλι mintime χωρίζονται σε frequent και infrequent POIs, και τα frequent ταξινομούνται κατά φθίνουσα density (importance).
- Κατασκευή MMC states: δημιουργείται state για κάθε frequent POI και ένα τελευταίο state που εκπροσωπεί όλα τα infrequent POIs. Το βάρος ενός state τίθεται ίσο με τη density του.
- Labeling sequence: αφαιρούνται οι εγγραφές με speed $> \epsilon$ (κατώφλι) και κάθε trace επισημαίνεται με το closest state εντός απόστασης d , αλλιώς “unknown”.
- Συμπίεση (squash): διαδοχικές καταγραφές με ίδιο label συγχωνεύονται (π.χ. πολλά σημεία στο ίδιο POI $\rightarrow$ μία επίσκεψη).
- Transition probabilities: μετριούνται/κανονικοποιούνται οι μεταβάσεις για να προκύψει transition matrix / directed weighted graph (με ειδική αντιμετώπιση τύπου $\pi_i \Rightarrow \text{unknown} \Rightarrow \pi_i$ ως self-transition).

Ως είσοδο, το MMC λαμβάνει το trail κινητικότητας ενός ατόμου (ακολουθία χωροχρονικών καταγραφών) και απαιτεί επιλογή/παραμετροποίηση της διαδικασίας clustering για POI discovery, μαζί με τις βασικές παραμέτρους μάθησης: d (απόσταση συγχώνευσης clusters και απόσταση αντιστοίχισης trace $\rightarrow$ POI), ϵ (κατώφλι ταχύτητας για αφαίρεση moving points) και minTime (κατώφλι για διάκριση frequent έναντι infrequent POIs). Ως έξοδο δίνει την Mobility Markov Chain είτε ως transition matrix είτε ως directed weighted graph, περιλαμβάνοντας το σύνολο των states/POIs (συχνά με ένα επιπλέον state που συμπτύσσει τα infrequent POIs), βάρη σημαντικότητας ανά state (π.χ. density/πλήθος καταγραφών στο cluster) και τις πιθανότητες μεταβάσεων $\Pr(\pi_i \rightarrow \pi_j)$ που προκύπτουν από counting και κανονικοποίηση ανά state προέλευσης, ενώ προαιρετικά μπορεί να συνοδεύεται από απεικονίσεις/ερμηνείες

Σε σχέση με GSTD/Brinkhoff/Hermoupolis, το MMC δεν συνθέτει κίνηση από ρητούς κανόνες/σενάρια, αλλά μαθαίνεται από mobility traces και συμπυκνώνει τη συμπεριφορά σε μια πιθανοτική δομή τύπου $POI \rightarrow POI$ (states=POIs, transitions=κινήσεις με πιθανότητες). Έτσι μπορεί να χρησιμοποιηθεί για πρόβλεψη επόμενης κίνησης, δειγματοληπτώντας από την κατανομή των εξερχόμενων πιθανοτήτων του τρέχοντος state, ενώ (δευτερευόντως) η ίδια δομή επιτρέπει random-walk τύπου διερευνήσεις/δειγματοληψία ακολουθιών για ανάλυση της κινητικότητας. Με αυτή την έννοια, το MMC λειτουργεί ως φυσικό βήμα μετάβασης από rule-based προσομοιώσεις προς προσεγγίσεις που εκτιμούν κατανομές/μοτίβα απευθείας από δεδομένα και αυτή ακριβώς η μετάβαση αξιοποιείται στο Κεφάλαιο 4, όπου εξετάζονται πιο καθαρά data-driven μοντέλα κινητικότητας.

Το MMC είναι πρώτης τάξης Markov μοντέλο (η επόμενη κίνηση εξαρτάται από το τρέχον state/POI), επομένως δεν “κουβαλά” από μόνο του μακροχρόνιες εξαρτήσεις (π.χ. ωριαία/ημερήσια ρουτίνα). Επιπλέον, η ποιότητά του εξαρτάται έντονα από το POI extraction (clustering + thresholds όπως d, ϵ), καθώς διαφορετικές επιλογές μπορούν να αλλάξουν το σύνολο POIs και άρα και τις transition probabilities. Τέλος, επειδή μοντελοποιεί την κινητικότητα ως μεταβάσεις μεταξύ σημαντικών θέσεων, δεν περιγράφει τη λεπτομερή γεωμετρία της διαδρομής ανάμεσα σε δύο POIs, εκτός αν συνδυαστεί με μηχανισμό routing ή άλλο μοντέλο.

ΚΕΦΑΛΑΙΟ 4 : Μοντέλα Παραγωγής Συνθετικών Τροχιών με Βάση τη Μηχανική Μάθηση

4.1 Knowledge-driven vs data-driven

Τα knowledge-driven μοντέλα βασίζονται σε θεωρητικά πλαίσια, κανόνες και φυσικούς νόμους για να προσομοιάσουν ή να προβλέψουν συμπεριφορές. Στην περίπτωση των δεδομένων κίνησης, ενσωματώνουν γνώση για τη φυσική της κίνησης, γεωμετρικούς περιορισμούς, κανόνες κυκλοφορίας και κοινωνικοοικονομικές συνθήκες. Αντίθετα, τα data-driven μοντέλα αντλούν τη γνώση τους αποκλειστικά από δεδομένα παρατήρησης. Μέσα από στατιστική ανάλυση ή αλγορίθμους μηχανικής μάθησης, «μαθαίνουν» απευθείας τις συσχετίσεις και τα μοτίβα, χωρίς να απαιτείται σαφής κωδικοποίηση κανόνων εκ των προτέρων.

Τα knowledge-driven μοντέλα έχουν το πλεονέκτημα της εξηγησιμότητας και της δυνατότητας ελέγχου, καθώς οι κανόνες που τα διέπουν είναι γνωστοί και μπορούν να τροποποιηθούν ανάλογα με τις απαιτήσεις της εφαρμογής. Ωστόσο, συχνά αδυνατούν να αποτυπώσουν την πολυπλοκότητα και την αβεβαιότητα πραγματικών περιβαλλόντων, ειδικά όταν τα φαινόμενα δεν μπορούν να περιγραφούν πλήρως με αναλυτικούς κανόνες. Από την άλλη, τα data-driven μοντέλα, ιδίως όταν χρησιμοποιούν βαθιά νευρωνικά δίκτυα, μπορούν να αναγνωρίσουν πολύπλοκα, μη γραμμικά μοτίβα, αλλά απαιτούν μεγάλα και ποιοτικά σύνολα δεδομένων. Επιπλέον, μπορεί να υστερούν σε εξηγησιμότητα, καθώς η γνώση ενσωματώνεται έμμεσα στα βάρη του μοντέλου.

Τα τελευταία χρόνια, παρατηρείται αυξημένο ενδιαφέρον για hybrid μοντέλα (EETG-SVAE με Spatiotemporal Constraints (Zhang et al., 2023)[28]) που συνδυάζουν στοιχεία και από τις δύο προσεγγίσεις. Για παράδειγμα, σε εφαρμογές προσομοίωσης δεδομένων κίνησης, μπορεί να χρησιμοποιηθεί ένα data-driven νευρωνικό δίκτυο για να μάθει τα βασικά μοτίβα κίνησης από ιστορικά δεδομένα, ενώ παράλληλα να ενσωματώνονται knowledge-driven περιορισμοί, όπως οι κανόνες φυσικής κίνησης και οι χωροχρονικοί περιορισμοί. Αυτή η συνδυαστική στρατηγική στοχεύει να εκμεταλλευτεί την

προσαρμοστικότητα και ακρίβεια των data-driven μοντέλων, ενώ διασφαλίζει τη ρεαλιστικότητα και εγκυρότητα μέσω των knowledge-driven παραμέτρων.

4.2 Generative Adversarial Network (GAN)

Τα Generative Adversarial Networks (GANs) αποτελούν μια βασική οικογένεια μοντέλων της βαθιάς μάθησης για παραγωγή συνθετικών δεδομένων, με ιδιαίτερη επιτυχία σε πολύπλοκες κατανομές. Εισήχθησαν από τους Goodfellow et al. (2014) [8] και η κεντρική τους ιδέα είναι η αντιπαραθετική εκπαίδευση (adversarial training): δύο δίκτυα εκπαιδεύονται ταυτόχρονα σε ένα παιχνίδι μηδενικού αθροίσματος, μέχρι τα παραγόμενα δείγματα να γίνουν δυσδιάκριτα από τα πραγματικά.


Ένα GAN αποτελείται από:

- Generator (G): λαμβάνει ως είσοδο ένα τυχαίο διάνυσμα θορύβου $z \sim p_z$ και παράγει ένα συνθετικό δείγμα $G(z)$.
- Discriminator (D): λαμβάνει ένα δείγμα x (πραγματικό ή συνθετικό) και επιστρέφει πιθανότητα $D(x) \in [0,1]$ ότι το x προέρχεται από τα πραγματικά δεδομένα.

Η εκπαίδευση διατυπώνεται ως πρόβλημα min-max:

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

Ο Discriminator επιδιώκει να ξεχωρίζει σωστά πραγματικά από συνθετικά δείγματα (μεγιστοποιεί το παραπάνω), ενώ ο Generator επιδιώκει να “ξεγελά” τον Discriminator παράγοντας δείγματα που μοιάζουν με τα πραγματικά (ελαχιστοποιεί). Ιδανικά, το σύστημα συγκλίνει σε ισορροπία όπου ο Discriminator δεν έχει πια αξιόπιστο σήμα διάκρισης, άρα τα $G(z)$ ακολουθούν κατανομή πολύ κοντά στα πραγματικά δεδομένα.



Σχήμα 10: Βασική αρχιτεκτονική GAN: ο *Generator* μετασχηματίζει τυχαίο θόρυβο z σε συνθετικά δείγματα, ενώ ο *Discriminator* προσπαθεί να διακρίνει πραγματικά από παραγόμενα δείγματα. Η αντιπαραθετική εκπαίδευση βελτιώνει σταδιακά τον *Generator* ώστε τα συνθετικά δεδομένα να γίνονται δυσδιάκριτα από τα πραγματικά.

Σε αντίθεση με rule-based/knowledge-driven προσομοιώσεις, ένα GAN μπορεί (θεωρητικά) να μάθει απευθείας από δεδομένα τη στατιστική “υπογραφή” της κινητικότητας, όπως συχνά μοτίβα μετακινήσεων, κατανομές αποστάσεων/χρόνων, ακόμη και πιο λεπτές συσχετίσεις που είναι δύσκολο να κωδικοποιηθούν χειροκίνητα. Αυτό είναι ιδιαίτερα χρήσιμο όταν θέλουμε ρεαλιστικά συνθετικά σύνολα δεδομένων για benchmarking ή/και data augmentation.

Η άμεση εφαρμογή ενός κλασικού GAN σε δεδομένα τροχιάς είναι δύσκολη, γιατί οι τροχιές:

- είναι ακολουθιακά δεδομένα (ισχυρές χρονικές εξαρτήσεις),
- έχουν συχνά μεταβλητό μήκος,
- υπόκεινται σε χωρικούς/φυσικούς περιορισμούς (π.χ. οδικό δίκτυο, εμπόδια, μέγιστες ταχύτητες),
- απαιτούν συνέπεια τόσο σε μικρο-επίπεδο (ομαλές μεταβάσεις) όσο και σε μακρο-επίπεδο (λογική πορεία/προορισμοί).

Γι’ αυτό στη βιβλιογραφία εμφανίζονται συνήθως εξειδικευμένες παραλλαγές. Ακολουθιακοί generators/discriminators (π.χ. RNN/LSTM/Transformer), conditional GANs με πλευρική πληροφορία (π.χ. ώρα, τύπος χρήστη, χάρτης/περιοχή), καθώς και μηχανισμοί constraints ώστε τα παραγόμενα δείγματα να παραμένουν έγκυρα (π.χ. network-constrained κίνηση ή περιορισμοί ταχύτητας/χώρου). Με άλλα λόγια, τα GANs

δίνουν το βασικό πλαίσιο “μάθε να παράγεις ρεαλιστικά δείγματα”, αλλά για trajectories απαιτείται προσαρμογή ώστε να διατηρηθεί η χωροχρονική δομή.

Συνοψίζοντας, τα GANs εισάγουν ένα ισχυρό data-driven μηχανισμό παραγωγής που μπορεί να προσεγγίσει περίπλοκες κατανομές. Στην κινητικότητα, η αξία τους φαίνεται κυρίως όταν συνδυάζονται με ακολουθιακή μοντελοποίηση και περιορισμούς εγκυρότητας, ώστε οι συνθετικές τροχιές να είναι ταυτόχρονα ρεαλιστικές και συνεπείς.

4.2.1 Συνθετικές Τροχιές με GANs

Οι Ouyang et al. (2018) [12], προτείνουν ένα μη-παραμετρικό generative μοντέλο βασισμένο σε Generative Adversarial Networks (GANs) για τη σύνθεση ρεαλιστικών ανθρώπινων τροχιών. Σε αντίθεση με τις παραδοσιακές σειριακές προσεγγίσεις, όπου μια τροχιά παράγεται βήμα-προς-βήμα στον χρόνο, το προτεινόμενο μοντέλο παράγει ολόκληρες τροχιές ως ενιαίες δομές, επιτρέποντας τη σύλληψη σύνθετων χωρικών και σημασιολογικών συσχετίσεων.

Ως είσοδος στο GAN χρησιμοποιείται ένα σύνολο πραγματικών ανθρώπινων τροχιών, οι οποίες αρχικά μετασχηματίζονται από τη συμβατική σειριακή μορφή:

$$\text{Traj} = \{(x_1, y_1, t_1), \dots, (x_T, y_T, t_T)\}$$

σε μια χωρικά-κεντρική (location-major) αναπαράσταση.

Η περιοχή ενδιαφέροντος διακριτοποιείται σε ένα πλέγμα διαστάσεων $N1 \times N2$, και κάθε τροχιά αναπαρίσταται ως ένας τριδιάστατος πίνακας:

$$M \in R^{N1 \times N2 \times K}$$

Όπου K είναι ο μέγιστος αριθμός επισκέψεων (stays) στο ίδιο κελί κατά τη διάρκεια της ημέρας. Για κάθε κελί (x, y) και για κάθε επίσκεψη k , το στοιχείο $M_{x,y,k} = (t, d)$ περιέχει:

- την ώρα επίσκεψης t ,
- τη διάρκεια παραμονής d .

Έτσι, το input του Discriminator είναι είτε:

- ένας πραγματικός πίνακας τροχιάς M_{real} προερχόμενος από τα δεδομένα, είτε

- ένας συνθετικός πίνακας $M_{\text{synthetic}}$, παραγόμενος από τον Generator.

Ο Generator λαμβάνει ως είσοδο έναν τυχαίο διανυσματικό θόρυβο $z \sim P_z$

Η άμεση έξοδος του Generator είναι ένας συνθετικός τρισδιάστατος πίνακας τροχιάς:

$$\hat{M} = G(z)$$

ο οποίος έχει την ίδια δομή με τους πίνακες των πραγματικών δεδομένων.

Στη συνέχεια, μέσω διαδικασίας post-processing, ο πίνακας $\hat{M}$ μετατρέπεται ξανά σε σειριακή τροχιά:

$$\text{Traj} = \{(x_1, y_1, t_1), \dots, (x_T, y_T, t_T)\}$$

Επομένως, το τελικό output του μοντέλου είναι:

- πλήρως συνθετικές ανθρώπινες τροχιές,
- χωρικά, χρονικά και σημασιολογικά συνεπείς με τα πραγματικά δεδομένα,
- κατάλληλες για ανάλυση και πειραματισμό χωρίς έκθεση ευαίσθητων πληροφοριών.

Ο Generator και ο Discriminator υλοποιούνται με συνελκτικά νευρωνικά δίκτυα (CNNs), ώστε να αξιοποιούνται τοπικές χωρικές συσχετίσεις μεταξύ γειτονικών κελιών του πλέγματος. Η εκπαίδευση πραγματοποιείται με τη μέθοδο Wasserstein GAN με Gradient Penalty (WGAN-GP) [10], η οποία βελτιώνει τη σταθερότητα της εκπαίδευσης και μειώνει φαινόμενα όπως το mode collapse.

Το μοντέλο αξιολογείται στο Nokia Lausanne dataset, με πλέγμα 64×64 και $K=4$. Που σημαίνει ότι για κάθε θέση στον χάρτη μπορούμε να έχουμε καταγεγραμμένες έως τέσσερις επισκέψεις μέσα στη μέρα (αν κάποιος πάει π.χ. σπίτι-δουλειά-σπίτι-σούπερμάρκετ-σπίτι).

Η ποιότητα των συνθετικών δεδομένων μετράται μέσω στατιστικών κατανομών:

- $p(r)$: πιθανότητα επίσκεψης τοποθεσίας,

- $p(r,t)$: χρονική κατανομή επισκέψεων,
- $p(r,d)$: κατανομή διάρκειας παραμονής,
- $p(r,dtotal)$: συνολικός χρόνος παραμονής.

Η ομοιότητα μεταξύ πραγματικών και συνθετικών δεδομένων υπολογίζεται με τη Jensen–Shannon Divergence (JSD), ενώ η διατήρηση της σχετικής σημασιολογίας μεταξύ τροχιών αξιολογείται με τη μετρική semantic distance των Bindschaedler & Shokri (2016) [11]. Τα αποτελέσματα δείχνουν ότι το προτεινόμενο GAN-based μοντέλο υπερτερεί των κλασικών σειριακών μοντέλων (MC, HMM, LSTM) τόσο σε γεωγραφικό όσο και σε σημασιολογικό επίπεδο.


Συνοψίζοντας, το μοντέλο των Ouyang et al. (2018) λαμβάνει ως input χωρικά-δομημένες αναπαραστάσεις πραγματικών τροχιών και παράγει ως output πλήρεις, ρεαλιστικές συνθετικές ανθρώπινες διαδρομές. Η ολιστική, μη-σειριακή προσέγγιση που βασίζεται σε GANs επιτρέπει την αποτύπωση σύνθετων χωρικών και σημασιολογικών μοτίβων, τα οποία είναι δύσκολο να μοντελοποιηθούν με παραδοσιακές μεθόδους σημείο-προς-σημείο.

JSD(preal, psynthetic) Results


	$p(r)$	$p(r, t)$	$p(r, d)$	$p(r, dtotal)$
First-order MC	0.226045 (2.455)	0.377977 (1.898)	0.617615 (2.158)	0.282112 (2.235)
Time-dep MC	0.244647 (4.208)	0.383154 (2.756)	0.617357 (0.216)	0.299368 (3.789)
HMM	0.274112 (5.654)	0.438551 (3.497)	0.619812 (0.624)	0.420264 (0.819)
LSTM-MLE	0.386385 (14.140)	0.555498 (8.778)	0.642768 (6.427)	0.603640 (0.981)
Gans	0.066109 (1.818)	0.355129 (1.779)	0.213122 (7.308)	0.245102 (2.188)

Σχήμα 11: Σύγκριση GANS με προηγούμενα μοντέλα [11]

Σύμφωνα με τα αποτελέσματα που παρουσιάζονται στο Σχήμα 11 με βάση τη σχετική βιβλιογραφία, το GAN-based μοντέλο πετυχαίνει σημαντικά χαμηλότερες τιμές JSD[20] σε όλες τις μετρικές, δηλαδή οι συνθετικές τροχιές του είναι πολύ πιο κοντά στις πραγματικές, τόσο ως προς τη γεωγραφία, όσο και ως προς τα χρονικά χαρακτηριστικά.



(a) Histograms for pairwise semantic distance within the synthetic, training and testing dataset.



(b) QQ-plot for pairwise semantic distance for synthetic set and test set.

Σχήμα 12: Αξιολόγηση Σχετικής Σημασιολογίας Τροχιών [11]


Πέρα από αυτή την ποσοτική σύγκριση, η σημασιολογική ποιότητα των συνθετικών τροχιών αξιολογείται μέσω της μετρικής semantic distance των Bindschaedler & Shokri (2016) [11]. Στο Σχήμα 12 παρουσιάζονται τα ιστογράμματα της semantic distance για τα σύνολα training, test και synthetic, καθώς και το αντίστοιχο QQ-plot μεταξύ του synthetic και του test set. Η έντονη σύμπτωση των κατανομών και η ευθυγράμμιση των σημείων κατά μήκος της διαγωνίου δείχνουν ότι οι συνθετικές τροχιές διατηρούν τις ίδιες σχετικές σημασιολογικές σχέσεις με τις πραγματικές, δηλαδή παρόμοιοι χρήστες στο πραγματικό σύνολο παραμένουν παρόμοιοι και στο συνθετικό.

Ο συνδυασμός των χαμηλών τιμών JSD και της υψηλής σημασιολογικής συνέπειας καταδεικνύει ότι το προτεινόμενο μη-παραμετρικό GAN-based μοντέλο δεν αναπαράγει απλώς τα βασικά στατιστικά της κινητικότητας, αλλά και τα βαθύτερα πρότυπα ανθρώπινης συμπεριφοράς, καθιστώντας τα παραγόμενα δεδομένα κατάλληλα για ανάλυση και προσομοίωση.

4.2.2 IGMM-GAN

Το IGMM-GAN των Smolyak et al. (2020) [13] προτείνεται ως ένα μοντέλο σύνθεσης τροχιών και ταυτόχρονης ανίχνευσης ανωμαλιών σε δεδομένα ανθρώπινης κινητικότητας. Το βασικό του πλεονέκτημα έγκειται στην ικανότητά του να μοντελοποιεί πολυτροπικές (multimodal) κατανομές τροχιών, αντιμετωπίζοντας έναν βασικό περιορισμό των κλασικών GAN-based μεθόδων ανίχνευσης ανωμαλιών, οι οποίες υποθέτουν συνήθως μονοτροπική δομή στον λανθάνοντα χώρο.

Η συνολική αρχιτεκτονική του IGMM-GAN, η οποία παρουσιάζεται στο Σχήμα 13, βασίζεται σε ένα Bidirectional GAN (BiGAN) των Donahue et al. 2016 [15], το οποίο επεκτείνεται με ένα Infinite Gaussian Mixture Model (IGMM) στον λανθάνοντα χώρο.



Σχήμα 13: Συνολική αρχιτεκτονική του IGMM-GAN. Ο Generator χαρτογραφεί τυχαία διανύσματα στον χώρο των τροχιών, ο Encoder μαθαίνει την αντίστροφη απεικόνιση στον λανθάνοντα χώρο και ο Discriminator διακρίνει πραγματικά από συνθετικά δείγματα. Η ανίχνευση ανωμαλιών πραγματοποιείται μέσω IGMM στον λανθάνοντα χώρο. [15]

Το μοντέλο αποτελείται από τρία βασικά υποδίκτυα:

- Generator (G): μετασχηματίζει ένα τυχαίο διάνυσμα θορύβου z σε συνθετική τροχιά $G(z)$,
- Encoder (E): χαρτογραφεί μια πραγματική τροχιά x σε λανθάνοντα αναπαράσταση $z=E(x)$,
- Discriminator (D): διακρίνει ζεύγη $(x, E(x))$ από $(G(z), z)$.

Η χρήση BiGAN επιτρέπει όχι μόνο τη δημιουργία συνθετικών τροχιών, αλλά και την ενσωμάτωση των πραγματικών δεδομένων σε έναν κοινό λανθάνοντα χώρο, απαραίτητο για την ανίχνευση ανωμαλιών.

Σε αντίθεση με προηγούμενες GAN-based μεθόδους, το IGMM-GAN δεν υποθέτει ότι τα δεδομένα στον λανθάνοντα χώρο ακολουθούν μία μοναδική Gaussian κατανομή. Αντίθετα, εφαρμόζει ένα Infinite Gaussian Mixture Model, το οποίο:

- μαθαίνει αυτόματα τον αριθμό των clusters,
- εκτιμά για κάθε cluster μέση τιμή μ_i και συνδιακύμανση Σ_i ,
- αποτυπώνει τη φυσική πολυτροπικότητα των τροχιών (π.χ. διαφορετικά πρότυπα οδηγών ή διαδρομών).

Η ανίχνευση ανωμαλιών βασίζεται στον υπολογισμό της απόστασης Mahalanobis της λανθάνουσας αναπαράστασης $z' = E(x')$ από το πλησιέστερο cluster στον λανθάνοντα χώρο:

$$D_M^{i(z')} = \sqrt{(z' - \mu_i)^\top \Sigma_i^{-1} (z' - \mu_i)}$$

$$D(x') = \min_i D_M^{(i)}(E(x'))$$

Μετά την εκπαίδευση του BiGAN, οι αναπαραστάσεις $z = E(x)$ των δεδομένων εκπαίδευσης χρησιμοποιούνται για την εκτίμηση των (μ_i, Σ_i) μέσω IGMM, ενώ για κάθε νέο δείγμα x' η τιμή $D(x')$ λειτουργεί ως anomaly score.

Οι τροχιές τμηματοποιούνται σε segments σταθερού μήκους και κάθε segment κωδικοποιείται ως πολυδιάστατη χρονοσειρά $4 \times N$, που περιλαμβάνει latitude, longitude καθώς και τις αντίστοιχες ταχύτητες (latitudinal και longitudinal velocity), ώστε το μοντέλο να λαμβάνει ταυτόχρονα πληροφορία θέσης και δυναμικής κίνησης.

Το IGMM-GAN λαμβάνει ως είσοδο:


- Πραγματικές τροχιές GPS, κωδικοποιημένες ως πολυδιάστατες χρονοσειρές (π.χ. γεωγραφικές συντεταγμένες και ταχύτητες),

- Τυχαία διανύσματα θορύβου z για τη σύνθεση συνθετικών τροχιών.


Το μοντέλο παράγει:

- Συνθετικά segments/διαδρομές σταθερού μήκους που ακολουθούν τα στατιστικά και χωροχρονικά μοτίβα των πραγματικών δεδομένων,
- Λανθάνουσες αναπαραστάσεις τροχιών στον χώρο z ,
- Βαθμολογίες ανωμαλίας (anomaly scores) βασισμένες στην απόσταση Mahalanobis.

Η ικανότητα του μοντέλου να παράγει ρεαλιστικές τροχιές και να εντοπίζει ανωμαλίες παρουσιάζεται ενδεικτικά στο Σχήμα 14, όπου συγκρίνονται πραγματικές και συνθετικές διαδρομές, καθώς και στο Σχήμα 15, όπου απεικονίζονται παραδείγματα ανώμαλων τροχιών που αποκλίνουν είτε γεωμετρικά είτε ως προς την ταχύτητα.



(a) Real and generated cab spotting routes.



(b) Real and generated cab spotting speed profiles.

Σχήμα 14: Σύγκριση πραγματικών και συνθετικών τροχιών που παράγονται από το IGMM-GAN. [15]



(a) Route with an unnecessary detour.




(b) Route with an unusual high speed in an urban area.

Σχήμα 15: Παραδείγματα ανώμαλων τροχιών που ανιχνεύονται μέσω της Mahalanobis απόστασης στον λανθάνοντα χώρο. [15]

Συνολικά το IGMM-GAN δεν στοχεύει στη γεωγραφική ακρίβεια επιπέδου οδικού δικτύου, αλλά στη στατιστική μοντελοποίηση και ανίχνευση ανωμαλιών. Δίνει μεγαλύτερη έμφαση στη δομή του λανθάνοντα χώρου και στην πολυτροπικότητα των δεδομένων, προσφέροντας ένα ισχυρό εργαλείο για ανάλυση και έλεγχο ποιότητας συνόλων τροχιών.

4.2.3 Two-Stage GAN

Το Two-Stage GAN των Wang et al. (2021) [9] προτείνεται ως εξέλιξη των grid-based GAN μοντέλων σύνθεσης τροχιών, με στόχο την αντιμετώπιση του βασικού περιορισμού της περιορισμένης γεωγραφικής ακρίβειας που προκύπτει από τη χωρική διακριτοποίηση. Ενώ το μοντέλο των Ouyang et al. (2018) παράγει ρεαλιστικές τροχιές σε επίπεδο χωρικών στάσεων, δεν αποτυπώνει τη λεπτομερή γεωμετρία της κίνησης πάνω στο πραγματικό οδικό δίκτυο. Το Two-Stage GAN εισάγει μια ιεραρχική διαδικασία δύο σταδίων, η οποία επιτρέπει τη σύνθεση τόσο της συνολικής χωρικής κατανομής της κινητικότητας όσο και της ακριβούς πορείας των διαδρομών σε επίπεδο δρόμων.



Σχήμα 16: Διάγραμμα της αρχιτεκτονικής Two-Stage GAN για παραγωγή συνθετικών διαδρομών GPS. [9]

Στο Σχήμα 16 παρουσιάζεται η συνολική αρχιτεκτονική του Two-Stage GAN. Στο πρώτο στάδιο (Stage One GAN), οι τροχιές παράγονται σε μορφή πλέγματος (grid representation). Στη συνέχεια, το Link Module εφαρμόζει αναζήτηση βάθους (Depth-First Search, DFS) και διαδικασία σύνδεσης, μετατρέποντας τη δισδιάστατη αναπαράσταση σε σειριακή ακολουθία κελιών. Στο δεύτερο στάδιο (Stage Two GAN), κάθε κελί της ακολουθίας επεξεργάζεται λεπτομερώς με χρήση εικόνων χάρτη και προκαθορισμένων σημείων εισόδου και εξόδου, ώστε το τελικό αποτέλεσμα να αντιστοιχεί σε ρεαλιστική τροχιά πάνω στο οδικό δίκτυο.

Όπως και στην προηγούμενη προσέγγιση, οι αρχικές τροχιές GPS της μορφής

$$\text{Traj} = \{(x_1, y_1, t_1), \dots, (x_T, y_T, t_T)\}$$

υφίστανται προεπεξεργασία και μετασχηματίζονται σε χωρική αναπαράσταση πλέγματος. Η περιοχή ενδιαφέροντος διακριτοποιείται σε πλέγμα διαστάσεων $N_1 \times N_2$, και κάθε τροχιά αναπαρίσταται ως ένας δισδιάστατος πίνακας:

$$T \in R^{N_1 \times N_2}$$

όπου κάθε κελί κωδικοποιεί τον συνολικό χρόνο διέλευσης της τροχιάς εντός της αντίστοιχης γεωγραφικής περιοχής. Ο χρόνος αυτός υπολογίζεται αθροιστικά από τα

σημεία GPS που εμπίπτουν στο κελί και δεν διακρίνει μεταξύ στάσης και αργής κίνησης. Η αναπαράσταση αυτή αποτυπώνει την ένταση της χωρικής δραστηριότητας σε επίπεδο περιοχών, χωρίς να διατηρεί τη χρονική σειρά ή τη λεπτομερή γεωμετρία της κίνησης.

Στο πρώτο στάδιο, ένα Generative Adversarial Network βασισμένο σε συνελκτικά νευρωνικά δίκτυα εκπαιδεύεται με τη μέθοδο Wasserstein GAN με Gradient Penalty (WGAN-GP) [10], ώστε να μάθει την κατανομή των χωρικών πινάκων T και να παράγει συνθετικούς πίνακες δραστηριότητας $\hat{T}$. Το αποτέλεσμα του σταδίου αυτού περιγράφει σε ποιες περιοχές κινείται ο χρήστης και με ποια ένταση, χωρίς όμως να καθορίζει ακόμη τη λεπτομερή πορεία της κίνησης.


Η μετάβαση από τη χωρική αναπαράσταση πλέγματος σε ακολουθιακή μορφή πραγματοποιείται μέσω ενός ειδικού link module, το οποίο εφαρμόζει αναζήτηση βάθους (Depth-First Search) στον συνθετικό πίνακα $\hat{T}$, ώστε να εξαχθεί μία συνεκτική και συνδεδεμένη ακολουθία γειτονικών κελιών. Η διαδικασία αυτή μετατρέπει τη δισδιάστατη αναπαράσταση διάρκειας παραμονής σε μια σειριακή περιγραφή της διαδρομής, απαραίτητη για το δεύτερο στάδιο του μοντέλου. Παράλληλα, για κάθε κελί προσδιορίζονται σημεία εισόδου και εξόδου, καθώς και η διάρκεια παραμονής, δημιουργώντας μια ενδιάμεση αναπαράσταση της τροχιάς.

Στο δεύτερο στάδιο, το μοντέλο εξειδικεύεται στην παραγωγή λεπτομερών τροχιών GPS εντός κάθε κελιού της ακολουθίας. Για κάθε κελί, ως input στον Generator χρησιμοποιούνται:

- μια εικόνα του τοπικού οδικού δικτύου (map image),
- το σημείο εισόδου στο κελί,
- το σημείο εξόδου από το κελί,
- και η διάρκεια παραμονής που έχει προκύψει από το πρώτο στάδιο.

Η εικόνα του χάρτη κωδικοποιείται μέσω ενός πλήρως συνελκτικού δικτύου (Fully Convolutional Network), το οποίο εξάγει χωρικά χαρακτηριστικά του οδικού δικτύου και τα χρησιμοποιεί ως συνθήκη για τη διαδικασία παραγωγής.

Large Scale GPS Trajectory Generation Using Map Based on Two Stage GAN



Σχήμα 17: Διαδικασία εξαγωγής χωρικών χαρακτηριστικών του οδικού δικτύου από εικόνες χάρτη. (a) αρχική εικόνα χάρτη, (b) απεικόνιση του οδικού δικτύου της περιοχής, (c) χαρακτηριστικά οδικού δικτύου που εξάγονται από τον encoder και χρησιμοποιούνται ως συνθήκη στο δεύτερο στάδιο του μοντέλου. [9]

Ο Generator βασίζεται σε έναν συμμετρικό μηχανισμό αποκωδικοποίησης με δύο παράλληλα LSTM, τα οποία παράγουν την τροχιά ταυτόχρονα από το σημείο εισόδου προς το σημείο εξόδου και αντίστροφα. Η ανταλλαγή κρυφών καταστάσεων μεταξύ των δύο LSTM επιτρέπει την αντιμετώπιση του φαινομένου exposure bias, διασφαλίζοντας ότι η παραγόμενη τροχιά παραμένει συνεπής και καταλήγει στο προκαθορισμένο σημείο εξόδου. Το αποτέλεσμα είναι μια ακολουθία σημείων GPS:

$$\{(x_1, y_1), \dots, (x_T, y_T)\}$$

η οποία ακολουθεί τη γεωμετρία του πραγματικού οδικού δικτύου και συνδέει ομαλά τα σημεία εισόδου και εξόδου.

$$\begin{pmatrix} \hat{x}_{t+1} \\ \hat{y}_{t+1} \\ h_t \\ c_t \end{pmatrix} = \text{LSTM} \begin{pmatrix} \hat{x}_t \\ \hat{y}_t \\ h_{t-1} \oplus h_{rev_{t-1}} \\ c_{t-1} \oplus c_{rev_{t-1}} \end{pmatrix},$$

$$\begin{pmatrix} \hat{x}_{T-t} \\ \hat{y}_{T-t} \\ h_t \\ c_t \end{pmatrix} = \text{LSTM}_{\text{rev}} \begin{pmatrix} \hat{x}_{T-t+1} \\ \hat{y}_{T-t+1} \\ h_{rev_{t-1}} \oplus h_{t-1} \\ c_{rev_{t-1}} \oplus c_{t-1} \end{pmatrix},$$

Σχήμα 18: Αρχιτεκτονική συμμετρικού LSTM που χρησιμοποιείται στο δεύτερο στάδιο του Two-Stage GAN. Δύο παράλληλα LSTM παράγουν την τροχιά από το σημείο εισόδου προς το σημείο εξόδου και αντίστροφα, ανταλλάσσοντας κρυφές καταστάσεις για τη μείωση του exposure bias και τη βελτίωση της γεωμετρικής συνέπειας. [9]


Ο Discriminator του δεύτερου σταδίου υλοποιείται ως συνελκτικό δίκτυο, το οποίο λαμβάνει ως είσοδο τη συνένωση της κωδικοποιημένης εικόνας χάρτη και της παραγόμενης τροχιάς, αφού αυτή μετασχηματιστεί εκ νέου σε μορφή πλέγματος. Με τον τρόπο αυτό, το μοντέλο αξιολογεί τη ρεαλιστικότητα της παραγόμενης διαδρομής τόσο ως προς τη στατιστική ομοιότητα με τις πραγματικές τροχιές όσο και ως προς τη συμβατότητά της με το τοπικό οδικό δίκτυο. Το δεύτερο στάδιο δεν αποτελεί ένα πλήρως end-to-end GAN, αλλά ένα GAN-based μοντέλο ενισχυμένο με ισχυρούς χωρικούς και χρονικούς περιορισμούς.

Σε αντίθεση με το μοντέλο των Ouyang et al., του οποίου το τελικό αποτέλεσμα είναι συνθετικές τροχιές σε επίπεδο χωρικών στάσεων, το Two-Stage GAN παράγει πλήρεις, συνεχείς τροχιές GPS ευθυγραμμισμένες με το πραγματικό οδικό δίκτυο. Με τον τρόπο αυτό, το μοντέλο συνδυάζει την ικανότητα των GANs να μαθαίνουν ρεαλιστικές χωρικές κατανομές με υψηλή γεωγραφική ακρίβεια σε επίπεδο δρόμων.


Η ποιότητα των παραγόμενων τροχιών αξιολογείται μέσω στατιστικών κατανομών που αφορούν την κατανομή επισκέψεων ανά περιοχή, το μήκος των διαδρομών και τη συνολική γεωγραφική απόσταση, με χρήση της Jensen–Shannon Divergence (JSD) (Lin, 1991). Τα πειραματικά αποτελέσματα δείχνουν ότι το Two-Stage GAN διατηρεί αποτελεσματικά τα μακροσκοπικά μοτίβα κινητικότητας των πραγματικών δεδομένων,

ενώ ταυτόχρονα επιτυγχάνει σημαντικά βελτιωμένη γεωγραφική πιστότητα σε σύγκριση με τα απλά grid-based GAN μοντέλα.

Παρά τα πλεονεκτήματά του, το μοντέλο εξακολουθεί να εξαρτάται από τη χωρική διακριτοποίηση και από μια εξωτερική αλγοριθμική διαδικασία σύνδεσης των δύο σταδίων, ενώ η ποιότητα των παραγόμενων τροχιών επηρεάζεται από τη διαθεσιμότητα και την ακρίβεια των εικόνων χάρτη. Ωστόσο, αποτελεί ένα από τα πρώτα μοντέλα που επιτυγχάνουν σύνθεση μεγάλων συνόλων τροχιών με υψηλή γεωγραφική ακρίβεια σε πραγματικά οδικά δίκτυα.



Σχήμα 19: Κατανομή μήκους ακολουθίας διαδρομών για το (a) πραγματικό και το (b) συνθετικό σύνολο δεδομένων. Παρατηρείται υψηλή ομοιότητα μεταξύ των δύο κατανομών. [9]



Σχήμα 20: Εξέλιξη της Jensen–Shannon Divergence (JSD) Lin, 1991 κατά τη διάρκεια της εκπαίδευσης του Two-Stage GAN. Η σύγκλιση σε χαμηλή τιμή υποδεικνύει αποτελεσματική προσαρμογή της κατανομής των συνθετικών δεδομένων. [9]

4.2.4 LSTM-TrajGAN

Το LSTM-TrajGAN των Rao et al. (2021) [14] αποτελεί μια εξειδικευμένη εφαρμογή των Generative Adversarial Networks για τη σύνθεση συνθετικών τροχιών με κύριο στόχο την προστασία της ιδιωτικότητας χρηστών. Σε αντίθεση με παραδοσιακές τεχνικές ανωνυμοποίησης, όπως η γεωγραφική θόλωση (geomasking) ή η χωρική και χρονική γενίκευση, οι οποίες συχνά αλλοιώνουν σημαντικά τη χρησιμότητα των δεδομένων, το LSTM-TrajGAN επιδιώκει να παράγει νέες τροχιές που διατηρούν τα στατιστικά και χωροχρονικά πρότυπα των αρχικών δεδομένων χωρίς να επιτρέπουν την επαναταυτοποίηση χρηστών.

Πριν χρησιμοποιηθούν από το μοντέλο, οι πραγματικές τροχιές υφίστανται διαδικασία προεπεξεργασίας και κωδικοποίησης. Κάθε τροχιά αποτελείται από ακολουθία σημείων της μορφής:


$$\text{Traj} = \{(lat_i, lon_i, day_i, hour_i, category_i)\}_{i=1}^T$$

όπου περιλαμβάνονται:

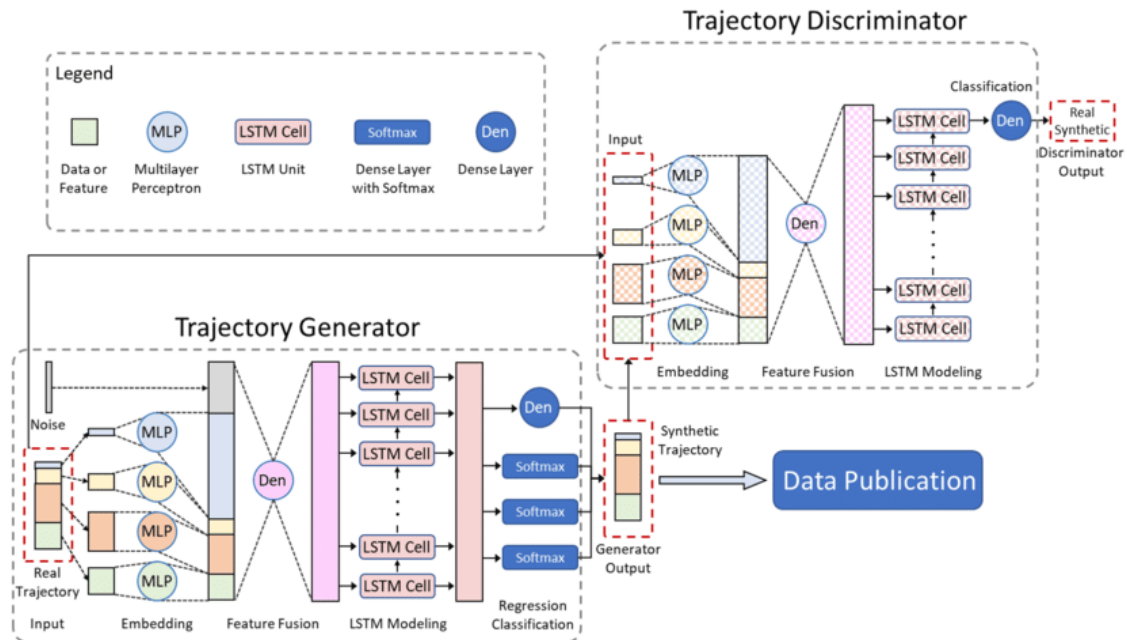
- χωρικά χαρακτηριστικά (γεωγραφικό πλάτος και μήκος),
- χρονικά χαρακτηριστικά (ημέρα και ώρα),
- θεματικά χαρακτηριστικά (κατηγορία σημείου ενδιαφέροντος POI).

Οι γεωγραφικές συντεταγμένες κανονικοποιούνται ως αποκλίσεις από το κέντρο του συνόλου δεδομένων, ενώ τα χρονικά και θεματικά χαρακτηριστικά κωδικοποιούνται μέσω one-hot encoding. Επειδή οι τροχιές έχουν διαφορετικό μήκος, εφαρμόζεται zero-padding ώστε όλες να αποκτούν κοινό μήκος, επιτρέποντας την εκπαίδευση σε παρτίδες (batch training) με χρήση LSTM.

Το αποτέλεσμα της διαδικασίας είναι ένας δισδιάστατος πίνακας χαρακτηριστικών για κάθε τροχιά, όπως απεικονίζεται στο Σχήμα 21.



Σχήμα 21: Κωδικοποίηση χωροχρονικών δεδομένων τροχιάς σε πίνακα [14]



Σχήμα 22: Η αρχιτεκτονική νευρωνικού δικτύου του μοντέλου LSTM-TrajGAN.[14]

Ο Generator αποτελείται από πέντε λειτουργικά επίπεδα:

1. είσοδος που περιλαμβάνει την κωδικοποιημένη πραγματική τροχιά και τυχαίο θόρυβο z
2. ενσωμάτωση (embedding) των επιμέρους χαρακτηριστικών (χωρικών, χρονικών και θεματικών) μέσω πολυεπίπεδων perceptrons (MLPs),
3. συγχώνευση (feature fusion) των embeddings και του θορύβου σε ενιαία αναπαράσταση,
4. ακολουθιακή μοντελοποίηση με many-to-many LSTM,
5. αποκωδικοποίηση των τελικών χαρακτηριστικών κάθε σημείου μέσω κατάλληλων επιπέδων εξόδου

Με τον τρόπο αυτό, ο Generator παράγει για κάθε σημείο της τροχιάς νέες γεωγραφικές συντεταγμένες, νέες χρονικές τιμές και νέες κατηγορίες POI, χρησιμοποιώντας tanh για συνεχείς χωρικές τιμές και softmax για κατηγορικές μεταβλητές.

Αντίστοιχα, ο Discriminator ακολουθεί παρόμοια λογική αναπαράστασης χωρίς τη χρήση θορύβου και χρησιμοποιεί many-to-one LSTM ώστε να παράγει μία συνολική δυαδική απόφαση (real/synthetic) για ολόκληρη την τροχιά.

Σε αντίθεση με τα κλασικά GANs που βασίζονται αποκλειστικά στην Binary Cross-Entropy, το LSTM-TrajGAN εισάγει τη συνάρτηση TrajLoss, η οποία συνδυάζει adversarial loss με πρόσθετους όρους που μετρούν την ομοιότητα πραγματικών και συνθετικών τροχιών σε χωρικό, χρονικό και θεματικό επίπεδο. Η συνολική απώλεια ορίζεται ως:

$$TrajLoss(y_r, y_p, t_r, t_s) = \alpha L_B CE(y_r, y_p) + \beta L_s(t_r, t_s) + \gamma L_t(t_r, t_s) + c L_c(t_r, t_s)$$

όπου L_s , L_t και L_c αντιστοιχούν σε χωρική, χρονική και θεματική ομοιότητα αντίστοιχα, ενώ οι συντελεστές α, β, γ, c ρυθμίζουν τη συνεισφορά κάθε όρου. Με τον τρόπο αυτό, ο Generator εκπαιδεύεται όχι μόνο να «ξεγελά» τον Discriminator, αλλά και να διατηρεί ουσιώδη χαρακτηριστικά των αρχικών δεδομένων.

Το LSTM-TrajGAN λαμβάνει ως είσοδο:

- κωδικοποιημένες πραγματικές τροχιές της μορφής $\{(lat, lon, day, hour, category)\}_t$
- τυχαίο διάνυσμα θορύβου z ,
- (μετά την προεπεξεργασία) τροχιές κοινού μήκους λόγω padding.

Το μοντέλο παράγει:


- συνθετικές τροχιές ίδιου μήκους με τις αρχικές, $\{(\widehat{lat}, \widehat{lon}, \widehat{day}, \widehat{hour}, \widehat{category})\}_t$
- τροχιές που διατηρούν στατιστικά χωρικά, χρονικά και θεματικά μοτίβα των πραγματικών δεδομένων, με μειωμένο κίνδυνο επαναταυτοποίησης.

Η μέθοδος αξιολογείται σε σενάρια προστασίας ιδιωτικότητας και χρησιμότητας δεδομένων, δείχνοντας (σύμφωνα με τους συγγραφείς) μειωμένη ικανότητα επαναταυτοποίησης χρηστών σε σχέση με κλασικές τεχνικές θορύβου/geomasking, ενώ διατηρεί ικανοποιητική ομοιότητα με τα πραγματικά δεδομένα ως προς χωρικά, χρονικά και θεματικά μοτίβα. Οι αξιολογήσεις βασίζονται τόσο σε μετρικές ιδιωτικότητας (π.χ. linking attacks) όσο και σε μετρικές ομοιότητας τροχιών και κατανομών.

Το LSTM-TrajGAN αποτελεί μια αποτελεσματική μέθοδο σύνθεσης συνθετικών τροχιών με έμφαση στην προστασία της ιδιωτικότητας. Σε αντίθεση με το Two-Stage GAN, δεν χρησιμοποιεί χωρική διακριτοποίηση ή εικόνες χάρτη, αλλά μαθαίνει απευθείας την ακολουθιακή δομή των τροχιών. Αν και δεν στοχεύει στη γεωμετρική ευθυγράμμιση με πραγματικά οδικά δίκτυα, προσφέρει ισχυρή προστασία ιδιωτικότητας και πλήρως end-to-end αρχιτεκτονική.

4.2.5 TS-TrajGen: Παραγωγή συνεχών τροχιών με Two-Stage GAN

Το TS-TrajGen των Jiang et al. (2023) [17] προτείνεται για το πρόβλημα της παραγωγής συνεχών τροχιών πάνω σε οδικό δίκτυο (continuous trajectories), δηλαδή τροχιών όπου κάθε διαδοχικό ζεύγος τμημάτων δρόμου είναι γειτονικό στο γράφημα του οδικού δικτύου. Σε αντίθεση με προσεγγίσεις που παράγουν διακριτοποιημένες ή μη-συνεχείς ακολουθίες, το TS-TrajGen στοχεύει σε τροχιές άμεσα αξιοποιήσιμες σε εφαρμογές αστικής προσομοίωσης.



Σχήμα 23: Αρχιτεκτονική TS-TrajGen: ο generator παράγει τροχιές με κόστος τύπου A* που συνδυάζει $g(\cdot)$ και $h(\cdot)$, ενώ ο discriminator παρέχει reward $R(T)$ ως άθροισμα sequential reward και mobility-yaw reward. [17]

Στο TS-TrajGen, ο generator καθοδηγείται από δύο εκπαιδευμένες συνιστώσες κόστους: $g(\cdot)$ και $h(\cdot)$ οι οποίες προεκπαιδεύονται με next-location prediction πριν από το adversarial fine-tuning, ώστε ο generator να ξεκινά από μια ρεαλιστική “πολιτική” κίνησης. Η $g(\cdot)$ λαμβάνει ως input τη μερική τροχιά $x_{1:i}$ ως ακολουθία (l_k, t_k) (road segment IDs και χρονικά slots), και επιστρέφει ως output μια τοπολογικά περιορισμένη κατανομή $P(l_j | x_{1:i})$ για το επόμενο road segment (μη γειτονικά segments έχουν πιθανότητα 0), άρα και το αντίστοιχο observed cost. Η $h(\cdot)$ λαμβάνει ως input έναν υποψήφιο δρόμο l_j , τον προορισμό l_d , τη δομή του road graph (adjacency) και road attributes, και παράγει ως output την εκτίμηση $P(l_j | l_d)$ (ή ισοδύναμα expected cost), δηλαδή πόσο “κατάλληλο” είναι το l_j ως επόμενο βήμα προς τον στόχο. Οι δύο συνιστώσες συνδυάζονται σε συνολικό κόστος τύπου A* ($f = g + h$), το οποίο καθορίζει την πολιτική κίνησης του generator για την επιλογή του επόμενου road segment δεδομένης της μερικής τροχιάς και του προορισμού.

Σε αντίθεση με το κλασικό A* [16] όπου οι συναρτήσεις κόστους βασίζονται σε απλή γεωμετρική απόσταση, στο TS-TrajGen το συνολικό κόστος f ενσωματώνει χρονική πληροφορία και “sequential moving state”, επιτρέποντας την εκμάθηση πιο ποικίλων προτύπων ανθρώπινης κίνησης, ενώ η συνιστώσα $h(\cdot)$ αξιοποιεί δομική αναπαράσταση του οδικού δικτύου μέσω GAT, βελτιώνοντας την καθοδήγηση προς τον προορισμό. Επιπλέον, ο discriminator δεν χρησιμοποιείται μόνο για διάκριση real/fake, αλλά παράγει σήμα βελτιστοποίησης (reward) για τον generator, το οποίο ορίζεται ως:

$$R(T) = R_s(T) + R_m(T)$$

Το R_s αξιολογεί τη ρεαλιστικότητα της τροχιάς ως χρονοσειρά μεταβάσεων (sequential reward), ενώ το R_m αξιολογεί τη χωρική ομοιότητα της τροχιάς σε επίπεδο διαδρομής για ίδιο OD (origin-destination), mobility yaw reward, με βάση DTW [18]. Για την εκτίμηση reward σε ενδιάμεσα βήματα μιας μερικής τροχιάς εφαρμόζεται Monte-Carlo rollout, ώστε το reward να λαμβάνει υπόψη και την πιθανή συνέχεια της διαδρομής.

Η στοχαστική παραγωγή τροχιάς βήμα-βήμα έχει το πρόβλημα της συσσώρευσης σφάλματος (error accumulation): αν ο generator κάνει ένα λάθος βήμα νωρίς, τα επόμενα βήματα “χτίζονται” πάνω σε λάθος κατάσταση, κάτι που δυσκολεύει ιδιαίτερα τη δημιουργία μακρών διαδρομών και την επίτευξη του προορισμού. Για να αντιμετωπιστεί αυτό, το TS-TrajGen εισάγει μια two-stage διαδικασία παραγωγής βασισμένη σε A* search:

- στο 1ο στάδιο παράγεται πρώτα μια “χονδρική” τροχιά σε επίπεδο δομικών περιοχών (structural regions) του οδικού δικτύου,
- στο 2ο στάδιο παράγεται η τελική continuous τροχιά σε επίπεδο road segments υπό την καθοδήγηση της regional τροχιάς.

Η χρήση A* επιτρέπει, επιπλέον, ‘rollback’ σε καλύτερες μερικές λύσεις (διατηρεί πολλαπλές υποψήφιες μερικές διαδρομές και επεκτείνει κάθε φορά την καλύτερη), ενώ η two-stage στρατηγική μειώνει την πολυπλοκότητα και περιορίζει το πρόβλημα στις κατάλληλες υποπεριοχές του γράφου.

Στο 1ο στάδιο (regional trajectory generation), το οδικό δίκτυο χωρίζεται σε k structural regions με multilevel graph partitioning, ώστε οι περιοχές να είναι σχετικά ανεξάρτητες και παρόμοιου μεγέθους.

Ως είσοδος χρησιμοποιούνται origin–destination και start time (l_s, l_d, t_s) , τα οποία δειγματοληπτούνται από ιστορική OD πληροφορία (μετρημένη από τα δεδομένα), και στη συνέχεια τα l_s, l_d αντιστοιχίζονται στις αντίστοιχες περιοχές (r_s, r_d) . Έξοδος του 1ου σταδίου είναι μια ακολουθία περιοχών (regional trajectory).


Στο 2ο στάδιο (road-level continuous generation), η regional τροχιά μετατρέπεται σε road-level μέσω ενός συνόλου boundary road segments S_{r_i, r_j} που ορίζεται για κάθε ζεύγος διαδοχικών περιοχών (r_i, r_j) , ενώ για κάθε boundary segment υπολογίζεται εκ των προτέρων η ιστορική συχνότητα επίσκεψης. Στη συνέχεια επιλέγονται boundary segments (με πιθανότητες ανάλογες της συχνότητας) και σχηματίζεται μια discontinuous (αραιή) ακολουθία T , η οποία λειτουργεί ως οδηγός. Στη συνέχεια, ο road-level generator ολοκληρώνει την τροχιά μεταξύ κάθε διαδοχικού ζεύγους (l_i, l_{i+1}) της T , παράγοντας την τελική continuous τροχιά πάνω στο οδικό δίκτυο, περιορίζοντας την αναζήτηση σε μικρότερες υποπεριοχές αντί για όλο το δίκτυο.

Οι συγγραφείς αξιολογούν το TS-TrajGen σε πραγματικά taxi datasets (με map matching στο road network) τόσο σε macro-similarity (κατανομές/OD) όσο και σε micro-similarity (ομοιότητα τροχιών για ίδιο OD). Παρουσιάζουν επίσης μελέτες περίπτωσης (next-location prediction, traffic control simulation) που υποστηρίζουν τη χρησιμότητα των συνθετικών continuous trajectories σε σενάρια προσομοίωσης.

4.3 Mobility GPT

Το MobilityGPT των Haydari et al. (2024) [19] αντιμετωπίζει την παραγωγή τροχιών σαν μια διαδικασία όπου το μοντέλο προβλέπει βήμα–βήμα το επόμενο τμήμα δρόμου (road link), όπως ένα μοντέλο κειμένου προβλέπει την επόμενη λέξη. Στόχος δεν είναι μόνο να βγαίνουν “λογικές” ακολουθίες, αλλά και (α) να αναπαράγονται οι συνηθισμένες μετακινήσεις από περιοχή σε περιοχή (αφετηρία–προορισμός) και (β) οι διαδρομές να

είναι όντως εφικτές πάνω στο οδικό δίκτυο, δηλαδή κάθε επόμενο τμήμα να συνδέεται με το προηγούμενο. Για αυτό το MobilityGPT χρησιμοποιεί δύο ιδέες στην εκπαίδευση: δίνει μεγαλύτερη έμφαση σε συχνά ζευγάρια αφετηρίας–προορισμού (gravity sampling) και περιορίζει τις επιλογές του επόμενου δρόμου μόνο σε συνδεδεμένα τμήματα (Road Connectivity Matrix).



Σχήμα 24: Επισκόπηση του πλαισίου MobilityGPT για παραγωγή συνθετικών τροχιών . [19]

Όπως φαίνεται στο Σχήμα 24, το MobilityGPT εκπαιδεύεται σε τρία στάδια. Πρώτα, προεκπαιδεύεται σε ακολουθίες οδικών τμημάτων (road links), χρησιμοποιώντας (α) ένα gravity-based σχήμα δειγματοληψίας για να δίνει έμφαση στις βασικές ροές αφετηρίας–προορισμού (OD) και (β) τον πίνακα συνδεσιμότητας RCM, ώστε τα διαδοχικά τμήματα που παράγονται να είναι πραγματικά συνδεδεμένα στο οδικό δίκτυο. Έπειτα, δημιουργείται ένα μοντέλο ανταμοιβής (reward model) που βαθμολογεί τις παραγόμενες τροχιές με βάση μετρήσιμα κριτήρια, χωρίς ανθρώπινη αξιολόγηση. Τέλος, το μοντέλο βελτιστοποιείται περαιτέρω με ενισχυτική μάθηση, αξιοποιώντας τη βαθμολογία του reward model για να παράγει τροχιές πιο κοντά στις πραγματικές.

Οι τροχιές μετατρέπονται μέσω map-matching [25], δηλαδή αντιστοίχισης GPS σημείων σε οδικά links του γράφου $D(V,E)$, ώστε μια συνεχής ακολουθία (lat,lon) να μετατραπεί σε διακριτή ακολουθία οδικών τμημάτων (discretization σε road segments). Η διαδικασία αυτή συμβάλλει στη μείωση σφαλμάτων που σχετίζονται με το GPS. Οι προκύπτουσες διαδρομές αναπαρίστανται ως link trajectories:

$$\Phi = (\phi_1, \phi_2, \dots, \phi_T)$$

όπου ϕ_i είναι το i -οστό road link της διαδρομής. Επιπλέον, σε κάθε τροχιά προστίθεται ένα ειδικό token τερματισμού $\langle \text{EOT} \rangle$, ώστε η τελική ακολουθία να γράφεται ως $(\phi_1, \dots, \phi_T, \langle \text{EOT} \rangle)$. Το MobilityGPT αντιμετωπίζει την τροχιά ως ακολουθία tokens και εκπαιδεύεται να προβλέπει το επόμενο token με βάση τα προηγούμενα, όπως στα γλωσσικά μοντέλα. Κατά την παραγωγή η ακολουθία επεκτείνεται βήμα βήμα μέχρι να παραχθεί το $\langle \text{EOT} \rangle$.

Το gravity model χρησιμοποιείται ως μηχανισμός δειγματοληψίας κατά το training. Συγκεκριμένα, οι τροχιές επιλέγονται με τρόπο που δίνει μεγαλύτερη πιθανότητα σε διαδρομές που αντιστοιχούν σε “σημαντικές” ροές OD μεταξύ περιοχών. Με αυτόν τον τρόπο, το μοντέλο εκτίθεται συχνότερα σε κυρίαρχες χωρικές ροές και μαθαίνει καλύτερα τα μακροσκοπικά πρότυπα μετακίνησης, χωρίς να απαιτείται επιπλέον πληροφορία πέρα από τις ίδιες τις τροχιές.

Παρότι η αναπαράσταση με road links μειώνει τα σφάλματα από τα GPS σημεία, ένα γενετικό μοντέλο μπορεί ακόμη να παράγει μη εφικτές μεταβάσεις link→link. Για τον περιορισμό αυτού του φαινομένου, κατασκευάζεται ένας πίνακας συνδεσιμότητας RC από τις πραγματικές τροχιές, ο οποίος κωδικοποιεί ποιες μεταβάσεις επιτρέπονται στο πραγματικό οδικό δίκτυο:

$$RC_{\phi_x, \phi_y} = \begin{cases} 1, \text{αν } (\phi_x, \phi_y) \text{ εμφανίζεται ως διαδοχικό ζεύγος σε κάποια } \Phi, \\ \quad \text{ή ανήκει στην τελευταία γραμμή/στήλη} \\ 0, \text{διαφορετικά} \end{cases}$$


Η επιπλέον “τελευταία” γραμμή και στήλη, γεμάτες με 1s, προστίθενται για να διευκολύνουν την παραγωγή του ειδικού token τερματισμού $\langle \text{EOT} \rangle$. Στη συνέχεια, ο RC ενσωματώνεται πριν από το softmax στην έξοδο της τελευταίας γραμμικής στρώσης του Transformer. Συγκεκριμένα, αν F συμβολίζει τα logits (την έξοδο της τελευταίας γραμμικής στρώσης), τότε:

$$F' = F \cdot RC$$

και οι τελικές πιθανότητες υπολογίζονται ως:

$$\text{Softmax}(F')$$

Με αυτόν τον μηχανισμό, το μοντέλο “φιλτράρει” τις υποψήφιες επιλογές του επόμενου link, ώστε να λαμβάνονται υπόψη μόνο μεταβάσεις που είναι πράγματι συνδεδεμένες/παρατηρημένες στο πραγματικό οδικό δίκτυο. Έτσι ενισχύεται η τοπολογική εγκυρότητα και η συνέχεια των παραγόμενων link trajectories.



Σχήμα 25: Σχήμα κατασκευής του fine-tuning dataset για Reinforcement Learning from Trajectory Feedback (RLTF) [19].

Το MobilityGPT ενισχύεται περαιτέρω μέσω fine-tuning με Reinforcement Learning from Trajectory Feedback (RLTF) Σχήμα 25. Η βασική ιδέα είναι η κατασκευή ενός trajectory-aware preference dataset χωρίς ανθρώπινη εποπτεία. Για κάθε prompt που προκύπτει από μια μερική τροχιά, το μοντέλο παράγει δύο εναλλακτικές ολοκληρώσεις (completions), οι οποίες συγκρίνονται ως προς την ομοιότητά τους με την τροχιά αναφοράς με βάση ένα ποσοτικό κριτήριο (όπως για παράδειγμα ομοιότητα μήκους τροχιάς). Η ολοκλήρωση με μικρότερη απόκλιση επισημαίνεται ως Φ_{chosen} , ενώ η άλλη ως Φ_{rejected} , σχηματίζοντας ζευγάρια προτίμησης. Στη συνέχεια, το παραγόμενο reward dataset χρησιμοποιείται για την εκπαίδευση ενός reward model U με επιβλεπόμενη μάθηση, και το προεκπαιδευμένο MobilityGPT βελτιστοποιείται με policy optimization (PPO), όπου το U παρέχει το σήμα ανταμοιβής που κατευθύνει την πολιτική προς παραγωγή τροχιών πιο συνεπών με τα χαρακτηριστικά των πραγματικών δεδομένων.

Ως κύρια είσοδο, το MobilityGPT δέχεται tokenized link trajectories (road links ως tokens μετά από map-matching). Κατά την εκπαίδευση, η διαδικασία καθοδηγείται από δύο priors: (i) gravity-aware sampling, που δίνει έμφαση σε σημαντικές ροές OD, και (ii) Road Connectivity Matrix (RCM), που περιορίζει τις επιτρεπτές μεταβάσεις link→link. Κατά την παραγωγή, το μοντέλο μπορεί να λάβει ως prompt μια μερική ακολουθία links και να τη συνεχίσει μέχρι τερματισμό. Ως έξοδο παράγει συνθετικές link trajectories, δηλαδή νέες ακολουθίες road links, με υψηλή τοπολογική εγκυρότητα (connectivity) και καλύτερη συμφωνία με μακρο-κατανομές κινητικότητας, όπως οι OD ροές.

Η αξιολόγηση του MobilityGPT γίνεται συγκρίνοντας τις συνθετικές με τις πραγματικές τροχιές ως προς μετρικές χρησιμότητας. Συγκεκριμένα, χρησιμοποιείται το Query Error Chen et al., 2011 [21], για μετρήσεις συχνότητας σε road links και η Jensen–Shannon divergence (JSD) Lin, 1991 [20], για σύγκριση κατανομών (OD, μήκος διαδρομής, radius και gravity), ενώ εισάγεται και μετρική connectivity ως ποσοστό πλήρως συνδεδεμένων link trajectories. Τα αποτελέσματα δείχνουν ότι το MobilityGPT υπερέχει των baseline μοντέλων στις παραπάνω μετρικές.

Συνοψίζοντας, το MobilityGPT είναι μια προσέγγιση τύπου GPT για παραγωγή συνθετικών τροχιών, με εκπαίδευση σε δύο στάδια: προεκπαίδευση (gravity-aware sampling και RCM για OD ροές και συνδεσιμότητα) και fine-tuning με RLTF χωρίς ανθρώπινη αξιολόγηση. Τα πειράματα δείχνουν ότι παράγει ρεαλιστικές τροχιές και βελτιώνει σημαντικά τη συμφωνία με τα πραγματικά δεδομένα σε βασικές μετρικές. Ωστόσο, το μοντέλο δεν παρέχει τυπικές εγγυήσεις ιδιωτικότητας.


4.4 TrajGail

Το TrajGAIL των Choi et al. (2021) [24] αντιμετωπίζει τη δημιουργία αστικών τροχιών οχημάτων ως πρόβλημα imitation learning. Αντί να «προβλέπει» απλώς το επόμενο σημείο, μαθαίνει να μιμείται τις πραγματικές διαδρομές και να παράγει νέες, συνθετικές τροχιές ως ακολουθίες από road links στο οδικό δίκτυο. Για να το πετύχει, συνδυάζει μια μοντελοποίηση της κίνησης ως σειρά διαδοχικών αποφάσεων με ένα adversarial σχήμα τύπου GAIL: ένας discriminator προσπαθεί να ξεχωρίσει τις πραγματικές από τις παραγόμενες τροχιές και το σήμα του χρησιμοποιείται ως reward ώστε ο generator να βελτιώνεται και να παράγει όλο και πιο ρεαλιστικές διαδρομές.

Οι αρχικές τροχιές GPS προεπεξεργάζονται με link matching (map matching [25] σε επίπεδο οδικών συνδέσμων), ώστε κάθε διαδρομή να αναπαρίσταται ως ακολουθία IDs συνδέσμων (link sequence). Με αυτόν τον τρόπο το πρόβλημα μοντελοποιείται ως επιλογή διαδρομής link to link πάνω σε οδικό δίκτυο.


Η παραγωγή της ακολουθίας διατυπώνεται ως σειριακή λήψη αποφάσεων: κάθε βήμα αντιστοιχεί σε επιλογή κίνησης στο τέλος ενός συνδέσμου, δηλαδή σε μια διασταύρωση. Παρότι μια απλή MDP (διαδικασία λήψης αποφάσεων Markov) υπόθεση θα έλεγε ότι η επιλογή εξαρτάται μόνο από τον τρέχοντα σύνδεσμο, οι συγγραφείς επισημαίνουν ότι η πραγματική συμπεριφορά εξαρτάται και από το ιστορικό της διαδρομής και από λανθάνουσες μεταβλητές (π.χ. προέλευση, προορισμός, σκοπός μετακίνησης, κατάσταση κυκλοφορίας). Για τον λόγο αυτό υιοθετείται μερικώς παρατηρήσιμη διαδικασία Markov POMDP, όπου οι παρατηρήσεις (observations) αντιστοιχούν σε link IDs και εμπλουτίζονται με δύο ειδικά tokens Start και End για την έναρξη και τον τερματισμό της τροχιάς, ενώ το “belief state” εκτιμάται από το ιστορικό παρατηρήσεων με RNN.

Για να περιοριστεί η υπολογιστική πολυπλοκότητα, αντί για τεράστιο action space όλων των δυνατών μεταβάσεων link→link, χρησιμοποιείται ένα μικρό κοινό σύνολο ενεργειών $a_t \in \{\text{Straight, Left, Right, Terminate}\}$ (σε πιο γενικά οδικά δίκτυα, οι μη εφικτές ενέργειες μπορούν να αποκλείονται μέσω masking), παρέχοντας ένα σταθερό “λεξιλόγιο” ενεργειών σε όλο το δίκτυο. Τέλος, το paper εστιάζει στην παραγωγή της διαδρομής ως ακολουθίας road links (χωρίς ρητή μοντελοποίηση του χρονικού σκέλους).



Σχήμα 26: POMDP: Στο παρατηρήσιμο επίπεδο (κάτω) βρίσκονται οι παρατηρήσεις $\mathbf{o}_t$ (π.χ. road links), οι ενέργειες $\mathbf{a}_t$ (επιλογές κίνησης), η κατάσταση $\mathbf{s}_t$ και η ανταμοιβή $\mathbf{r}_t$. Στο μη παρατηρήσιμο επίπεδο (πάνω) η μη παρατηρήσιμη κατάσταση “belief” $\mathbf{s}_t^*$ (και η αντίστοιχη $\mathbf{r}_t^*$) συνοψίζει κρυφές πληροφορίες και εξάρτηση από το ιστορικό, στο TrajGAIL εκτιμάται από την ακολουθία παρατηρήσεων (μέσω RNN) ώστε η πολιτική να λαμβάνει αποφάσεις με βάση το πλαίσιο της διαδρομής και όχι μόνο τον τρέχοντα σύνδεσμο. [24]

Στη συνέχεια, το TrajGAIL ενσωματώνει το σχήμα Generative Adversarial Imitation Learning (GAIL), όπου η πολιτική (generator) βελτιώνεται μέσω ενός σήματος ανταμοιβής που προέρχεται από έναν discriminator. Σε αντίθεση με επιβλεπόμενες προσεγγίσεις πρόβλεψης επόμενου link, το TrajGail βελτιστοποιεί μια πολιτική ως προς τη συνολική ποιότητα διαδρομής. Το συνολικό πλαίσιο του TrajGAIL φαίνεται στο Σχήμα 27: ο generator (ως RL agent) παράγει τροχιές μέσω αλληλεπίδρασης με το οδικό “περιβάλλον”, ενώ ο discriminator (ως IRL agent) αποδίδει ανταμοιβή που κατευθύνει την εκπαίδευση της πολιτικής.



Σχήμα 27: Πλαίσιο μοντέλου TrajGAIL: ο generator (policy generator + value estimator) παράγει τροχιές (policy roll-out) και αλληλεπιδρά με το περιβάλλον μέσω look-up επόμενης παρατήρησης, ενώ ο discriminator παρέχει το reward $R(s_t, a_t)$ που χρησιμοποιείται για τη βελτίωση της πολιτικής. [24]

Ο generator λειτουργεί ως reinforcement learning (RL) agent: ξεκινά από το εικονικό token “Start” και εφαρμόζει διαδοχικά την πολιτική π_θ μέχρι να φτάσει στο token “End” (τερματισμός τροχιάς), δημιουργώντας μια πλήρη συνθετική ακολουθία links. Επειδή το πρόβλημα είναι POMDP, η ακολουθία παρατηρήσεων, link IDs $(o_1, \dots, o_t)$ μετασχηματίζεται σε belief state s_t μέσω RNN embedding layer, ώστε η απόφαση να εξαρτάται από το ιστορικό της τροχιάς. Με βάση το s_t , η πολιτική δίνει πιθανότητες ενεργειών:

$$\pi_\theta(a_t | s_t)$$

και η επόμενη παρατήρηση o_{t+1} προκύπτει από look-up μετάβασης του περιβάλλοντος (οδικό δίκτυο), δηλαδή από τη χαρτογράφηση $(o_t, a_t) \mapsto o_{t+1}$.

Για να σταθεροποιηθεί η εκπαίδευση της πολιτικής και να εκτιμάται το “πόσο καλό” είναι ένα action μέσα στο πλαίσιο της υπόλοιπης διαδρομής, το TrajGAIL εισάγει state-action value $Q(s_t, a_t)$ μέσω ξεχωριστού value network (και αυτό με δικό του RNN embedding). Αν ένα action έχει υψηλό Q , το policy ενισχύεται να το διαλέγει πιο συχνά. Το value


network εκπαιδεύεται με MSE ως προς το discounted return (πόσο καλό είναι το action σε αυτή τη φάση με βάση και το υπόλοιπο της διαδρομής).

Ο discriminator λύνει πρόβλημα δυαδικής ταξινόμησης: λαμβάνει ως είσοδο το ζεύγος (s_t, a_t) (belief state από το ιστορικό + δράση στο τελευταίο βήμα) και επιστρέφει πιθανότητα ότι το δείγμα να είναι generated. Εκπαιδεύεται με binary cross-entropy. Κεντρικό στοιχείο του πλαισίου αποτελεί το γεγονός ότι ο discriminator ορίζει το σήμα ανταμοιβής προς τον generator (αυτό αντιστοιχεί σε IRL: το reward δεν δίνεται χειροκίνητα, αλλά μαθαίνεται από expert trajectories μέσω του discriminator):

$$r(s_t, a_t) = -\log D_\omega(s_t, a_t)$$

Έτσι, όσο πιο δύσκολα διακρίσιμη είναι μια τροχιά, τόσο μεγαλύτερη ανταμοιβή λαμβάνει η πολιτική.

Στο TrajGAIL υπάρχουν τρία διαφορετικά objectives (policy objective, value objective, discriminator objective) και το καθένα ενημερώνει μόνο τα αντίστοιχα παραμετρικά μέρη του μοντέλου, με ξεχωριστές RNN embeddings ανά module (policy/value/discriminator), ώστε το κάθε υποδίκτυο να “διαβάζει” την ακολουθία με τρόπο χρήσιμο για τον στόχο του. Η ροή ενημέρωσης των παραμέτρων φαίνεται στο Σχήμα 28: τα objectives για policy, value και discriminator υπολογίζονται ξεχωριστά και τα gradients διαδίδονται μόνο στα αντίστοιχα υποδίκτυα, με ξεχωριστά RNN embeddings για κάθε module.



Σχήμα 28: Σχήμα backpropagation του TrajGAIL: τρεις διακριτοί στόχοι J_{policy} , J_{value} και $J_{discrim}$ ενημερώνουν αντίστοιχα το policy generator, το value estimator και τον discriminator, με ξεχωριστά RNN embedding layers ανά module. [24]

Για να αποφευχθεί σύγκλιση σε “στενή” πολιτική που παράγει μικρή ποικιλία τροχιών (local optimum λόγω σπανιότητας του reward σήματος στα αρχικά στάδια), προστίθεται όρος μεγιστοποίησης εντροπίας στην ενημέρωση της πολιτικής:

$$J(\theta) = J_{policy}(\theta) + \lambda H(\pi_\theta)$$

ώστε να ενθαρρύνεται εξερεύνηση και να μαθαίνεται καλύτερα η υποκείμενη κατανομή διαδρομών.

Οι συγγραφείς επισημαίνουν ότι μια απευθείας εφαρμογή του standard GAIL στην παραγωγή τροχιών μπορεί να οδηγήσει σε υπερβολικά μεγάλες διαδρομές με βρόχους (loops), επειδή ο generator μεγιστοποιεί αθροιστική ανταμοιβή και δεν υπάρχει εγγενής ποινή μήκους: περισσότερα βήματα $\Rightarrow$ μεγαλύτερο cumulative reward. Η εισαγωγή της POMDP διατύπωσης και η εκτίμηση belief state μέσω RNN επιτρέπει στην πολιτική να λαμβάνει υπόψη το ιστορικό επίσκεψης, ώστε να αποφεύγει μη ρεαλιστικές επαναλήψεις links.

Ως είσοδο, το TrajGAIL χρησιμοποιεί ακολουθίες παρατηρήσεων $o_{1:t}$ (IDs road links με tokens Start/End) και, σε κάθε βήμα, παράγει κατανομή πάνω στο μικρό action set $a_t \in \{\text{Straight, Left, Right, Terminate}\}$ μέσω της πολιτικής $\pi_\theta(a_t | s_t)$, όπου $s_t = f(o_{1:t})$ είναι RNN-based belief state. Ως έξοδο, παράγει μια πλήρη συνθετική τροχιά ως ακολουθία road links (roll-out από Start μέχρι End) που μιμείται τις κατανομές/μοτίβα δρομολόγησης των expert trajectories.

Το TrajGAIL αξιολογείται τόσο σε επίπεδο μεμονωμένης τροχιάς όσο και σε επίπεδο dataset. Σε trajectory level, χρησιμοποιούνται οι μετρικές BLEU των Papineni et al., 2002 [22] και METEOR των Banerjee & Lavie [23], 2005 για να εκτιμηθεί η ομοιότητα της παραγόμενης link-sequence με πραγματικές ακολουθίες. Οι συγγραφείς σημειώνουν ότι τέτοιες sequence level μετρικές είναι πιο κατάλληλες από element wise accuracy (π.χ. “ακρίβεια επόμενου link”), επειδή τοπικά μικρά λάθη μπορεί να υποτιμούν τη συνολική ποιότητα της τροχιάς.

Σε dataset-level, εξετάζεται η κατανομή routes: routes που δεν εμφανίζονται στο πραγματικό dataset χαρακτηρίζονται ως unknown και η απόσταση μεταξύ πραγματικής και συνθετικής κατανομής μετρείται με Jensen–Shannon divergence (JSD) Lin, 1991[20], όπου μικρότερη τιμή δηλώνει μεγαλύτερη ομοιότητα. Τέλος, για να μελετηθεί η επίδραση της πολυπλοκότητας των δεδομένων στην απόδοση, ορίζεται ένα μέτρο dataset complexity με βάση την entropy των μεταβάσεων link→link (link transition entropy) και εξετάζεται η σχέση της με τη JSD, όπου το TrajGAIL εμφανίζει μικρότερη ευαισθησία στην αύξηση πολυπλοκότητας (δηλαδή μεγαλύτερη robustness).

Συνοψίζοντας, το TrajGAIL παράγει συνθετικές τροχιές ως ακολουθίες road links, μαθαίνοντας πολιτική π_θ σε περιβάλλον οδικού δικτύου με σήμα ανταμοιβής που προκύπτει adversarial από discriminator. Η POMDP διατύπωση με RNN belief state επιτρέπει την ενσωμάτωση ιστορικού, ενώ ο όρος εντροπίας βοηθά στην αποφυγή πρόωρης χαμηλής ποικιλίας. Παρότι βελτιώνει μετρικές ομοιότητας και route-distribution έναντι baselines, δεν παρέχει εγγυήσεις ιδιωτικότητας και δεν μοντελοποιεί ρητά χρονικά χαρακτηριστικά (π.χ. χρόνους/ταχύτητες).

4.5 EETG-SVAE

Το EETG-SVAE (End-to-End Trajectory Generation with Spatiotemporal Validity using Sequential Variational Autoencoders) προτείνεται από τους Zhang et al. [26] ως μια βαθιά γενετική προσέγγιση τύπου VAE, ειδικά σχεδιασμένη για παραγωγή ρεαλιστικών τροχιών σε συνεχή χώρο. Το βασικό κίνητρο της μεθόδου είναι ότι πολλές υπάρχουσες deep generative προσεγγίσεις για τροχιές είτε:

1. αποτυγχάνουν να διαχωρίσουν τις παγκόσμιες global (λόγος/σκοπός και γενική δομή) από τις τοπικές local (πώς εκτελείται η διαδρομή, βήμα βήμα) σημασιολογίες μιας διαδρομής,
2. χρησιμοποιούν απλούς ανεξάρτητους priors, οι οποίοι δεν συλλαμβάνουν τη διαδοχική εξάρτηση των σημείων, ή
3. παράγουν τροχιές που παραβιάζουν χωροχρονικούς περιορισμούς, όπως κίνηση εκτός οδικού δικτύου ή μη ρεαλιστικές ταχύτητες.

Το EETG-SVAE στοχεύει να αντιμετωπίσει αυτά τα προβλήματα με ένα πλήρως end-to-end μοντέλο, το οποίο μαθαίνει απευθείας από δεδομένα τροχιών, χωρίς ρητές heuristics (κανόνες) ή εξωτερικά pipelines.

Κεντρική ιδέα του EETG-SVAE είναι ότι μια τροχιά μπορεί να αναλυθεί σε διακριτές αλλά αλληλεξαρτώμενες συνιστώσες:

- Global semantics: εκφράζουν τον γενικό σκοπό ή το μοτίβο της μετακίνησης (π.χ. μετακίνηση προς εργασία, περιήγηση, παραλαβή από αεροδρόμιο),
- Local semantics: περιγράφουν τις τοπικές αποφάσεις και μικρο-διακυμάνσεις κατά μήκος της διαδρομής (π.χ. επιλογή δρόμου),
- Dynamic priors: μοντελοποιούν την αλληλεξάρτηση κοντινών χρονικών βημάτων και αφαιρούν την υπόθεση i.i.d. (independent and identically distributed) στα διαδοχικά latent variables, ώστε η αβεβαιότητα να εξελίσσεται συνεκτικά στον χρόνο.


Σε αντίθεση με προσεγγίσεις που συμπιέζουν ολόκληρη την τροχιά σε μία ενιαία λανθάνουσα αναπαράσταση, το EETG-SVAE χρησιμοποιεί παραγοντοποιημένες λανθάνουσες μεταβλητές ώστε να διαχωρίζει ρητά τις global από τις local σημασιολογίες, ενώ οι dynamic priors μοντελοποιούν τη χρονική εξάρτηση της στοχαστικότητας.

Η γενετική διαδικασία του EETG-SVAE ορίζεται ως εξής:

- Πρώτα φτιάχνουν μια ακολουθία από priors $\Theta_{1:T}$ ξεκινώντας από ένα αρχικό $\Theta_0 \sim p(\Theta_0)$ (π.χ. unit Gaussian) και μετά παράγονται διαδοχικά $\Theta_{1:T}$ με $\Theta_t \sim p(\Theta_t | \Theta_{t-1})$.
- Για κάθε τροχιά δειγματοληπτείται ένα global latent $f \sim p_0(f)$ (π.χ. unit Gaussian), που “κρατάει” τη γενική σημασιολογία/σκοπό της διαδρομής.
- Για κάθε χρονικό βήμα δειγματοληπτούνται τα local latents $z_{1:T}$:
 - Για το πρώτο βήμα: z_1 τραβιέται από το Θ_1 (ουσιαστικά ο prior του πρώτου βήματος).
 - Για τα επόμενα βήματα: για $t \geq 2$, $z_t \sim p(z_t | z_{t-1}, \Theta_t)$, δηλαδή το z_t εξαρτάται και από το προηγούμενο z_{t-1} και από το τρέχον dynamic prior Θ_t .
- Τέλος παράγουν τα παρατηρούμενα σημεία s_t από:

$$s_t \sim p(s_t | z_t, f)$$

αλλά υπό περιορισμούς εγκυρότητας C (constrained by the violation function in C). Δηλαδή, η γενετική διαδικασία τιμωρεί ή αποκλείει άκυρες τροχιές μέσω του constraint/violation formulation που εισάγουν.



Σχήμα 29 Αρχιτεκτονική EETG-SVAE [26]

Σύμφωνα με την αρχιτεκτονική EETG-SVAE:

- το μοντέλο λαμβάνει σαν είσοδο την πραγματική τροχιά. Τα (x_t, y_t) περνάνε από ένα Coordinate encoding MLP (multi-layer perceptron) για να γίνουν πολυδιάστατες αναπαραστάσεις e_t .
- Ο πάνω global-semantic encoder (BiLSTM) κωδικοποιεί ολόκληρη την ακολουθία $\{e_t\}$ και από τις κρυφές καταστάσεις εκτιμά mean/variance για τη global λανθάνουσα f που αντιστοιχεί στη γενική σημασιολογία/μακρο-μοτίβο της διαδρομής.
- Ο κάτω αριστερά local-semantic encoder (BiLSTM + RNN) παράγει, σε κάθε χρονικό βήμα, τις κατανομές των time-step latents z_t (mean/variance $\rightarrow$ sampling). Αυτά είναι τα local/dynamic στοιχεία που αλλάζουν βήμα-βήμα.
- Κάτω δεξιά φαίνεται ο prior generator τύπου VRNN: ξεκινά από $\theta_0 \sim \mathcal{N}(0,1)$ και παράγει αλυσιδωτά $\theta_{1:T}$ με εξάρτηση $\theta_{t+1} | \theta_t$ (όχι i.i.d.). Αυτοί είναι οι dynamic priors που καθοδηγούν/επιβάλλουν συνεκτική στοχαστικότητα στον χρόνο.

- Ο decoder παίρνει το global f και το local z_t , τα κάνει concatenation σε joint αναπαράσταση και μετά με coordinate decoding MLP παράγει τα συνεχόμενα σημεία $s_t = (\hat{x}_t, \hat{y}_t)$.
- Το Spatiotemporal constraints στα δεξιά αντιστοιχεί στο ότι κατά την εκπαίδευση/βελτιστοποίηση εισάγουν validity constraints (π.χ. road compliance, speed/turn constraints κ.λπ.) ως learnable/constrained optimization όρο μέσω violation function.

Ένα βασικό πλεονέκτημα του EETG-SVAE είναι η ρητή ενσωμάτωση χωροχρονικών περιορισμών εγκυρότητας. Παραδείγματα τέτοιων περιορισμών περιλαμβάνουν:

- περιορισμό κίνησης εντός οδικού δικτύου,
- ανώτατα όρια ταχύτητας,
- αποφυγή μη ρεαλιστικών απότομων στροφών.

Οι περιορισμοί ορίζονται ρητά από τον χρήστη ως ένα σύνολο εγκυρότητας C (π.χ. δρόμοι, όρια ταχύτητας, γωνίες στροφής) και ενσωματώνονται απευθείας στο training objective μέσω constrained optimization/regularization όρου (violation formulation). Έτσι το μοντέλο εκπαιδεύεται να μειώνει την πιθανότητα παραγωγής άκυρων μοτίβων, αντί να βασίζεται σε εκ των υστέρων post-processing φιλτραρίσματα, κάτι που μπορεί να βελτιώσει και τη γενικευσιμότητα/robustness.

Η παραγόμενη τροχιά αξιολογείται με συνδυασμό μετρικών: MDE [27] (μέση απόσταση από reference/ground-truth τροχιά) για την πιστότητα σημείο-προς-σημείο, MMD [28] για το πόσο ταιριάζουν οι κατανομές βασικών χαρακτηριστικών (π.χ. γωνίες/μήκη τμημάτων, συνολικό μήκος, πυκνότητα/πλήθος σημείων) μεταξύ πραγματικών και συνθετικών τροχιών, καθώς και Novelty Score [29] για να ελέγχεται αν οι τροχιές δεν είναι απλές αντιγραφές του training set.

Συνοψίζοντας, το EETG-SVAE αποτελεί μια ισχυρή end-to-end βαθιά γενετική προσέγγιση για παραγωγή τροχιών, η οποία συνδυάζει παραγοντοποιημένες λανθάνουσες μεταβλητές, δυναμικούς priors και ρητή ενσωμάτωση χωροχρονικών περιορισμών εγκυρότητας στο objective.

Αποτελεί αντιπροσωπευτικό παράδειγμα του πώς τα deep generative models μπορούν να ξεπεράσουν περιορισμούς τόσο των παραδοσιακών στοχαστικών μοντέλων όσο και απλούστερων neural generative προσεγγίσεων ωστόσο, παρά τα πλεονεκτήματά του, το EETG-SVAE απαιτεί υπολογιστικά απαιτητική εκπαίδευση, εξαρτάται από τον σωστό και κατάλληλα διατυπωμένο ορισμό των περιορισμών, και παρουσιάζει αυξημένη αρχιτεκτονική πολυπλοκότητα σε σχέση με απλούστερα μοντέλα.

ΚΕΦΑΛΑΙΟ 5 Εφαρμογή

5.1.Dataset

Το Porto-Taxi dataset διατέθηκε αρχικά για διαγωνισμό πρόβλεψης τροχιών στο Kaggle και περιλαμβάνει GPS καταγραφές οχημάτων με περίοδο δειγματοληψίας 15 δευτερολέπτων. Στο πλαίσιο του TS-TrajGen, οι τροχιές αντιστοιχίζονται στο οδικό δίκτυο μέσω δεδομένων δρόμων από OpenStreetMap και εφαρμογής map matching, ώστε να προκύπτουν τροχιές ως ακολουθίες από αναγνωριστικά οδικών τμημάτων (road-segment IDs). Η αντιστοίχιση πραγματοποιείται με τον αλγόριθμο Fast Map Matching (FMM) των Can Yang και Gyozo Gidofalvi (2018) [30], ο οποίος μοντελοποιεί το πρόβλημα ως Hidden Markov Model και επιλέγει την πιθανότερη ακολουθία road segments λαμβάνοντας υπόψη την εγγύτητα των παρατηρήσεων στους υποψήφιους δρόμους και τη συνέπεια των μεταβάσεων πάνω στο γράφημα του δικτύου. Κατά την προεπεξεργασία απορρίπτονται μη φυσιολογικές τροχιές, όπως τροχιές πολύ μικρού μήκους (μήκος < 5) και τροχιές με βρόχους (loops).

Για την υλοποίηση χρησιμοποιήθηκαν τα map-matched δεδομένα Porto-Taxi που διατίθενται μαζί με το TS-TrajGen [17]. Για λόγους υπολογιστικού κόστους, επιλέχθηκε τυχαίο υποσύνολο 15% των μοναδικών τροχιών σε επίπεδο traj_id, ώστε καμία τροχιά να μην σπάσει μεταξύ train και test. Στη συνέχεια, το υποσύνολο χωρίστηκε σε train/test με αναλογία 80/20, διασφαλίζοντας ότι δεν υπάρχει επικάλυψη traj_id μεταξύ των δύο συνόλων, ώστε το test να περιέχει εντελώς άγνωστες τροχιές.

Τα δεδομένα περιέχουν και τα εξής αρχεία:

- porto.geo: περιγράφει τα τμήματα του οδικού δικτύου ως γραμμικά segments (11.095 εγγραφές), παρέχοντας γεωμετρία (lat-long) και χαρακτηριστικά όπως κατηγορία δρόμου, μήκος και μονόδρομος.
- .rel ορίζει τη συνδεσιμότητα του δικτύου ως κατευθυνόμενες σχέσεις segment→segment (26,161 εγγραφές), δηλαδή τις επιτρεπτές μεταβάσεις μεταξύ διαδοχικών road segments, οι οποίες χρησιμοποιούνται για να επιβάλλεται τοπολογική εγκυρότητα στις παραγόμενες τροχιές.

5.2. Προεπεξεργασία για Pretraining

Στο TS-TrajGen, πριν από το κύριο στάδιο εκπαίδευσης, απαιτείται η μετατροπή των map-matched τροχιών σε ένα σύνολο supervised παραδειγμάτων πρόβλεψης του επόμενου οδικού τμήματος (road segment). Για τον σκοπό αυτό χρησιμοποιήθηκε το script preprocess_pretrain_input.py, το οποίο παράγει τα αρχεία εισόδου του pretraining (train/eval/test) και βοηθητικές δομές του οδικού δικτύου.

Το script λαμβάνει ως είσοδο:

1. Map-matched trajectories (porto_mm_train.csv, porto_mm_test.csv)

Κάθε γραμμή αντιστοιχεί σε μία τροχιά και περιλαμβάνει:

- ✓ mm_id αναγνωριστικό εγγραφής του map-matched dataset
- ✓ user_id: αναγνωριστικό οχήματος
- ✓ traj_id: αναγνωριστικό τροχιάς.
- ✓ rid_list: η τροχιά ως ακολουθία road segment IDs, σε μορφή id1,id2,id3,...
- ✓ time_list: η αντίστοιχη ακολουθία χρονικών στιγμών (ISO timestamps) για κάθε στοιχείο του rid_list

	mm_id	user_id	traj_id		rid_list	time_list
0	736	20000436	736	9636,10886,9634,9631,9638,9630,282,277,291,289...	2013-07-01T16:03:34Z,2013-07-01T16:04:49Z,2013...	
1	2161	20000353	2167	7269,1112,10644,7268,1700,1825,1826,9236,1829,...	2013-07-01T21:00:26Z,2013-07-01T21:00:37Z,2013...	
2	4127	20000549	4142	10711,7076,4511,1049,881,892,879,8733,2365	2013-07-02T05:19:33Z,2013-07-02T05:19:48Z,2013...	
3	3053	20000621	3066	4170,10553,2679,2687,5304,5428,5455,5442,5456,...	2013-07-02T00:09:26Z,2013-07-02T00:09:41Z,2013...	
4	4128	20000129	4143	1109,1222,10550,5565,10549,10551,5561,826,9243...	2013-07-02T05:27:56Z,2013-07-02T05:28:41Z,2013...	

Σχήμα 30: Map Matched Dataset Porto Taxi

2. Οδικό δίκτυο.

- ✓ porto.geo: περιγραφή των road segments (γεωμετρία polyline (lon, lat) και χαρακτηριστικά όπως μήκος, κόμβος έναρξης και λήξης δρομου κλπ.).
- ✓ porto.rel: κατευθυνόμενη συνδεσιμότητα μεταξύ segments, μέσω ζευγών origin_id → destination_id

```
[porto.geo] separator: , | shape: (11095, 13)
```

geo_id	type	coordinates
0	LineString	[[-8.6406364, 41.1660713], [-8.6409114, 41.166...
1	LineString	[[-8.6406364, 41.1660713], [-8.6407202, 41.166...
2	LineString	[[-8.6420446, 41.168347], [-8.6423385, 41.1682...
3	LineString	[[-8.6420446, 41.168347], [-8.6422246, 41.1683...
4	LineString	[[-8.6415867, 41.1668853], [-8.6417347, 41.166...

highway	lanes	tunnel	bridge	roundabout	oneway	length	maxspeed
0	7	0	0	0	1	32.388	0
1	7	0	0	0	1	224.655	0
2	7	1	0	0	1	115.105	6
3	7	1	0	0	1	191.892	0
4	7	2	0	1	1	118.915	4

u	v
0 25503936	4722746638
1 25503936	281726624
2 25503951	1243857957
3 25503951	4507024043
4 25504027	1243857999

```
[porto.rel] separator: , | shape: (26161, 4)
```

rel_id	type	origin_id	destination_id
0	geo	0	10167
1	geo	0	10168
2	geo	1	1050
3	geo	1686	1050
4	geo	2	5397

Σχήμα 31: Οδικό δίκτυο .geo και .rel

Από τα αρχεία .geo και .rel, δημιουργούνται (εφόσον δεν υπάρχουν ήδη) τα παρακάτω βοηθητικά αρχεία:

- Adjacent_list.json: λεξικό γειτνίασης του γράφου, όπου για κάθε origin_id αποθηκεύεται η λίστα των επιτρεπτών επόμενων segments destination_id. Με τον τρόπο αυτό, οι επιτρεπτές μεταβάσεις segment→segment προκύπτουν απευθείας από το οδικό δίκτυο και χρησιμοποιούνται ως περιορισμός εγκυρότητας στα επόμενα βήματα.
- porto_rid_gps.json: λεξικό αντιστοίχισης geo_id → (lon, lat). Για κάθε segment του porto.geo, υπολογίζεται ένα αντιπροσωπευτικό σημείο (centroid) από τη γεωμετρία LineString και αποθηκεύεται ώστε να μπορούν να υπολογιστούν χωρικά χαρακτηριστικά, όπως αποστάσεις.


```

=== adjacent_list head ===
  origin_id (geo_id) destination_ids (neighbors) out_degree
0          0          [10167, 10168]           2
1          1          [1050]             1
2          2          [5397]             1
3          3          [9645]             1
4          4          [5404, 5405]        2

=== porto_rid_gps head ===
  geo_id centroid_lon centroid_lat
0      0    -8.640774    41.166174
1      1    -8.640678    41.166142
2      2    -8.642192    41.168312
3      3    -8.642135    41.168346
4      4    -8.641661    41.166941

```

Σχήμα 32: adjacent list και rid_gps

Τα timestamps του time_list μετατρέπονται σε διακριτές χρονικές τιμές με βάση το λεπτό της ημέρας. Συγκεκριμένα:

- για καθημερινές: $t = \text{hour} * 60 + \text{minute}$, απ' όπου προκύπτουν timestamps (0–1439),
- για Σαββατοκύριακο: $t = \text{hour} * 60 + \text{minute} + 1440$, με timestamps (1440–2879).

Έτσι, το μοντέλο λαμβάνει πληροφορία ημερήσιου κύκλου και διάκριση weekday/weekend.

Μετασχηματισμός τροχιών σε supervised δείγματα (Pretraining samples)

Για κάθε τροχιά, ορίζεται ως προορισμός des το τελικό road segment. Στη συνέχεια, το script παράγει δείγματα πρόβλεψης επόμενου βήματος σε διαφορετικά σημεία της τροχιάς, δημιουργώντας μία γραμμή δεδομένων ανά δείγμα με τα ακόλουθα πεδία:

- trace_loc: το prefix της τροχιάς μέχρι το τρέχον σημείο (π.χ. 9636,10886,9634,9631).
- trace_time: το αντίστοιχο prefix χρόνου μετά την παραπάνω κωδικοποίηση.
- des: ο τελικός προορισμός (τελικό segment της τροχιάς).

- `candidate_set`: το σύνολο επιτρεπτών επόμενων segments από το τρέχον segment, δηλαδή οι εξερχόμενοι γείτονες από το `adjacent_list.json`.
- `candidate_dis`: λίστα αποστάσεων (σε αντιστοίχιση 1-προς-1 με το `candidate_set`) από κάθε υποψήφιο segment προς τον προορισμό `des`, υπολογισμένων από τα centroids του `porto_rid_gps.json`.
- `target`: ο δείκτης (index) του πραγματικού επόμενου segment μέσα στη λίστα `candidate_set` (δηλαδή το label είναι ποια επιλογή είναι σωστή ανάμεσα στους επιτρεπτούς γείτονες).

Ως αποτέλεσμα, παράγονται τρία αρχεία pretraining:

- `porto_taxi_pretrain_input_train.csv`
- `porto_taxi_pretrain_input_eval.csv`
- `porto_taxi_pretrain_input_test.csv`

	trace_loc	trace_time	des	candidate_set	candidate_dis	target
	9636,10886,9634,9631	963,964,965,965	4868	9637,9638,9639	25.960959094825103,25.80133006516927,25.890251...	1
	9636,10886,9634,9631,9638,9630,282	963,964,965,965,965,965,965	4868	277,278,279	25.492202337076918,25.675940718232333,25.63090...	0
36,10886,9634,9631,9638,9630,282,277,291,289...	963,964,965,965,965,965,965,965,966,966,966,96...	4868	305,306,307	7.8056220743799845,10.054889058070657,8.950576...	2	
36,10886,9634,9631,9638,9630,282,277,291,289...	963,964,965,965,965,965,965,965,966,966,966,96...	4868	8955,8956	9.831602039459963,9.85694986578719	0	
36,10886,9634,9631,9638,9630,282,277,291,289...	963,964,965,965,965,965,965,965,966,966,966,96...	4868	7903,7904	10.926000544001603,10.441468672705852	1	

Σχήμα 33: Pretraining δεδομένα

5.3 1ο Στάδιο: Προεκπαίδευση road-level generator.

Η γεννήτρια του TS-TrajGen βασίζεται στη λογική του A^* και μοντελοποιεί την πολιτική κίνησης ως πιθανότητα επιλογής του επόμενου road segment, με κατάσταση που περιλαμβάνει (i) το μέχρι τώρα prefix και (ii) τον προορισμό. Στον πυρήνα, χρησιμοποιεί αποσύνθεση κόστους τύπου A^* :

$$f(l_i) = g() + h()$$

Function H (`pretrain_gat_fc.py`)

Στο TS-TrajGen, μετά τη δημιουργία των pretraining inputs, ακολουθεί η προεκπαίδευση της συνάρτησης H (expected cost). Η H στοχεύει να αποδώσει “βαθμολογία/κόστος” σε

υποψήφιες επόμενες μεταβάσεις, λαμβάνοντας υπόψη τη δομή του οδικού δικτύου (graph) και τη σχέση candidate → destination. Η προεκπαίδευση υλοποιείται με το script `pretrain_gat_fc.py`, το οποίο εκπαιδεύει ένα GAT-based μοντέλο (DistanceGatFC).

Το `pretrain_gat_fc.py` διαβάζει τα εξής αρχεία:

1. Pretraining datasets (από το preprocess στάδιο):

- `porto_taxi_pretrain_input_train.csv`
- `porto_taxi_pretrain_input_eval.csv`
- `porto_taxi_pretrain_input_test.csv`

2. Δομή γράφου οδικού δικτύου (adjacency matrix):

- `porto_adjacent_mx.npz`: αραιός πίνακας γειτνίασης A , όπου $A[i,j]=1$ δηλώνει ότι επιτρέπεται μετάβαση από το road segment i στο j .

3. Χαρακτηριστικά κόμβων (node features):

- `porto_node_feature.pt`: Τα features περιγράφουν ιδιότητες του road segment (π.χ. attributes από το `porto.geo`) και χρησιμοποιούνται ώστε το GAT να μάθει embeddings που συνδυάζουν τοπολογική πληροφορία (μέσω A) και σημασιολογικό περιεχόμενο (μέσω των features).

```
Loaded type: <class 'torch.Tensor'>
Tensor shape: (11896, 10) | dtype: torch.float32 | requires_grad: False
```

	id	f0	f1	f2	f3	f4	f5	f6	f7	f8	f9
0	0	7.0	0.0	0.0	0.0	1.0	0.0	0.014330	0.0	9.0	5.0
1	1	7.0	0.0	0.0	0.0	1.0	0.0	0.103716	0.0	9.0	5.0
2	2	7.0	1.0	0.0	0.0	1.0	0.0	0.052786	0.6	9.0	5.0
3	3	7.0	1.0	0.0	0.0	1.0	0.0	0.088484	0.0	9.0	5.0
4	4	7.0	2.0	0.0	1.0	1.0	0.0	0.054557	0.4	9.0	5.0


Σχήμα 34: Χαρακτηριστικά δρόμου


Η υλοποιείται με το μοντέλο DistanceGatFC, το οποίο:

- Μαθαίνει αναπαραστάσεις road segments μέσω GAT: εφαρμόζει Graph Attention Network πάνω στον γράφο του οδικού δικτύου (adjacency matrix) και στα node features, ώστε να παραγάγει embeddings για κάθε road segment που ενσωματώνουν τόσο τοπολογική πληροφορία (γειτονιά/συνδέσεις) όσο και σημασιολογικά χαρακτηριστικά (attributes του segment).
- Υπολογίζει score για κάθε υποψήφιο επόμενο βήμα: για κάθε δείγμα, συνδυάζει τα embeddings των candidates και του destination με το χαρακτηριστικό απόστασης candidate_dis (candidate $\rightarrow$ destination) και, μέσω ενός fully-connected scoring head, παράγει ένα score ανά candidate, το οποίο χρησιμοποιείται για να επιλεγεί ο καταλληλότερος επόμενος road segment.

Η εκπαίδευση διατυπώνεται ως πρόβλημα ταξινόμησης πάνω στο candidate set. Για κάθε δείγμα, το μοντέλο παράγει ένα score ανά υποψήφιο candidate και εκπαιδεύεται ώστε να δίνει τη μέγιστη βαθμολογία στον σωστό candidate.

Μετά την ολοκλήρωση της εκπαίδευσης αποθηκεύεται το τελικό μοντέλο με όνομα gat_fc.pt, το οποίο χρησιμοποιείται στα επόμενα στάδια του pipeline.





Σχήμα 35: Accuracy/Loss GAT-FC

Στο Porto Taxi, το train loss μειώνεται σταθερά ανά epoch, δείχνοντας ομαλή σύγκλιση. Το validation accuracy κορυφώνεται νωρίς (peak στο epoch 2) και στη συνέχεια παρουσιάζει plateau με μικρές διακυμάνσεις, υποδεικνύοντας ότι επιπλέον epochs δίνουν περιορισμένα κέρδη στη γενίκευση. Ο scheduler ReduceLROnPlateau μειώνει απότομα το learning rate μετά από διαδοχικά epochs, χωρίς βελτίωση στο validation στο συγκεκριμένο run, η μείωση του LR δεν οδηγεί σε νέα κορυφή απόδοσης. Η απόδοση στο test είναι 0.7679, κοντά στο best validation (0.7762), γεγονός που υποδηλώνει μικρό generalization gap, το μοντέλο παρουσιάζει ικανοποιητική απόδοση και εκτός δεδομένων που είδε στην εκπαίδευση, άρα η γενίκευση είναι σχετικά σταθερή (όχι έντονο overfitting).

Function G (pretrain_function_g_fc.py)

Η προεκπαίδευση της Function G (Generator v1) υλοποιείται με το FunctionGFC, το οποίο μαθαίνει μια πολιτική επιλογής επόμενης μετάβασης (next-hop) υπό μορφή ταξινόμησης πάνω στο candidate set.

Για κάθε δείγμα, το μοντέλο λαμβάνει ως είσοδο:

- trace_loc: ακολουθία road IDs του ιστορικού (μέχρι το τρέχον βήμα)
- trace_time: ακολουθία χρονικών bins για τα αντίστοιχα βήματα
- des: προορισμός (destination ID)

- `candidate_set`: λίστα επιτρεπτών επόμενων road IDs (outgoing neighbors από το τρέχον segment)
- `candidate_dis`: αποστάσεις `candidate`→`destination`
- `target`: θέση (index) του πραγματικού next hop μέσα στο `candidate_set`


Η G υλοποιείται με το μοντέλο FunctionGFC, το οποίο:

- Κωδικοποιεί το ιστορικό της τροχιάς ως ακολουθία (sequence encoder): μετατρέπει τα `trace_loc` (road IDs) και `trace_time` (time bins) σε διανυσματικές αναπαραστάσεις (embeddings) μέσω embedding layers, τα συνενώνει σε ένα ενιαίο διάνυσμα εισόδου ανά χρονικό βήμα και τα τροφοδοτεί σε LSTM για να μάθει τη χρονική εξάρτηση της κίνησης. Επειδή τα ιστορικά έχουν διαφορετικά μήκη, εφαρμόζεται padding και χρησιμοποιείται mask ώστε το LSTM να επεξεργάζεται μόνο τα πραγματικά βήματα (αγνοώντας τα padded). Το αποτέλεσμα είναι μια συμπαγής αναπαράσταση της μέχρι τώρα πορείας που συνοψίζει το κινητικό μοτίβο του οχήματος.
- Ενισχύει την αναπαράσταση με intra-trajectory attention: μετά το LSTM, το μοντέλο διαθέτει μια ακολουθία hidden states για όλα τα βήματα του ιστορικού. Χρησιμοποιεί ως *query* το τελευταίο μη-padded state και υπολογίζει βάρη attention για κάθε χρονικό βήμα (με masking στα padded), ώστε να σχηματίσει το `attn_hidden` ως σταθμισμένο άθροισμα των hidden states.
- Παράγει score για κάθε υποψήφιο επόμενο βήμα μέσω FC και περιορισμού στους candidates: το τελικό διάνυσμα κατάστασης `attn_hidden` περνά από ένα fully-connected (linear) layer που παράγει logits για όλα τα road segments. Στη συνέχεια, εφαρμόζεται gather ώστε να διατηρηθούν μόνο τα logits που αντιστοιχούν στα IDs του `candidate_set`, με αποτέλεσμα ένα score ανά candidate. Η επιλογή του επόμενου road segment γίνεται ως Top-1 (argmax του score) πάνω στο `candidate set`.

Η εκπαίδευση της Function G διατυπώνεται ως πρόβλημα ταξινόμησης πάνω στο candidate set. Για κάθε δείγμα, το μοντέλο παράγει ένα score ανά υποψήφιο candidate (με βάση την κωδικοποίηση του ιστορικού μέσω LSTM+attention) και εκπαιδεύεται ώστε η

υψηλότερη βαθμολογία να αντιστοιχεί στον σωστό candidate (στόχος target, δηλαδή το index του πραγματικού next-hop μέσα στο candidate set).

Μετά την ολοκλήρωση της προεκπαίδευσης αποθηκεύεται το τελικό μοντέλο με όνομα `function_g_fc.pt`, το οποίο αξιοποιείται στα επόμενα στάδια του pipeline.



Σχήμα 36: Accuracy/Loss GFC

Στο Porto Taxi, το FunctionGFC παρουσιάζει σταθερή μείωση του train loss και αύξηση του validation Top-1 accuracy έως περίπου το epoch 6 (88.33%), μετά το οποίο παρατηρείται plateau. Η τελική επίδοση στο test set είναι 88.28%, πολύ κοντά στο validation, υποδηλώνοντας πολύ μικρό generalization gap και σταθερή γενίκευση.

Παρότι τόσο η G όσο και η H προεκπαιδεύονται ως ταξινόμηση πάνω στο candidate set, η G μαθαίνει μια πολιτική μετάβασης που εξαρτάται από το ιστορικό/χρόνο (sequence model), ενώ η H μαθαίνει ένα cost/score που στηρίζεται κυρίως στη δομή του οδικού γράφου και στη σχέση candidate→destination (graph model).

5.4 2ο Στάδιο Region Level generator.

Το TS-TrajGen υιοθετεί two-stage (ιεραρχική) παραγωγή: πρώτα παράγει μια “χοντρική” διαδρομή σε επίπεδο περιοχών (regions/traffic zones) και μετά τη λεπτομέρεια σε επίπεδο road segments. Ο βασικός λόγος είναι ότι η καθαρά βήμα-βήμα παραγωγή σε πολύ μεγάλο χώρο καταστάσεων (δεκάδες χιλιάδες road segments) συσσωρεύει σφάλμα: ένα μικρό λάθος νωρίς μπορεί να οδηγήσει την τροχιά να ξεφύγει και να καταλήξει σε μη ρεαλιστική ακολουθία. Με το region-level στάδιο, το μοντέλο μαθαίνει πρώτα τη μακροσκοπική ροή προς τον προορισμό και έπειτα γίνεται η λεπτομερής δρομολόγηση μέσα σε κάθε περιοχή.

Δημιουργία input για KaHIP (process_kahip_graph_format.py).

Για να δημιουργηθούν οι regions/traffic zones στο region-level στάδιο, το TS-TrajGen εφαρμόζει graph partitioning πάνω στο οδικό δίκτυο, χρησιμοποιώντας τη βιβλιοθήκη KaHIP. Ωστόσο, πριν εκτελεστεί το partitioning, απαιτείται το οδικό δίκτυο να μετατραπεί σε μορφή εισόδου συμβατή με το KaHIP.

Το script process_kahip_graph_format.py υλοποιεί αυτή την προεπεξεργασία: διαβάζει το road network (nodes από το .geo και συνδέσεις από το .rel) και κατασκευάζει έναν undirected Γράφο σε format KaHIP (.graph). Παράλληλα, εντοπίζει και αφαιρεί απομονωμένα road segments (segments που δεν συμμετέχουν σε καμία σύνδεση), ώστε να αποφευχθούν θόρυβοι και προβληματικές μικροσυστάδες στο partitioning. Τέλος, επειδή τα εργαλεία partitioning απαιτούν συνεχή αρίθμηση κόμβων, πραγματοποιεί re-indexing των road IDs και εξάγει το τελικό αρχείο γράφου, το οποίο χρησιμοποιείται ως είσοδος στο KaHIP για την παραγωγή των regions.

Graph partition με KaHIP / KaFFPa (process_kaffpa_res.py)

Εκτελείτε graph partitioning πάνω στον γράφο εισόδου (METIS/KaHIP format) με στόχο να δημιουργήσει k regions (blocks). Πρακτικά, ο αλγόριθμος χωρίζει το σύνολο των κόμβων σε 100 ομάδες παρόμοιου μεγέθους.

Το script `process_kaffpa_res.py` αποτελεί το βήμα μετατροπής του αποτελέσματος του graph partitioning (KaHIP/KaFFPa) σε δομές regions που μπορούν να χρησιμοποιηθούν από το υπόλοιπο pipeline. Συγκεκριμένα, διαβάζει το αρχείο partition (π.χ. `porto.partK`), το οποίο περιέχει για κάθε κόμβο/road segment του γράφου εισόδου την ετικέτα του region στο οποίο ανήκει, και το μετασχηματίζει σε δύο βασικές αντιστοιχίσεις: (i) `rid2region` (road-segment ID $\rightarrow$ region ID) και (ii) `region2rid` (region ID $\rightarrow$ λίστα road-segment IDs). Με αυτόν τον τρόπο ορίζονται ρητά οι traffic zones” ως σύνολα road segments, ώστε στη συνέχεια να είναι εφικτό (α) να χαρτογραφηθούν road-level τροχιές σε region-level ακολουθίες και (β) να κατασκευαστεί ο region graph (μεταβάσεις region $\rightarrow$ region) που απαιτείται για την εκπαίδευση και χρήση των region-level μοντέλων.

Region Preprocessing (construct_traffic_zone_relation.py)

Αφού οριστούν τα regions μέσω partitioning (δηλ. έχουμε τις αντιστοιχίσεις `rid2region` και `region2rid`), το επόμενο απαραίτητο βήμα στο region-level στάδιο είναι να κατασκευαστεί ο γράφος περιοχών (region graph): ποιες περιοχές μπορούν να ακολουθήσουν ποιες, με βάση τη συνδεσιμότητα του πραγματικού οδικού δικτύου. Το script `construct_traffic_zone_relation.py` υπολογίζει ακριβώς αυτές τις σχέσεις γειτνίασης μεταξύ regions, “ανεβάζοντας” τις road-level μεταβάσεις του `.rel` στο επίπεδο περιοχών.

- Διαβάζει το road-level αρχείο συνδεσιμότητας `.rel` (directed ακμές road $\rightarrow$ road) και χτίζει μια λίστα γειτόνων ανά road segment (adjacency list).
- Φορτώνει τις αντιστοιχίσεις road $\rightarrow$ region (`rid2region.json`) και region $\rightarrow$ roads (`region2rid.json`).
- Για κάθε region, εξετάζει όλες τις εξερχόμενες μεταβάσεις των road segments που περιέχει. Αν μια μετάβαση οδηγεί σε road segment που ανήκει σε διαφορετικό region, τότε καταγράφει μια directed σχέση region $\rightarrow$ next_region (δηλαδή επιτρέπεται μετάβαση από την περιοχή A στην περιοχή B).

outputs:

- `region_adj_mx.npz`: αραιός πίνακας γειτνίασης regions, όπου $A[r, r'] = 1$ δηλώνει ότι υπάρχει τουλάχιστον μία road-level μετάβαση από κάποιο road του region r προς κάποιο road του region r' .
- `region_adjacent_list.json`: λίστα γειτνίασης σε μορφή dictionary, όπου για κάθε region αποθηκεύονται τα επόμενα regions, μαζί με ένα σύνολο από boundary road segments που λειτουργούν ως σημεία διέλευσης προς το downstream region (δηλ. roads του επόμενου region που είναι άμεσα προσβάσιμα από το τρέχον region).

Ο region-level generator χρειάζεται έναν σαφή χάρτη επιτρεπτών μεταβάσεων region→region ώστε να δημιουργεί μακροσκοπικές διαδρομές που παραμένουν συνεπείς με τη συνδεσιμότητα του road network (δηλαδή να μην προτείνει άλματα σε μη προσβάσιμες περιοχές). Αυτή η δομή χρησιμοποιείται έπειτα για candidate sets/constraints και για την εκπαίδευση των region-level μοντέλων, ό,τι κάναμε στο road-level, αλλά σε μικρότερο χώρο καταστάσεων.

Χαρτογράφηση road-level τροχιών σε region-level (map_region_traj.py)

Το script `map_region_traj.py` μετασχηματίζει τις ήδη map-matched τροχίες σε επίπεδο road segments (π.χ. `rid_list`), σε επίπεδο regions, ώστε να τροφοδοτηθεί το region-level στάδιο του TS-TrajGen.

- Συγκεκριμένα, φορτώνει την αντιστοίχιση `road_id → region_id` (`rid2region.json`) και, για κάθε τροχιά, αντικαθιστά κάθε road segment με το region στο οποίο ανήκει.
- Έπειτα εφαρμόζει συμπίεση διαδοχικών επαναλήψεων: κρατά μόνο τις στιγμές όπου αλλάζει region (δηλαδή αφαιρεί συνεχόμενα ίδια region ids), ώστε η έξοδος να είναι μια ακολουθία από μεταβάσεις μεταξύ περιοχών αντί για πλήρη ακολουθία road segments.
- Παράλληλα, δημιουργεί ένα αντίστοιχο `time_list` που ευθυγραμμίζεται με τη region ακολουθία (κρατά τον χρόνο εισόδου/μετάβασης στο νέο region).
- Τέλος, γράφει αρχεία region-level trajectories για train/eval/test (με πεδία `traj_id`, `region_list`, `time_list`), χρησιμοποιώντας ένα εσωτερικό split του train set (90%

train, 10% eval) για την επόμενη προεκπαίδευση/κωδικοποίηση στο region-level pipeline.

	traj_id	region_list	time_list
0	736	63,75,76,86	2013-07-01T16:03:34Z,2013-07-01T16:07:04Z,2013...
1	2167	46,36,35,32	2013-07-01T21:00:26Z,2013-07-01T21:00:56Z,2013...
2	4142	25,33	2013-07-02T05:19:33Z,2013-07-02T05:21:03Z
3	3066	65,68,66,60,50	2013-07-02T00:09:26Z,2013-07-02T00:10:11Z,2013...
4	4143	46,20,3,15,7,14,27,29,13,14,13	2013-07-02T05:27:56Z,2013-07-02T05:28:41Z,2013...

Σχήμα 37: Region Δεδομένα

Κωδικοποίηση region-level τροχιών σε pretraining inputs (encode_region_traj.py)

Μετά το map_region_traj.py, οι τροχιές δεν είναι πλέον ακολουθίες από road segments αλλά ακολουθίες από regions (με timestamps στις αλλαγές region). Το επόμενο βήμα είναι να μετατραπούν αυτές οι region-level τροχιές σε ένα εποπτευόμενο dataset προεκπαίδευσης (pretrain input), ώστε να μπορούν να εκπαιδευτούν τα region-level μοντέλα (Function G/H) με τον ίδιο imitate learning τρόπο όπως στο road-level. Αυτό ακριβώς υλοποιεί το encode_region_traj.py: παίρνει κάθε region-trajectory και τη σπάει σε πολλά training records τύπου (prefix → επόμενο βήμα), όπου το επόμενο βήμα επιλέγεται μέσα από ένα candidate set που προκύπτει από τον region graph.

Το script διαβάζει:

- Region trajectories: mm_region_train.csv, mm_region_eval.csv, mm_region_test.csv (έξοδος του mapping σε regions).
- Region adjacency list: region_adjacent_list.json (ο γράφος region→region).
- Region κέντρα (GPS): region_gps.json ή το υπολογίζει ως “γεωμετρικό κέντρο” από τα roads του region, για να μπορεί να μετρήσει αποστάσεις προς τον προορισμό.

Παράγει 3 CSV αρχεία pretrain input:

- region_pretrain_input_train.csv
- region_pretrain_input_eval.csv

- region_pretrain_input_test.csv

	trace_loc	trace_time	des	candidate_set	candidate_dis	target
0	63	963	86	84,72,74,64,75,83,65	12.668123646450775,21.925606524856775,18.67679...	4
1	63,75,76	963,967,969	86	86,78,77,65,85,75	0.0,14.194843548191718,17.604099807402292,12.2...	0
2	46	1260	32	43,39,45,20,49,36	7.58883297853521,10.806028937084132,9.32615090...	5
3	46,36,35	1260,1260,1262	32	36,32,33,44	17.22396511887161,0.0,1.6361887875242296,8.595...	1
4	25	319	33	26,27,92,33,34	15.305689454719387,14.858828714761476,14.36854...	3

Σχήμα 38: Region Pretrain Inputs

Υπολογισμός region node features για Region-GAT (prepare_region_feature.py)

Στο region-level στάδιο, κάθε κόμβος του γράφου δεν είναι πλέον ένα road segment αλλά ένα region (σύνολο από road segments). Για να εκπαιδευτεί ένα GAT σε επίπεδο regions, χρειαζόμαστε node features ανά region. Το prepare_region_feature.py κατασκευάζει αυτά τα features αξιοποιώντας τη γνώση που έχει ήδη μάθει το road-level GAT.

- Φορτώνει το προεκπαιδευμένο road-level GAT και στήνει τα embeddings/αναπαραστάσεις για όλα τα road segments. Έτσι αποκτά ένα διάνυσμα αναπαράστασης για κάθε road segment, το οποίο ενσωματώνει τόσο τοπολογία (μέσω adjacency) όσο και road attributes (μέσω node features).
- Διαβάζει τους χάρτες αντιστοίχισης road↔region (rid2region.json, region2rid.json) που παρήχθησαν από το KaHIP partitioning.
- Συνθέτει feature για κάθε region από τα road embeddings που περιέχει: δημιουργεί έναν πίνακα membership (region × road) και μέσω ενός πολλαπλασιασμού πίνακα υπολογίζει για κάθε region ένα συγκεντρωτικό διάνυσμα (aggregation) των road-level αναπαραστάσεων. Στο συγκεκριμένο script η συγκέντρωση γίνεται ως άθροισμα (sum) των embeddings των road segments που ανήκουν στο region.
- Αποθηκεύει το αποτέλεσμα σε αρχείο τύπου region_feature.pt, το οποίο χρησιμοποιείται ως node feature matrix για το region-level GAT στα επόμενα βήματα προεκπαίδευσης.

Με αυτό το βήμα, κάθε region αποκτά ένα feature vector που κληρονομεί σημασιολογική και τοπολογική γνώση από το road-level GAT, απλώς σε πιο μακροσκοπική κλίμακα.

Αυτό κάνει το region-level GAT πιο σταθερό/αποδοτικό, γιατί ξεκινά από meaningful αναπαραστάσεις.

```
Loaded type: <class 'torch.Tensor'>
Tensor shape: (100, 256) | dtype: torch.float32 | requires_grad: True
```

	region_id	f0	f1	f2	f3	f4	f5	f6	f7	f8	f9
0	0	-1.818294	-1.337331	-4.254462	-4.456694	0.262053	1.488705	10.207604	-18.205187	-1.157230	9.186815
1	1	-1.274918	0.603085	-9.977889	-3.454564	-1.001055	3.188389	-5.091725	-44.177666	0.062774	6.705524
2	2	-3.504105	4.432373	-4.864886	-4.573250	-2.007837	6.693565	10.490948	-46.801483	0.656443	9.048488
3	3	-1.710060	0.139722	-7.196295	-4.909872	-0.370543	2.086215	4.883797	-29.889662	-0.797796	7.920498
4	4	-1.179606	0.178568	-4.786240	-2.231534	0.820112	2.816752	5.307413	-41.257736	-0.580600	9.335806

Σχήμα 39: Χαρακτηριστικά Regions

Υπολογισμός πίνακα αποστάσεων μεταξύ regions (construct_region_dist.py)


Στο region-level στάδιο, εκτός από το region graph (ποια regions είναι γειτονικά), χρειαζόμαστε και ένα ποσοτικό μέτρο πόσο μακριά είναι ένα region από ένα άλλο. Το construct_region_dist.py κατασκευάζει έναν πίνακα $K \times K$ (όπου K =πλήθος regions, π.χ. 100) με εκτιμώμενες αποστάσεις region→region (0 με τον εαυτό του, διαγώνιος), ώστε αργότερα να μπορεί να υπολογίζεται εύκολα ένα χαρακτηριστικό τύπου *candidate→destination distance* στο region-level (ανάλογο με το candidate_dis που είχαμε στο road-level).

Region-level προεκπαίδευση (GFC & GAT)

Όπως και στο road-level στάδιο, στο region-level εκτελούνται αντίστοιχες διαδικασίες προεκπαίδευσης με FC-based generator (GFC) και GAT-based scorer (GAT).

- Region-Function G (GFC): μαθαίνει πολιτική next-region επιλογής και αποδίδει scores πάνω στο candidate_set (γειτονικά regions). Το αποθηκευμένο checkpoint χρησιμοποιείται στη συνέχεια ως region-level “generator prior” για τη μακροσκοπική δρομολόγηση.
- Region-Function H (GAT): αξιοποιεί τον γράφο περιοχών (region adjacency) και τα region node features ώστε να αποδίδει expected cost / scoring για τους υποψήφιους επόμενους regions και να παρέχει embeddings/αναπαραστάσεις σε επίπεδο regions που ενσωματώνουν τη δομή του region graph.

Συνολικά, η region-level προεκπαίδευση δεν εισάγει νέο είδος μηχανισμού σε σχέση με το road-level, αλλά επαναχρησιμοποιεί το ίδιο σχήμα μάθησης σε διαφορετική κλίμακα, με στόχο να παράγει embeddings και scores που σταθεροποιούν τη μακροσκοπική ροή της τροχιάς πριν την λεπτομερή παραγωγή σε road segments.



Σχήμα 40: Region Μετρικές Accuracy/Loss

Η μείωση του train loss και η αύξηση της validation accuracy επιβεβαιώνουν ότι τα region-level μοντέλα μαθαίνουν αποτελεσματικά τη μακροσκοπική δυναμική μετάβασης μεταξύ περιοχών. Η χαμηλότερη Top-1 επίδοση σε σχέση με το road-level είναι αναμενόμενη, καθώς στο region graph το candidate set είναι μεγαλύτερο (έως ~10), άρα το πρόβλημα ταξινόμησης next-hop είναι δυσκολότερο. Συνεπώς, οι επιδόσεις ~0.58–0.64 αποτυπώνουν ικανοποιητική ικανότητα πρόβλεψης της επόμενης περιοχής στο πλαίσιο της ιεραρχικής two-stage παραγωγής.

5.5 Adversarial Learning

Στο τελικό στάδιο εκπαίδευσης, το TS-TrajGen εφαρμόζει adversarial learning σε επίπεδο road segments, ώστε ο generator να παράγει τροχιές που είναι (i) ρεαλιστικές ως ακολουθίες road IDs και (ii) συνεπείς με το οδικό δίκτυο, επιλέγοντας σε κάθε βήμα μόνο επιτρεπτές μεταβάσεις. Η διαδικασία ακολουθεί λογική τύπου SeqGAN, όπου ο generator βελτιστοποιείται με policy gradient (REINFORCE) αξιοποιώντας reward από discriminator και Monte-Carlo rollouts για την εκτίμηση ανταμοιβής σε ενδιάμεσα βήματα.

Είσοδοι

- πραγματικές map-matched τροχιές (rid_list, time_list).
- γνώση οδικού δικτύου και γεωμετρίας, όπως candidate sets (adjacent_list), κέντρα road segments (rid_gps), μήκη segments και βοηθητικές κατανομές για sampling, καθώς και δομές για rollouts (π.χ. διακριτές διαδρομές ανά OD),
- προεκπαιδευμένα βάρη του generator (Function-G και Function-H) ώστε το adversarial στάδιο να ξεκινά από ήδη σταθερή πολιτική next-hop.

Μοντέλα

- Ο Generator αποτελείται από προεκπαιδευμένες συνιστώσες: (i) sequence model (Function-G) για την ακολουθιακή δυναμική και (ii) graph-based component (Function-H/GAT) ώστε οι αποφάσεις next-hop να λαμβάνουν υπόψη τη δομή του road graph. Σε κάθε χρονικό βήμα ο generator επιλέγει επόμενο road segment μόνο μέσα από το candidate set του τρέχοντος segment, εξασφαλίζοντας network-constrained generation.
- Ο Discriminator είναι LSTM-based δυαδικός ταξινομητής που διακρίνει real από synthetic ακολουθίες.
- Ο Searcher παράγει synthetic τροχιές με βάση start–destination–μήκος, ενώ ο Rollout εκτελεί Monte-Carlo ολοκληρώσεις μερικών τροχιών και επιστρέφει reward ανά βήμα, συμπεριλαμβάνοντας και γεωμετρικό όρο ποιινής (yaw-based), ο οποίος ενσωματώνεται στο GAN loss.


Διαδικασία εκπαίδευσης


Αρχικά πραγματοποιείται pretraining του discriminator με positive δείγματα από πραγματικές τροχιές και negative δείγματα από τροχιές που παράγονται από τον Searcher. Στη συνέχεια εκτελείται εναλλασσόμενη εκπαίδευση:

- ενημέρωση generator με policy gradient χρησιμοποιώντας reward από rollouts,
- ενημέρωση discriminator με νέα real/fake δείγματα,
- ενημέρωση των παραμέτρων rollout ώστε να ακολουθούν τον τρέχοντα generator.

Έξοδοι και αξιολόγηση

Στο τέλος αποθηκεύονται τα ενημερωμένα weights του generator και του discriminator. Επιπλέον, κατά το training του generator καταγράφονται ενδεικτικές μετρικές ομοιότητας μεταξύ generated και true trajectories, όπως EDT, Hausdorff και DTW, μετά από αντιστοίχιση road IDs σε γεωμετρική polyline μέσω rid_gps.






Σχήμα 41: Μετρικές 1^{ου} Σταδίου GAN

Στο pretrain του discriminator παρατηρείται σταθερή βελτίωση (top-1 accuracy από ~ 0.754 σε ~ 0.894) και ταυτόχρονη μείωση του loss, δείχνοντας ότι ο discriminator μαθαίνει να διαχωρίζει αποτελεσματικά real από synthetic τροχιές. Κατά το adversarial loop, η top-1 accuracy κινείται ακόμη υψηλότερα (~ 0.905 – 0.946) ενώ το loss συνεχίζει να μειώνεται, κάτι που υποδηλώνει ότι ο discriminator παραμένει ισχυρός κριτής καθώς ο generator βελτιώνεται.

Τα metrics του generator (όπου χαμηλότερο = καλύτερο) παρουσιάζουν συνολική βελτίωση με μικρές διακυμάνσεις, κάτι αναμενόμενο σε adversarial learning. Η καλύτερη συνολική επίδοση εντοπίζεται στο epoch 6, όπου καταγράφονται τα χαμηλότερα DTW ≈ 55.14 και EDT ≈ 36.19 , ενώ η Hausdorff παραμένει επίσης χαμηλή (≈ 2.02 , πολύ κοντά στο ελάχιστο που εμφανίζεται στο epoch 2, ≈ 2.00). Τα αποτελέσματα αυτά υποδεικνύουν ότι οι παραγόμενες τροχιές προσεγγίζουν καλύτερα τις πραγματικές τόσο γεωμετρικά (DTW/Hausdorff) όσο και ως ακολουθίες road IDs (EDT).

Η ίδια adversarial διαδικασία εφαρμόζεται και στο region-level (train_region_gan.py), με action space σε regions αντί για road segments, ώστε να βελτιωθεί η μακροσκοπική ροή πριν το λεπτομερές road-level generation



Σχήμα 42: Μετρικές 2^{ου} Σταδίου GANS

Στο pretrain, η top-1 accuracy του region discriminator ανεβαίνει από ~ 0.50 σε ~ 0.73 με παράλληλη μείωση του loss, άρα ο κριτής μαθαίνει βασική διάκριση real/fake σε region sequences. Στο adversarial loop η accuracy παραμένει σε παρόμοια επίπεδα (~ 0.72 – 0.74) και το loss μειώνεται ηπιότερα, δείχνοντας ότι ο discriminator προσαρμόζεται σταδιακά στις βελτιώσεις του generator χωρίς να πέφτει η εκπαίδευση.

Ο region generator βελτιώνει τις μετρικές ομοιότητας νωρίς και στη συνέχεια εμφανίζει μικρές ταλαντώσεις, με early stop όταν η ποιότητα δεν συνεχίζει να βελτιώνεται. Η καλύτερη γεωμετρική αντιστοίχιση ως προς DTW εμφανίζεται στο epoch 4 (DTW ≈ 10.90), ενώ το χαμηλότερο EDT εντοπίζεται στο epoch 2 (EDT ≈ 5.70). Παράλληλα, η Hausdorff ελαχιστοποιείται στο epoch 3 (≈ 2.02), υποδεικνύοντας μειωμένες “ακραίες” γεωμετρικές αποκλίσεις σε σχέση με άλλα epochs. Η συμπεριφορά αυτή είναι τυπική σε adversarial learning: δεν υπάρχει απαραίτητα μονοτονική βελτίωση, αλλά συγκεκριμένα epochs που αποτελούν κατάλληλα checkpoints ανάλογα με το κριτήριο (DTW/EDT/Hausdorff) που δίνεται προτεραιότητα (DTW στην δική μας περίπτωση).

5.6 Τελική παραγωγή τροχιών στο test set


Στο τελικό στάδιο του pipeline εκτελέστηκε το script `our_model_generate.py` για την παραγωγή συνθετικών τροχιών με βάση τα OD-inputs του test dataset. Για κάθε εγγραφή του `porto_mm_test.csv`, το script διαβάζει το πραγματικό `rid_list` και χρησιμοποιεί ως συνθήκη παραγωγής το `origin` (πρώτο road segment), το `destination` (τελικό road segment) και ως `default length` το μήκος της πραγματικής τροχιάς, ώστε να παραχθεί μία νέα ακολουθία road-segment IDs μέσω της διαδικασίας αναζήτησης (A*-like) στο οδικό δίκτυο. Το παραγόμενο αποτέλεσμα αποθηκεύεται σε αρχείο CSV της μορφής `traj_id`, `rid_list`, `time_list` για μεταγενέστερη αξιολόγηση.


Σημειώνεται ότι η παραγωγή σε αυτό το στάδιο πραγματοποιείται με βάση τα προεκπαιδευμένα βάρη του road-level και region-level generator, δηλαδή τα checkpoints των Function-G (sequence model) και Function-H (GAT-FC/GFC) που φορτώνονται ρητά από το script (π.χ. `function_g_fc.pt`, `gat_fc.pt` και τα αντίστοιχα region checkpoints). Συνεπώς, τα τελικά παραγόμενα δείγματα και οι μετρικές που υπολογίστηκαν παρακάτω

αντανακλούν την απόδοση του GAT/GFC-based generation pipeline και όχι τα ενδιάμεσα logs/weights του adversarial GAN training.

Μετά την παραγωγή, αξιολογήσαμε τις επιτυχημένες παραγόμενες τροχιές, συγκρίνοντάς τις με τις αντίστοιχες πραγματικές του test set, χρησιμοποιώντας τόσο συμβολικές όσο και γεωμετρικές μετρικές ομοιότητας.

Συγκεκριμένα υπολογίστηκαν: avg EDT = 23.55, mean Hausdorff = 0.526 km και mean DTW (sum cost) = 12.54 km, δείχνοντας ότι οι παραγόμενες τροχιές διατηρούν ικανοποιητική γεωμετρική εγγύτητα με τις πραγματικές διαδρομές, με μεγαλύτερη διαφοροποίηση στη λεπτομέρεια της ακριβούς ακολουθίας road segments.





Σχήμα 43: Ενδεικτική οπτική σύγκριση πραγματικής (μπλε) και παραγόμενης (κόκκινη) τροχιάς σε επιτυχημένο δείγμα. Η παραγόμενη τροχιά ακολουθεί έγκυρες μεταβάσεις στο οδικό δίκτυο και καταλήγει στον ίδιο προορισμό, παρά τοπικές αποκλίσεις στην ενδιάμεση διαδρομή.

Στο Σχήμα 43 παρουσιάζεται ενδεικτικό επιτυχημένο παράδειγμα οπτικής σύγκρισης πραγματικής και παραγόμενης τροχιάς πάνω στο υπόβαθρο του οδικού δικτύου. Η πραγματική διαδρομή (μπλε) και η παραγόμενη (κόκκινη) ξεκινούν από παρόμοιο σημείο και καταλήγουν στον ίδιο προορισμό, ενώ η παραγόμενη τροχιά ακολουθεί έγκυρες μεταβάσεις μεταξύ road segments και παραμένει κουμπωμένη στο οδικό δίκτυο, χωρίς εκτός-δρόμου άλματα ή μη επιτρεπτές συνδέσεις. Παρά τις τοπικές αποκλίσεις στη λεπτομερή επιλογή τμημάτων (δηλ. διαφορετικές ενδιάμεσες επιλογές οδών σε σχέση με την πραγματική), η συνολική πορεία παραμένει συνεπής με τη γεωμετρία της κίνησης και καταλήγει ορθά στο destination, επιβεβαιώνοντας στην πράξη το network-constrained generation του μοντέλου.

ΚΕΦΑΛΑΙΟ 6 Συμπεράσματα και Προτάσεις για Μελλοντική Έρευνα

6.1 Συμπεράσματα

Η παρούσα διπλωματική εργασία ασχολήθηκε με το πρόβλημα της παραγωγής συνθετικών, αλλά ρεαλιστικών πολυδιάστατων δεδομένων κίνησης, με στόχο να υποστηριχθούν εφαρμογές ανάλυσης κινητικότητας και αξιολόγησης αλγορίθμων χωρίς να απαιτείται πρόσβαση σε πραγματικά (και συχνά ευαίσθητα) δεδομένα τροχιών.

Σε επίπεδο βιβλιογραφικής ανασκόπησης, παρουσιάστηκε η εξέλιξη του πεδίου από παραδοσιακές γεννήτριες (στοχαστικές και σεναριακές) έως μοντέλα μηχανικής/βαθιάς μάθησης. Τα παραδοσιακά μοντέλα (όπως GSTD/GSTD2 και Oporto) προσφέρουν ελεγχόμενη παραμετροποίηση και αναπαραγωγιμότητα, όμως συνήθως περιορίζονται από απλοποιητικές υποθέσεις για τη συμπεριφορά και δυσκολεύονται να αποτυπώσουν πολύπλοκες εξαρτήσεις που εμφανίζονται σε πραγματικά δεδομένα. Αντίστοιχα, οι network-constrained προσεγγίσεις (Brinkhoff, BerlinMOD, Hermoupolis, MMC) δείχνουν τη σημασία των περιορισμών δικτύου και των ρεαλιστικών κανόνων κίνησης, αλλά συχνά εξαρτώνται έντονα από σενάρια/κανόνες που ορίζει ο χρήστης.

Στο Κεφάλαιο 4 αναδείχθηκε ότι τα data-driven generative models (GAN-based μοντέλα, ακολουθιακά μοντέλα, Transformer-based προσεγγίσεις και imitation learning) μπορούν να μάθουν απευθείας από δεδομένα και να προσεγγίσουν πιο ρεαλιστικές κατανομές κινητικότητας, ειδικά όταν συνδυάζονται με μηχανισμούς που επιβάλλουν συνδεσιμότητα/εγκυρότητα πάνω στο οδικό δίκτυο και μετρικές αξιολόγησης που ελέγχουν τόσο τη γεωμετρία όσο και τη χρησιμότητα των παραγόμενων τροχιών.

Η βασική εφαρμοσμένη συνεισφορά της εργασίας ήταν η υλοποίηση και μελέτη ενός ολοκληρωμένου pipeline παραγωγής συνεχών τροχιών με το TS-TrajGen, πάνω σε map-matched δεδομένα ταξί στην Πορτογαλία. Η διαδικασία περιέλαβε προεπεξεργασία για pretraining, εκπαίδευση road-level (επίπεδο δρόμου) και region-level (επίπεδο περιοχών) μονάδων, και τελικό adversarial learning (GANs) σε επίπεδο δρόμου, αξιοποιώντας δομές του οδικού δικτύου ώστε οι μεταβάσεις να παραμένουν εφικτές.

Στην τελική αξιολόγηση των παραγόμενων τροχιών στο test set (στις επιτυχημένες περιπτώσεις), χρησιμοποιήθηκαν μετρικές ομοιότητας. Τα αποτελέσματα (avg EDT = 23.55, mean Hausdorff = 0.526 km, mean DTW = 12.54 km) δείχνουν ότι οι συνθετικές τροχιές επιτυγχάνουν ικανοποιητική γεωμετρική εγγύτητα με τις πραγματικές διαδρομές, ενώ η μεγαλύτερη απόκλιση εμφανίζεται στη λεπτομέρεια της ακριβούς ακολουθίας των road segments, κάτι που είναι αναμενόμενο, καθώς μπορεί να υπάρχουν πολλαπλές εναλλακτικές λογικές διαδρομές για το ίδιο OD.

Συνολικά, η εργασία καταλήγει ότι η παραγωγή συνθετικών τροχιών υψηλής ποιότητας δεν είναι μόνο θέμα μοντέλου, αλλά και θέμα σωστής αναπαράστασης του χώρου (οδικό δίκτυο), κατάλληλων περιορισμών εγκυρότητας και ουσιαστικής αξιολόγησης με περισσότερες από μία μετρικές. Παράλληλα, αναδείχθηκαν πρακτικοί περιορισμοί: υπολογιστικό κόστος, ευαισθησία σε υπερπαραμέτρους και checkpoints, καθώς και το γεγονός ότι πολλά σύγχρονα μοντέλα δεν συνοδεύονται από τυπικές εγγυήσεις ιδιωτικότητας.

6.2 Μελλοντικές Κατευθύνσεις

Με βάση τα ευρήματα της βιβλιογραφίας και τα συμπεράσματα της εφαρμογής, οι παρακάτω κατευθύνσεις αποτελούν ρεαλιστικά και ουσιαστικά επόμενα βήματα:

- Επέκταση της γεννήτριας ώστε να παράγει (ή να συν-παράγει) θεματικά χαρακτηριστικά: τύπο μετακίνησης, δραστηριότητα, POIs, κατηγορίες οχημάτων/χρηστών, ή πλαίσιο (ώρα αιχμής, ημέρα εβδομάδας), με συνεκτικότητα ως προς χώρο, χρόνο, σημασιολογία.
- Ενίσχυση γενικευσιμότητας και μεταφοράς σε νέα περιβάλλοντα: Δοκιμή του pipeline σε διαφορετικές πόλεις/οδικά δίκτυα και διερεύνηση transfer learning ή domain adaptation, ώστε να μειώνεται η εξάρτηση από ένα συγκεκριμένο dataset και να βελτιώνεται η αξιοπιστία σε out-of-distribution περιπτώσεις.
- Πιο ολοκληρωμένο πρωτόκολλο αξιολόγησης: Εκτός από EDT/DTW/Hausdorff, να ενταχθούν:
 - distributional metrics (π.χ. MMD σε χαρακτηριστικά κινητικότητας),

- utility metrics (π.χ. query error/OD flows/συχνότητες links),

Κλείνοντας, η εργασία έδειξε ότι η προσομοίωση τροχιών με ML δεν είναι απλώς παραγωγή διαδρομών, αλλά ένα συνολικό οικοσύστημα από αναπαράσταση χώρου, μοντελοποίηση ακολουθιών, περιορισμούς εγκυρότητας και αυστηρή αξιολόγηση. Οι μελλοντικές κατευθύνσεις που προτείνονται στοχεύουν στο να κάνουν αυτά τα συστήματα πιο ρεαλιστικά, πιο ελέγξιμα, πιο γενικεύσιμα και πιο ασφαλή για χρήση σε πραγματικά ερευνητικά σενάρια.

Αναφορές.

1. Yannis Theodoridis, Jefferson R. O. Silva, Mario A. Nascimento: On the Generation of Spatiotemporal Datasets. SSD 1999: 147-164
2. Saglio, J.-M., and Moreira, J.: Oporto: A realistic scenario generator for moving objects. In: GeoInformatica 5(1), pp. 71–93 (2001)
3. Brinkhoff, T.: A framework for generating network-based moving objects. In: GeoInformatica 6(2), pp. 153–180 (2002)
4. Düntgen, C., Behr, T., and Güting, R.H.: BerlinMOD: A benchmark for moving object databases. In: The VLDB Journal 18(6), pp. 1335–1368 (2009)
5. Pelekis, N., Ntrigkogas, C., Tampakis, P., Sideridis, S., and Theodoridis, Y.: Hermoupolis: A trajectory generator for simulating generalized mobility patterns. In: Proceedings of ECML PKDD 2013, LNAI 8190, Springer, pp. 659–662 (2013)
6. Pfoser, D., and Theodoridis, Y.: Generating semantics-based trajectories of moving objects. In: Computers, Environment and Urban Systems 27(3), pp. 243–263 (2003)
7. Gambs, S., Killijian, M.-O., and Núñez del Prado Cortez, M.: Show me how you move and I will tell you who you are. In: Transactions on Data Privacy 4(2), pp. 103–126 (2011)
8. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., et al.: Generative adversarial nets. In: Advances in Neural Information Processing Systems (NeurIPS), Vol. 27, pp. 2672–2680 (2014)

9. Wang, X., Liu, X., Lu, Z., and Yang, H.: Large scale GPS trajectory generation using map based on two stage GAN. In: Journal of Data Science 19(1), pp. 126–141 (2021)
10. Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., and Courville, A. C.: Improved Training of Wasserstein GANs. In: Advances in Neural Information Processing Systems 30 (NeurIPS 2017), pp. 5767–5777 (2017)
11. Bindschaedler, V., and Shokri, R.: Synthesizing plausible privacy-preserving location traces. In: Proceedings of the IEEE Symposium on Security and Privacy (SP), (2016)
12. Ouyang, K., Shokri, R., Rosenblum, D. S., and Yang, W.: A non-parametric generative model for human trajectories. In: Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence (IJCAI), pp. 3812–3817 (2018)
13. Smolyak, D., Gray, K., Badirli, S., and Mohler, G.: Coupled IGMM-GANs with applications to anomaly detection in human mobility data. In: ACM Transactions on Spatial Algorithms and Systems 6(4), Article 24 (2020)
14. Rao, J., Gao, S., Kang, Y., and Huang, Q.: LSTM-TrajGAN: A deep learning approach to trajectory privacy protection. In: Proceedings of the 11th International Conference on Geographic Information Science (GIScience 2021), 12:1–12:17 (2021)
15. Donahue, J., Krähenbühl, P., and Darrell, T.: Adversarial Feature Learning. In: 5th International Conference on Learning Representations (ICLR 2017) (2017)
16. Hart, P. E., Nilsson, N. J., and Raphael, B.: A formal basis for the heuristic determination of minimum cost paths. In: IEEE Transactions on Systems Science and Cybernetics 4(2), pp. 100–107 (1968)
17. Jiang, W., Zhao, W. X., Wang, J., and Jiang, J.: Continuous Trajectory Generation Based on Two-Stage GAN. In: Proceedings of the AAAI Conference on Artificial Intelligence, 37(4), pp. 4374–4382 (2023)
18. Keogh, E.: Exact indexing of dynamic time warping. In: Proc. of VLDB '02, pp. 406–417 (2002)

19. Haydari, A., Chen, D., Lai, Z., Zhang, M., and Chuah, C.-N.: MobilityGPT: Enhanced Human Mobility Modeling With a GPT Model. *IEEE Transactions on Intelligent Transportation Systems*, 27, pp. 1681–1694 (2024)
20. Lin, J.: Divergence measures based on the Shannon entropy. In: *IEEE Transactions on Information Theory* 37(1), pp. 145–151 (1991)
21. Chen, R., Fung, B. C. M., Desai, B. C. Differentially Private Trajectory Data Publication. *CoRR*, abs/1112.2020 (2011)
22. Papineni, K., Roukos, S., Ward, T., and Zhu, W. J.: BLEU: A method for automatic evaluation of machine translation. In: *Proceedings of the 40th Annual Meeting of the Association for Computational Linguistics (ACL)*, pp. 311–318 (2002)
23. Banerjee, S., and Lavie, A.: METEOR: An automatic metric for MT evaluation with improved correlation with human judgments. In: *Proceedings of the ACL Workshop on Intrinsic and Extrinsic Evaluation Measures for Machine Translation and/or Summarization*, pp. 65–72 (2005)
24. Choi, S., Kim, J., and Yeo, H.: TrajGAIL: Generating Urban Vehicle Trajectories Using Generative Adversarial Imitation Learning. *Transportation Research Part C: Emerging Technologies*, 128, Article 103091 (2021)
25. Brakatsoulas, S., Pfoser, D., Salas, R., and Wenk, C.: On map-matching vehicle tracking data. In: *Proceedings of the 31st International Conference on Very Large Data Bases (VLDB)*, pp. 853–864 (2005)
26. Zhang, L., Mbuya, J., Zhao, L., Pfoser, D., & Anastasopoulos, A. (2025). End-to-end trajectory generation: Contrasting deep generative models and language models. *ACM Transactions on Spatial Algorithms and Systems*, 11(4), Article 17, 17:1–17:28. (2025)
27. Huang, D., Song, X., Fan, Z., Jiang, R., Shibasaki, R., Zhang, Y., Wang, H., and Kato, Y.: A variational autoencoder based generative model of urban human mobility. In: *Proceedings of the IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)*, pp. 425–430 (2019)

28. Zhang, W., Zhang, X., Lan, L., and Luo, Z.: Maximum mean and covariance discrepancy for unsupervised domain adaptation. In: Neural Processing Letters 51(1), pp. 347–366 (2020)
29. Regenwetter, L., Srivastava, A., Gutfreund, D., and Ahmed, F.: Beyond statistical similarity: Rethinking metrics for deep generative models in engineering design. In: Computer-Aided Design 165, Article 103609 (2023)
30. Yang, C., and Gidófalvi, G.: Fast map matching: An algorithm integrating hidden Markov model with precomputation. In: International Journal of Geographical Information Science 32(3), pp. 547–570 (2018)
31. <https://github.com/TheodorosGk/trajectory-simulation-thesis>