



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ  
ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ  
ΤΜΗΜΑ ΜΗΧΑΝΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ

**ΑΝΑΠΤΥΞΗ ΥΠΟΛΟΓΙΣΤΙΚΟΥ ΜΟΝΤΕΛΟΥ ΜΑΘΗΣΗΣ ΣΕ ΒΑΘΟΣ ΓΙΑ  
ΤΟΝ ΥΠΟΛΟΓΙΣΜΟ ΡΥΠΩΝ ΓΙΑ ΒΕΝΖΙΝΟΚΙΝΗΤΑ ΕΛΑΦΡΑ ΚΑΙ  
ΠΕΤΡΕΛΑΙΟΚΙΝΗΤΑ ΒΑΡΕΑ ΕΠΑΓΓΕΛΜΑΤΙΚΑ ΟΧΗΜΑΤΑ**

υπό

**ΜΑΡΙΑ ΒΕΡΙΛΛΗ**

Διπλωματούχου Πολιτικού Μηχανικού Πανεπιστημίου Θεσσαλίας 2018

**Μεταπτυχιακή Εργασία**

Υπεβλήθη για την εκπλήρωση μέρους των  
απαιτήσεων για την απόκτηση του  
Μεταπτυχιακού Διπλώματος Ειδίκευσης

Βόλος, 2020

© 2020 Μαρία Βερίλλη

Η έγκριση της μεταπτυχιακής εργασίας από το Τμήμα Μηχανολόγων Μηχανικών της Πολυτεχνικής Σχολής του Πανεπιστημίου Θεσσαλίας δεν υποδηλώνει αποδοχή των απόψεων του συγγραφέα (Ν. 5343/32 αρ. 202 παρ. 2).

## **Εγκρίθηκε από τα Μέλη της Τριμελούς Εξεταστικής Επιτροπής:**

Πρώτος Εξεταστής (Επιβλέπων)	Δρ. Γεώργιος Σαχαρίδης Αναπληρωτής Καθηγητής, Τμήμα Μηχανολόγων Μηχανικών, Πανεπιστήμιο Θεσσαλίας
---------------------------------	---

Δεύτερος Εξεταστής	Δρ. Γεώργιος Λυμπερόπουλος Καθηγητής, Τμήμα Μηχανολόγων Μηχανικών, Πανεπιστήμιο Θεσσαλίας
--------------------	---

Τρίτος Εξεταστής	Δρ. Δημήτριος Παντελής Αναπληρωτής Καθηγητής, Τμήμα Μηχανολόγων Μηχανικών, Πανεπιστήμιο Θεσσαλίας
------------------	---

## Ευχαριστίες

Με την ολοκλήρωση της παρούσας εργασίας, θα ήθελα να ευχαριστήσω τον επιβλέποντα της μεταπτυχιακής εργασίας μου, Αναπληρωτή Καθηγητή κ. Γεώργιο Σαχαρίδη, καθώς και τον υποψήφιο διδάκτορα του Τμήματος Μηχανολόγων Μηχανικών του Πανεπιστημίου Θεσσαλίας Αντώνιο Φραγκογιό για την πολύτιμη βοήθεια και καθοδήγησή τους κατά τη διάρκεια της υλοποίησης της εργασίας μου.

Θα ήθελα να ευχαριστήσω ολόψυχα τον Κωνσταντίνο Λιάκο, υποψήφιο διδάκτορα του Τμήματος Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Πανεπιστημίου Θεσσαλίας, ο οποίος μου μεταλαμπάδευσε τις γνώσεις του στο κομμάτι της τεχνητή νοημοσύνης.

Τέλος, είμαι ευγνώμων στους γονείς μου, Δομήνικο και Δήμητρα Βερίλλη για την ολόψυχη αγάπη και υποστήριξή τους όλα αυτά τα χρόνια.

# **ΑΝΑΠΤΥΞΗ ΥΠΟΛΟΓΙΣΤΙΚΟΥ ΜΟΝΤΕΛΟΥ ΜΑΘΗΣΗΣ ΣΕ ΒΑΘΟΣ ΓΙΑ ΤΟΝ ΥΠΟΛΟΓΙΣΜΟ ΡΥΠΩΝ ΓΙΑ ΒΕΝΖΙΝΟΚΙΝΗΤΑ ΕΛΑΦΡΑ ΚΑΙ ΠΕΤΡΕΛΑΙΟΚΙΝΗΤΑ ΒΑΡΕΑ ΕΠΑΓΓΕΛΜΑΤΙΚΑ ΟΧΗΜΑΤΑ**

ΜΑΡΙΑ ΒΕΡΙΛΛΗ

Τμήμα Μηχανολόγων Μηχανικών, Πανεπιστήμιο Θεσσαλίας, 2020

Επιβλέπων Καθηγητής: Δρ. Γεώργιος Σαχαρίδης,  
Αναπληρωτής Καθηγητής Επιχειρησιακής Έρευνας

## **Περίληψη**

Η ατμοσφαιρική ρύπανση είναι άρρηκτα συνδεδεμένη με την οδική κυκλοφορία στα μεγάλα αστικά και μη κέντρα. Για την καταμέτρηση των οχημάτων καθώς και τον υπολογισμό των ρύπων που παράγονται από αυτά, ανά καιρούς παρουσιάζονται διάφορες τεχνολογίες οι οποίες, είναι δαπανηρές, περίπλοκες και για να εφαρμοστούν χρειάζονται σημαντικές τροποποιήσεις στο οδικό δίκτυο. Στην παρούσα διατριβή παρουσιάζεται ένα ισχυρό υπολογιστικό σύστημα βασισμένο στις αρχές της Μάθησης σε Βάθος, το οποίο αναγνωρίζει, καταμετρά και υπολογίζει τους ρύπους συγκεκριμένων τύπων οχημάτων, μέσω των ήδη τοποθετημένων καμερών οδικής παρακολούθησης. Συγκεκριμένα αναπτύχθηκε ένα ισχυρό υπολογιστικό σύστημα υπολογισμού ρύπων για βενζινοκίνητα ελαφρά επαγγελματικά οχήματα (αυτοκίνητα < 3,5 τόνους) τεχνολογίας Euro5 και πετρελαιοκίνητα βαρέα επαγγελματικά οχήματα (φορτηγά < 14 τόνους) τεχνολογίας EuroV, μέσω του αλγορίθμου αιχμής Συναινετικών Νευρωνικών Δικτύων. Το υπολογιστικό μοντέλο έχει την δυνατότητα να υπολογίζει τους ρύπους που παράγονται από τα οχήματα που αναγνωρίστηκαν και καταμετρήθηκαν, είτε μέσω μιας φωτογραφίας στην οποία απεικονίζονται τα προαναφερθέντα οχήματα, είτε μέσω βίντεο είτε μέσω βίντεο πραγματικού χρόνου. Το υπολογιστικό μοντέλο μπορεί να εφαρμοστεί στις ήδη υπάρχουσες κάμερες παρακολούθησης οδικής κυκλοφορίας, μειώνοντας σημαντικά το κόστος εγκατάστασης των σύνθετων και πολυδάπανων υπαρχουσών τεχνολογιών υπολογισμού ρύπων οχημάτων.

# **DEVELOPMENT OF A COMPUTATIONAL MODEL BASED ON DEEP LEARNING FOR THE ESTIMATION OF THE EMISSIONS FOR PETROL LIGHT AND DIESEL HEAVY COMMERCIAL VEHICLES**

MARIA VERILLI

Department of Mechanical Engineering, University of Thessaly, 2020

Supervisor: Dr George Saharidis

Associate Professor of Operational Research

## **Abstract**

Air pollution is inextricably related to traffic in large urban and rural centers. In order to count the vehicles and calculate the emissions produced by them, various technologies are being developed which are costly, complex and require significant modifications to the road network. This thesis presents a powerful computational model based on Deep Learning methods, which identifies, quantifies and calculates the emissions of specific types of vehicles through the existing installed road surveillance cameras. Specifically, a robust computational model has been developed in order to measure the emissions emitted by petrol light commercial vehicles (cars < 3.5 tn) Euro5 and diesel heavy-duty vehicles (trucks < 14 tn) EuroV, based on Convolutional Neural Network algorithm. This computational model is able to calculate the emissions produced by the vehicles, that have been identified and measured, either through a photograph, either by video or real-time video. The computational model can be applied to existing road traffic surveillance cameras, thus significantly reducing the cost of installing complex existing technologies that calculate vehicles' emissions.

# Πίνακας Περιεχομένων

<b>Κεφάλαιο 1. ΕΙΣΑΓΩΓΗ .....</b>	<b>1</b>
1.1 Κίνητρο και Υπόβαθρο .....	1
1.2 Οργάνωση Μεταπτυχιακής Εργασίας .....	2
<b>Κεφάλαιο 2. ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ .....</b>	<b>3</b>
2.1 Ορολογία και ορισμοί μηχανικής μάθησης .....	3
2.2 Βήματα της Μηχανικής Μάθησης.....	4
2.3 Ανάλυση της μάθησης .....	4
2.4 Μοντέλα εκμάθησης .....	5
2.4.1 Παλινδρόμηση - Regression .....	5
2.4.2 Ομαδοποίηση - Clustering .....	5
2.4.3 Μοντέλα Bayesian – Bayesian Models .....	5
2.4.4 Μοντέλα Βασισμένα σε Περιπτώσεις – Instance Based Models.....	6
2.4.5 Δέντρα Αποφάσεων – Decision Trees .....	6
2.4.6 Μηχανές Υποστήριξης Διανυσμάτων – Support Vector Machines .....	7
2.4.7 Μοντέλα Συνόλου – Ensemble Learning .....	8
2.4.8 Τεχνητά Νευρωνικά Δίκτυα – Artificial Neural Networks .....	9
<b>Κεφάλαιο 3. ΜΕΘΟΔΟΙ ΚΑΤΑΜΕΤΡΗΣΗΣ ΑΥΤΟΚΙΝΗΤΩΝ .....</b>	<b>12</b>
3.1 Intrusive Devices.....	12
3.2 Non-Intrusive Devices .....	16
3.3 Off-roadway devices .....	19
3.4 Sensor Combinations Devices .....	20
3.5 Συμπεράσματα .....	20
<b>Κεφάλαιο 4. ΜΕΤΡΗΣΗ ΟΔΙΚΩΝ ΡΥΠΩΝ .....</b>	<b>22</b>
4.1 Τεχνικές μέτρησης ρύπων.....	22
4.1.1 Portable Emission Measurement System (PEMS) .....	23
4.1.2 Plume chasing .....	24
4.1.3 Tunnel measurement .....	25
4.1.4 Remote sensing system .....	26
4.2 Μοντέλα μέτρησης ρύπων .....	27
4.2.1 Μακροσκοπικά μοντέλα .....	29
4.2.2 Μικροσκοπικά μοντέλα .....	31
4.3 Συμπεράσματα .....	32
<b>Κεφάλαιο 5. ΜΕΘΟΔΟΛΟΓΙΑ.....</b>	<b>35</b>
5.1 Γλώσσα προγραμματισμού .....	35
5.2 Εργαλεία για την ανάπτυξη του μοντέλου .....	35
5.3 Γραφικά περιβάλλοντα χρήστη .....	37
5.4 Βιβλιοθήκες .....	37
5.5 Βάση δεδομένων .....	38
5.6 Περιγραφή του αλγορίθμου .....	40
5.6.1 Αναγνώριση και Ταξινόμηση αυτοκινήτων και φορτηγών .....	41
5.6.2 Μαθηματικό μοντέλο υπολογισμού ρύπων.....	45

5.6.3	Καταμέτρηση και υπολογισμός ρύπων .....	47
<b>Κεφάλαιο 6. ΑΠΟΤΕΛΕΣΜΑΤΑ .....</b>		<b>49</b>
6.1	Συνάρτηση απώλειας .....	49
6.2	Μέσο Τετράγωνο Σφάλμα (MSE) .....	50
6.3	Μέσο Απόλυτο Σφάλμα (MAE) .....	50
6.4	Μέση Ακρίβεια (AP).....	51
6.5	Τελικά αποτελέσματα.....	52
6.6	Παραδείγματα πρόβλεψης εικόνων .....	53
6.7	Παραδείγματα υπολογισμού ρύπων .....	55
<b>Κεφάλαιο 7. ΣΥΜΠΕΡΑΣΜΑΤΑ .....</b>		<b>57</b>
<b>Κεφάλαιο 8. ΜΕΛΛΟΝΤΙΚΗ ΕΡΕΥΝΑ .....</b>		<b>58</b>
<b>ΒΙΒΛΙΟΓΡΑΦΙΑ .....</b>		<b>59</b>



## Κατάλογος Πινάκων

Πίνακας 1: Συγκεντρωτικός πίνακας τεχνολογιών παρακολούθησης της τεχνολογίας.....	21
Πίνακας 2: Συγκεντρωτικός πίνακας μεθόδων καταμέτρησης οχημάτων .....	33
Πίνακας 3: Κατηγορίες οχημάτων & χρονολογία εφαρμογής των προτύπων Euro .....	46
Πίνακας 4: Μέσες τιμές ρύπων κάθε οχήματος .....	47
Πίνακας 5: Συγκεντρωτικός πίνακας για τη μέθοδο CTEC.....	52
Πίνακας 6: Τελική μορφή του υπολογισμού των ρύπων των αυτοκινήτων .....	56
Πίνακας 7: Τελική μορφή του υπολογισμού των ρύπων των φορτηγών.....	56

## Κατάλογος Σχημάτων

Σχήμα 2- 1: Τυπική προσέγγιση μηχανικής μάθησης.....	3
Σχήμα 2- 2: Βασικά βήματα για το μοντέλο MM.....	4
Σχήμα 2- 3: Βήματα ομαδοποίησης k-means .....	5
Σχήμα 2- 4: Παράδειγμα ταξινόμησης.....	7
Σχήμα 2- 5:(α) Παράδειγμα ταξινόμησης ΜΥΔ δυο κλάσεων, (b) Παράδειγμα ταξινόμησης ΜΥΔ μιας κλάσης .....	8
Σχήμα 2- 6: Παράδειγμα ταξινόμησης ΤΔ.....	8
Σχήμα 2- 7: Παράδειγμα ταξινόμησης ΤΝΔ .....	9
Σχήμα 2- 8: Παράδειγμα ταξινόμησης ΣΝΔ .....	10
Σχήμα 2- 9: Παράδειγμα ταξινόμησης ΕΝΔ .....	11
Σχήμα 3- 1: Στοιχεία ενός επαγωγικού βρόγχου. ....	13
Σχήμα 3- 2: Παράδειγμα μαγνητικού ανιχνευτή .....	14
Σχήμα 3- 3: Παράδειγμα πιεζοηλεκτρικού μηχανισμού.....	15
Σχήμα 3- 4: Πνευματικός οδικός σωλήνας καταμέτρησης οχημάτων .....	16
Σχήμα 3- 5: Ανιχνευτής μικροκυμάτων Doppler .....	17
Σχήμα 3- 6: Παθητική συσκευή υπέρυθρης ακτινοβολίας.....	18
Σχήμα 3- 7: Ακουστικός αισθητήρας για καταμέτρηση οχημάτων .....	18
Σχήμα 3- 8: Μέθοδος επεξεργασίας εικόνας και video.....	19
Σχήμα 4- 1: Τρόπος λειτουργίας της μεθόδου PEMS.....	23
Σχήμα 4- 2: Πλεονεκτήματα & μειονεκτήματα της μεθόδου PEMS.....	24
Σχήμα 4- 3: Πλεονεκτήματα & μειονεκτήματα της μεθόδου Plume Chasing.....	25
Σχήμα 4- 4: Πλεονεκτήματα & μειονεκτήματα της μεθόδου Tunnel Measurement.....	26
Σχήμα 4- 5: Τρόπος λειτουργίας της μεθόδου Remote Sensing.....	27
Σχήμα 4- 6: Πλεονεκτήματα & μειονεκτήματα της μεθόδου Remote Sensing.....	27
Σχήμα 4- 7: Μοντέλα μέτρησης ρύπων.....	28
Σχήμα 4- 8: Χαρακτηριστικά των Μακροσκοπικών και Μικροσκοπικών Μοντέλων.....	34
Σχήμα 5- 1: Παράδειγμα φωτογραφιών αυτοκίνητων που χρησιμοποιήθηκαν στο μοντέλο...40	
Σχήμα 5- 2: Παράδειγμα φωτογραφιών φορτηγών που χρησιμοποιήθηκαν στο μοντέλο.....	40
Σχήμα 5- 3: Παράδειγμα αρχιτεκτονικής ΣΝΔ.....	42
Σχήμα 5- 4: Συναρτήσεις ενεργοποίησης.....	43
Σχήμα 5- 5:Συνάρτηση ReLU.....	43

Σχήμα 5- 6: Αρχιτεκτονική μορφή του μοντέλου CTEC.....	44
Σχήμα 6- 1: Διάγραμμα μέσης ακρίβειας.....	51
Σχήμα 6- 2: Διάγραμμα συνολικής απώλειας ανά εποχή.....	52
Σχήμα 6- 3: Παραδείγματα αποτελεσμάτων για την πρόβλεψη αυτοκίνητου .....	54
Σχήμα 6- 4: Παραδείγματα αποτελεσμάτων για την πρόβλεψη φορτηγού .....	55

# Κεφάλαιο 1. ΕΙΣΑΓΩΓΗ

---

## 1.1 Κίνητρο και Υπόβαθρο

Η επιστήμη των υπολογιστών, τις τελευταίες δεκαετίες έχει εξελιχθεί με ραγδαίους ρυθμούς σε υψηλό επίπεδο, παρέχοντας τη δυνατότητα στους χρήστες να χειρίζονται ισχυρά υπολογιστικά συστήματα για καθημερινή αλλά και πιο εξειδικευμένη χρήση. Αυτή η εξέλιξη, δίνει τη δυνατότητα να αναπτυχθούν έρευνες, είτε στο πεδίο της επιστήμης των υπολογιστών, είτε σε άλλα επιστημονικά πεδία, όπως αγροτεχνολογία [1], περιβάλλον και επιχειρησιακή έρευνα.

Ταυτόχρονα, η εξέλιξη των ισχυρών υπολογιστικών συστημάτων συντέλεσε και στην εξέλιξη νέων πιο σύνθετων αλγορίθμων. Σημαντικοί αλγόριθμοι αναπτύχθηκαν και εξελίχθηκαν στο πεδίο της μηχανικής μάθησης με αποτέλεσμα την δημιουργία ενός νέου και ραγδαίως εξελισσόμενου πεδίου τεχνητής νοημοσύνης, το πεδίο μάθησης σε βάθος [2]. Σαν όρο μηχανική μάθηση δύναται να εννοηθεί ότι είναι η απόκτηση της ικανότητας της μάθησης από μια μηχανή, με την βοήθεια αλγορίθμων, χωρίς αυτή να είναι αυστηρά προγραμματισμένη [3].

Στόχος της παρούσας μεταπτυχιακής εργασίας είναι η δημιουργία ενός υπολογιστικού μοντέλου για τον υπολογισμό των οδικών εκπομπών ρύπων για βενζινοκίνητα αυτοκίνητα τεχνολογίας Euro5 και πετρελαιοκίνητα φορτηγά μέχρι 14 τόνους τεχνολογίας EuroV, βασιζόμενο στην εφαρμογή μεθόδων μηχανικής μάθησης-μάθησης σε βάθος για την αναγνώριση και καταμέτρηση των διερχόμενων αυτοκινήτων.

Η μεγάλη αύξηση του αριθμού των οχημάτων στο δρόμο και η αυξανόμενη αστικοποίηση οδηγούν σε πρόβλημα συμφόρησης, ειδικότερα στα μεγάλα αστικά κέντρα. Η συλλογή δεδομένων κυκλοφορίας εκτελείται παραδοσιακά με τη χρήση χειροκίνητων διαδικασιών ή με την εφαρμογή επαγωγικών βρόχων σε ορισμένες θέσεις [4]. Οι επαγωγικοί βρόχοι για την παρακολούθηση της κυκλοφορίας έγιναν πρότυπα σε πολλές δικαιοδοσίες και χρησιμοποιούνται ευρέως [5]. Διάφορες άλλες συμβατικές προσεγγίσεις παρακολούθησης της κυκλοφορίας περιλαμβάνουν παθητικές υπέρυθρες συσκευές, αισθητήρες Doppler και ραντάρ μικροκυμάτων, ακουστικούς ανιχνευτές, μαγνητικές λωρίδες και πιεζοηλεκτρικούς αισθητήρες. Ωστόσο, αυτές οι προσεγγίσεις κληρονομούν ορισμένους περιορισμούς (κυρίως κόστος εγκατάστασης και συντήρησης) καθιστώντας τους δύσκολο να αναπτυχθούν για λεπτομερή συλλογή δεδομένων με καλύτερη χωρική κάλυψη στις πόλεις.

Οι αυξανόμενες απαιτήσεις κινητικότητας οδηγούν στην αύξηση της κυκλοφορίας στο δρόμο, προκαλώντας την αύξηση της κατανάλωσης καυσίμων και της ατμοσφαιρικής ρύπανσης και την ηχορύπανση που προκαλούν τα οχήματα. Έχει παρατηρηθεί πως η διαδρομή που θα επιλεγεί από τον οδηγό για την μετακίνηση του, λαμβάνοντας υπόψιν τα χαρακτηριστικά της διαδρομής, διαδραματίζει σημαντικό ρόλο στην αύξηση ή μείωση των ρύπων [6]. Η οδική κυκλοφορία αποτελεί σημαντική πηγή ατμοσφαιρικής ρύπανσης, κάτι που καθιστά την παρακολούθηση της αλληλεπίδρασης του οδικού δικτύου και των συνθηκών κυκλοφορίας πολύ σημαντικό. Για πολλά χρόνια έχουν σχεδιαστεί διάφορες προσεγγίσεις για την παρακολούθηση της ατμοσφαιρικής ρύπανσης στην πόλη [7], ενώ ταυτόχρονα έχουν αναπτυχθεί διάφορα μοντέλα για την μέτρηση των ρύπων σε μακροσκοπικό και σε μικροσκοπικό επίπεδο.

## **1.2 Οργάνωση Μεταπτυχιακής Εργασίας**

Το υπόλοιπο αυτής της μεταπτυχιακής εργασίας χωρίζεται σε τρεις ενότητες που καταλαμβάνουν τα Κεφάλαιο 2 - 4, αντίστοιχα. Συγκεκριμένα:

Στο Κεφάλαιο 2 γίνεται ανάλυση της μηχανικής μάθησης παρουσιάζονται ορολογίες που είναι απαραίτητες για την κατανόηση της παρούσας εργασίας, ενώ ταυτόχρονα γίνεται και αναφορά στα μοντέλα εκμάθησης.

Στο Κεφάλαιο 3 παρουσιάζεται μια βιβλιογραφική ανασκόπηση των μεθόδων που χρησιμοποιούνται για την καταμέτρηση των οχημάτων στους δρόμους

Στο Κεφάλαιο 4 αναπτύσσονται οι μέθοδοι και τα μοντέλα με τα οποία γίνεται η καταμέτρηση των οδικών ρύπων.

Στο Κεφάλαιο 5 γίνεται αναλυτική παρουσίαση της μεθοδολογίας που χρησιμοποιήθηκε για την ανάπτυξη του υπολογιστικού μοντέλου ρύπων.

Τα αποτελέσματα της εργασίας παρουσιάζονται στο Κεφάλαιο 6, ενώ δίνονται και παραδείγματα των αποτελεσμάτων σε μορφή εικόνων.


Τέλος, στο Κεφάλαιο 7 και 8 αναπτύσσονται συμπεράσματα της μεταπτυχιακής εργασίας και κατευθύνσεις για περαιτέρω έρευνα αντίστοιχα.

## Κεφάλαιο 2. ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Στο κεφάλαιο αυτό δίνονται πληροφορίες σχετικά με την μηχανική μάθηση (MM) και τον τρόπο λειτουργίας της. Γίνεται μια βιβλιογραφική αναφορά σχετικά με τη θεωρία και τις μεθόδους της μηχανικής μάθησης.

### 2.1 Ορολογία και ορισμοί μηχανικής μάθησης

Τυπικά, οι μεθοδολογίες MM περιλαμβάνουν μια διαδικασία μάθησης με στόχο να μάθουν από την "εμπειρία" (σετ εκπαίδευσης) για να εκτελέσουν μια εργασία. Τα δεδομένα στην MM συνίστανται σε ένα σύνολο παραδειγμάτων. Συνήθως, ένα μεμονωμένο παράδειγμα περιγράφεται από ένα σύνολο χαρακτηριστικών, γνωστό και ως χαρακτηριστικά ή μεταβλητές. Τα χαρακτηριστικά μπορεί να έχουν πλασματική μορφή (απαρίθμηση), δυαδική (δηλ. 0 ή 1), τακτική (π.χ. A + ή B-), ή αριθμητική (ακέραιος αριθμός, πραγματικός αριθμός κλπ.). Η απόδοση του μοντέλου MM σε μια συγκεκριμένη εργασία μετριέται με μια μέτρηση απόδοσης που βελτιώνεται με την εμπειρία με την πάροδο του χρόνου. Για τον υπολογισμό της απόδοσης μοντέλων και αλγορίθμων MM, χρησιμοποιούνται διάφορα στατιστικά και μαθηματικά μοντέλα. Μετά το τέλος της διαδικασίας εκμάθησης, το εκπαιδευμένο μοντέλο μπορεί να χρησιμοποιηθεί για την ταξινόμηση, την πρόβλεψη ή τη συγκέντρωση νέων παραδειγμάτων (σετ δοκιμής) χρησιμοποιώντας την εμπειρία που αποκτήθηκε κατά τη διάρκεια της διαδικασίας εκπαίδευσης. Το Σχήμα 2- 1 παρουσιάζει μια τυπική προσέγγιση MM.



Σχήμα 2- 1: Τυπική προσέγγιση μηχανικής μάθησης

Τα βήματα της MM ταξινομούνται συνήθως σε διαφορετικές ευρείες κατηγορίες, ανάλογα με τον τύπο μάθησης (εποπτευόμενο / μη εποπτευόμενο), μοντέλα μάθησης (ταξινόμηση,

παλινδρόμηση, ομαδοποίηση και μείωση των διαστάσεων) ή τα μαθησιακά μοντέλα που χρησιμοποιούνται για την υλοποίηση της επιλεγμένης εργασίας.

## 2.2 Βήματα της Μηχανικής Μάθησης

Τα βήματα εκμάθησης ενός μοντέλου MM κατηγοριοποιείται σε δύο κύριες κατηγορίες, με υπό εποπτεία και χωρίς εποπτεία εκμάθηση, ανάλογα με τα χαρακτηριστικά και το είδος της εκμάθησης. Στην εποπτευόμενη μάθηση, τα δεδομένα παρουσιάζονται με παραδείγματα εισόδων και τις αντίστοιχες εξόδους και ο στόχος είναι να κατασκευαστεί ένας γενικός κανόνας που χαρτογραφεί τις εισροές στις εξόδους. Σε ορισμένες περιπτώσεις, οι εισροές μπορούν να είναι μόνο μερικώς διαθέσιμες, με μερικές από τις εξόδους στόχου να λείπουν ή να παρέχονται μόνο ως ανατροφοδότηση στις δράσεις σε ένα δυναμικό περιβάλλον (ενισχυτική μάθηση). Στην εποπτευόμενη εκμάθηση, η αποκτηθείσα τεχνογνωσία (μοντέλο εκπαίδευσης) χρησιμοποιείται για την πρόβλεψη των άγνωστων ως προς το μοντέλο εξόδων (ετικέτες-κατηγορίες) από τα σετ δοκιμών. Στη μη εποπτευόμενη μάθηση, ωστόσο, δεν υπάρχει διάκριση μεταξύ σετ εκπαίδευσης και δοκιμής και τα δεδομένα δεν έχουν κατηγοριοποιηθεί. Το μοντέλο εκπαίδευσης επεξεργάζεται τα δεδομένα εισόδου με στόχο την εύρεση κρυφών μοτίβων. Στο Σχήμα 2- 2 που ακολουθεί παρουσιάζονται τα βασικά βήματα ενός μοντέλου MM.



Σχήμα 2- 2: Βασικά βήματα για το μοντέλο MM

## 2.3 Ανάλυση της μάθησης

Η Μείωση Διαστάσεων (ΜΔ) είναι μια μαθηματική-στατιστική ανάλυση που εφαρμόζεται και για τις δύο κατηγορίες εκμάθησης, εποπτευόμενες και μη, με στόχο την δημιουργία μιας πιο συμπαγούς κατώτερης διάστασης αναπαράστασης ενός συνόλου δεδομένων αλλά με τη διατήρηση όσο το δυνατόν περισσότερων πληροφοριών από τα αρχικά δεδομένα. Συνήθως εκτελείται πριν από την εφαρμογή ενός μοντέλου ταξινόμησης ή παλινδρόμησης, προκειμένου να αποφευχθούν οι επιπτώσεις των διαστάσεων. Μερικοί από τους πιο συνηθισμένους αλγόριθμους ΜΔ είναι οι ακόλουθοι: (i) ανάλυση κύριων

συστατικών [8], (ii) μερική παλινδρόμηση των ελάχιστων τετραγώνων [9] και (iii) ανάλυση γραμμικών διακρίσεων [10].

## 2.4 Μοντέλα εκμάθησης


Σε αυτή την υπό κατηγορία του κεφαλαίου 2, παρουσιάζονται τα πιο σημαντικά-αιχμής μοντέλα-αλγόριθμοι MM που εφαρμόζονται σε εκπαιδευτικό, ερευνητικό και βιομηχανικό επίπεδο.

### 2.4.1 Παλινδρόμηση - Regression

Η παλινδρόμηση αποτελεί ένα εποπτευόμενο μοντέλο μάθησης, το οποίο στοχεύει να παρέχει την πρόβλεψη μιας μεταβλητής εξόδου σύμφωνα με τις μεταβλητές εισόδου που είναι γνωστές. Οι πιο γνωστοί αλγόριθμοι περιλαμβάνουν τη γραμμική παλινδρόμηση και την υλικοτεχνική παλινδρόμηση [11], καθώς και τη σταδιακή παλινδρόμηση [12]. Επίσης, αναπτύχθηκαν πιο περίπλοκοι αλγόριθμοι παλινδρόμησης, όπως η συνηθισμένη παλινδρόμηση των ελάχιστων τετραγώνων [13], η πολλαπλή γραμμική παλινδρόμηση, η κυβιστική [14] και η τοπική εκτίμηση της εξομάλυνσης του διαγράμματος διασποράς [15].

### 2.4.2 Ομαδοποίηση - Clustering

Η ομαδοποίηση [16] είναι μια τυπική εφαρμογή του μη εποπτευόμενου μαθησιακού μοντέλου, που συνήθως χρησιμοποιείται για την εύρεση φυσικών ομαδοποιήσεων δεδομένων (ομάδες). Οι πιο γνωστές τεχνικές ομαδοποίησης είναι η τεχνική k-mean [17], η ιεραρχική τεχνική [18] και η τεχνική μεγιστοποίησης προσδοκιών [19]. Στο Σχήμα 2- 3 φαίνονται τα βήματα ομαδοποίησης k-means.



Σχήμα 2- 3: Βήματα ομαδοποίησης k-means

### 2.4.3 Μοντέλα Bayesian – Bayesian Models

Τα μοντέλα Bayesian (MB) είναι μια οικογένεια πιθανοτικών γραφικών μοντέλων στα οποία η ανάλυση πραγματοποιείται στο πλαίσιο της Bayesian συμπερασματολογίας. Αυτός




ο τύπος μοντέλων ανήκει στην κατηγορία εποπτευόμενης μάθησης και μπορεί να χρησιμοποιηθεί για την επίλυση είτε προβλημάτων ταξινόμησης είτε παλινδρόμησης. Το απλοϊκό μοντέλο Bayes [20], τα κατά Gauss απλοϊκά μοντέλα, τα πολυωνυμικά απλοϊκά Bayes μοντέλα, το μοντέλο συνδυασμών Gauss [21] και το δίκτυο εμπιστοσύνης Bayes [22] είναι μερικοί από τους πιο σημαντικούς αλγορίθμους στην υποκατηγορία αυτή.

#### **2.4.4 Μοντέλα Βασισμένα σε Περιπτώσεις – Instance Based Models**

Τα μοντέλα βασισμένα σε περιπτώσεις (ΜΒΠ) είναι μοντέλα που βασίζονται στη μνήμη, τα οποία μαθαίνουν συγκρίνοντας νέα παραδείγματα με διάφορες περιπτώσεις σύνδεσης μεταξύ τους, μέσω της βάσης δεδομένων εκπαίδευσης. Κατασκευάζουν υποθέσεις απευθείας από τα διαθέσιμα δεδομένα, ενώ δεν διατηρούν ένα σύνολο αφαίρεσης και παράγουν προβλέψεις ταξινόμησης ή παλινδρόμησης χρησιμοποιώντας μόνο συγκεκριμένες περιπτώσεις. Το μειονέκτημα αυτών των μοντέλων είναι ότι η πολυπλοκότητά τους αυξάνεται με των όγκο των δεδομένων. Οι πιο συνηθισμένοι αλγόριθμοι μάθησης σε αυτή την κατηγορία είναι ο k-πλησιέστερος γείτονας [23], η τοπικά σταθμισμένη μάθηση [24] και η κβαντοποίηση του διανύσματος μάθησης [25].

#### **2.4.5 Δέντρα Αποφάσεων – Decision Trees**

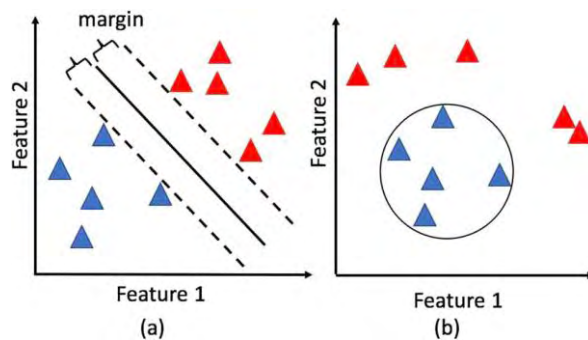
Τα δέντρα αποφάσεων (ΔΑ) είναι μοντέλα ταξινόμησης ή παλινδρόμησης που διαμορφώνονται σε με την μορφή αρχιτεκτονικής ενός δέντρου [26]. Με το μοντέλο ΔΑ, το σύνολο δεδομένων οργανώνεται προοδευτικά σε μικρότερες ομοιογενείς υποομάδες (υποομάδες) ενώ παράλληλα παράγεται ένα σχετικό γράφημα δέντρου. Κάθε εσωτερικός κόμβος της δομής δέντρου αντιπροσωπεύει μια διαφορετική σύγκριση ανά ζεύγη σε ένα επιλεγμένο χαρακτηριστικό ενώ κάθε κλάδος αντιπροσωπεύει το αποτέλεσμα αυτής της σύγκρισης. Οι κόμβοι των φύλλων αντιπροσωπεύουν την τελική απόφαση ή την πρόβλεψη που λαμβάνεται αφού ακολουθήσουμε τη διαδρομή από ρίζα σε φύλλο (εκφραζόμενη ως κανόνας ταξινόμησης). Οι πιο συνηθισμένοι αλγόριθμοι εκμάθησης σε αυτή την κατηγορία είναι οι δέντρα ταξινόμησης και παλινδρόμησης [27], ο ανιχνευτής αυτόματης αλληλεπίδρασης chi-square [28] και ο επαναληπτικός διχοτοποιητής [29]. Ένα παράδειγμα ταξινόμησης παρουσιάζεται στο Σχήμα 2- 4.



Σχήμα 2- 4: Παράδειγμα ταξινόμησης ΔΑ

#### 2.4.6 Μηχανές Υποστήριξης Διανυσμάτων – Support Vector Machines


Οι Μηχανές Υποστήριξης Διανυσμάτων (ΜΥΔ) παρουσιάστηκαν για πρώτη φορά στο άρθρο [30] που αναφέρεται σχετικά με τη θεμελίωση της θεωρίας της στατιστικής μάθησης. Οι ΜΥΔ είναι εγγενώς ένας δυαδικός ταξινομητής που κατασκευάζει ένα γραμμικό διαχωριστικό υπερπλάσιο για την ταξινόμηση των στιγμιότυπων δεδομένων. Οι δυνατότητες ταξινόμησης των παραδοσιακών ΜΥΔ μπορούν να ενισχυθούν σημαντικά μέσω του μετασχηματισμού του αρχικού χώρου χαρακτηριστικών σε ένα χώρο χαρακτηριστικών μιας υψηλότερης διάστασης χρησιμοποιώντας το «κόλπο του πυρήνα». Οι ΜΥΔ έχουν χρησιμοποιηθεί για ταξινόμηση, παλινδρόμηση και ομαδοποίηση. Με βάση τη σφαιρική βελτιστοποίηση, οι ΜΥΔ ασχολούνται με προβλήματα υπερφόρτωσης που εμφανίζονται σε χώρους μεγάλης διαστάσεως, καθιστώντας τους ελκυστικούς σε διάφορες εφαρμογές [31]. Οι πιο ευρέως χρησιμοποιούμενοι αλγόριθμοι ΜΥΔ περιλαμβάνουν την υποστήριξη διανυσμάτων παλινδρόμησης [32], τη μηχανή υποστήριξης διανυσμάτων ελαχίστων τετραγώνων [33] και την μηχανή υποστήριξης διανυσμάτων διαδοχική προβολής [34]. Στο Σχήμα 2- 5 παρουσιάζονται (α) παράδειγμα ταξινόμησης ΜΥΔ δυο κλάσεων και (b) παράδειγμα ταξινόμησης ΜΥΔ μιας κλάσης.



Σχήμα 2- 5:(a) Παράδειγμα ταξινόμησης ΜΥΔ δυο κλάσεων,  
(b) Παράδειγμα ταξινόμησης ΜΥΔ μιας κλάσης

#### 2.4.7 Μοντέλα Συνόλου – Ensemble Learning

Τα Μοντέλα Συνόλου (ΜΣ) στοχεύουν στη βελτίωση της προγνωστικής απόδοσης μιας δεδομένης τεχνικής μάθησης ή μοντελοποίησης μοντέλων κατασκευάζοντας ένα γραμμικό συνδυασμό απλούστερων μηχανισμών εκμάθησης. Θεωρώντας ότι κάθε εκπαιδευμένο σύνολο αντιπροσωπεύει μία και μοναδική υπόθεση, αυτά τα συστήματα πολλαπλών ταξινομητών επιτρέπουν την υβριδοποίηση μοντέλων ΜΜ που δεν προκαλούνται από τον ίδιο μηχανισμό εκμάθησης, αποδίδοντας έτσι καλύτερα αποτελέσματα σε περίπτωση σημαντικής ποικιλομορφίας μεταξύ των κλασσικών μοντέλων. Δηλαδή, συνδυάζουν μια ποικιλία αλγορίθμων ΜΜ για την εκπαίδευση των μοντέλων. Τα δέντρα αποφάσεων χρησιμοποιούνται τυπικά ως βασικοί εκπαιδευτές σε ΜΣ. Μερικούς από τους πιο γνωστούς αλγορίθμους ΜΣ είναι, Τυχαία Δάση (ΤΔ) [35], ο αλγόριθμος adaboost [36] και αλγόριθμος εκκίνησης συνόλου [37]. Στο παρακάτω Σχήμα 2- 6 παρουσιάζεται παράδειγμα ταξινόμησης του αλγορίθμου ΤΔ.




Σχήμα 2- 6: Παράδειγμα ταξινόμησης ΤΔ

#### 2.4.8 Τεχνητά Νευρωνικά Δίκτυα – Artificial Neural Networks

Τα Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ) χωρίζονται σε δύο κατηγορίες. Τα κλασσικά ΤΝΔ" και "Σε βάθος ΤΝΔ". Τα ΤΝΔ είναι εμπνευσμένα από τη λειτουργικότητα του ανθρώπινου εγκεφάλου, εξομοιώνοντας περίπλοκες λειτουργίες όπως η δημιουργία προτύπων, η γνώση, η μάθηση και η λήψη αποφάσεων [38]. Ο ανθρώπινος εγκέφαλος αποτελείται από δισεκατομμύρια νευρώνες που αλληλοσυνδέονται και επεξεργάζονται κάθε παρεχόμενη πληροφορία. Ομοίως, ένα ΤΝΔ ως ένα απλοποιημένο μοντέλο της δομής του βιολογικού νευρωνικού δικτύου, αποτελείται από διασυνδεδεμένες μονάδες επεξεργασίας που οργανώνονται σε μια συγκεκριμένη τοπολογία. Ένας αριθμός κόμβων είναι διατεταγμένοι σε πολλαπλά επίπεδα, συμπεριλαμβανομένων των παρακάτω:


- Ένα επίπεδο εισόδου όπου τα δεδομένα τροφοδοτούνται στο σύστημα,
- Ένα ή περισσότερα κρυφά επίπεδα όπου λαμβάνει χώρα η μάθηση, και
- Ένα επίπεδο εξόδου όπου δίνεται η απόφαση / πρόβλεψη.

Τα ΤΝΔ είναι εποπτευόμενα μοντέλα που χρησιμοποιούνται συνήθως για προβλήματα παλινδρόμησης και ταξινόμησης. Οι αλγόριθμοι εκμάθησης που χρησιμοποιούνται συνήθως στα ΤΝΔ περιλαμβάνουν τους αλγορίθμους perceptron [39], την οπίσθια διάδοση [40] και την ανθεκτική οπίσθια διάδοση [41]. Επίσης, έχει αναφερθεί ένας μεγάλος αριθμός αλγορίθμων μάθησης που βασίζονται σε ΤΝΔ, όπως αλγόριθμοι αντίθετης διάδοσης [42], συστήματα adaptive-neuro fuzzy inference [43], autoencoder, XY-Union και επιτηρούμενα δίκτυα Kohonen [44] όπως τα δίκτυα Hopfield [45], το πολλαπλών στρώσεων perceptron [46], οι αυτο-οργανωτικοί χάρτες [47], οι μηχανές ακραίας εκμάθησης [48], το γενικευμένο νευρωνικό δίκτυο παλινδρόμησης [49]. Ένα παράδειγμα ταξινόμησης ΤΝΔ παρουσιάζεται στο Σχήμα 2- 7.




Σχήμα 2- 7: Παράδειγμα ταξινόμησης ΤΝΔ

Τα σε βάθος ΤΝΔ αναφέρονται ευρύτερα ως Μάθηση σε Βάθος (ΜΒ) ή Βαθιά Νευρωνικά δίκτυα (ΒΝΔ) [50]. Πρόκειται για μια σχετικά νέα περιοχή έρευνας της ΜΜ που επιτρέπει υπολογιστικά μοντέλα που αποτελούνται από πολλαπλά στρώματα επεξεργασίας να μάθουν περίπλοκες αναπαραστάσεις δεδομένων χρησιμοποιώντας πολλαπλά επίπεδα αφαίρεσης. Ένα από τα κύρια πλεονεκτήματα του ΜΒ είναι ότι σε ορισμένες περιπτώσεις, το βήμα της εξαγωγής χαρακτηριστικών πραγματοποιείται από το ίδιο το μοντέλο. Τα μοντέλα ΜΒ έχουν βελτιώσει δραματικά την κατάσταση της τεχνολογίας σε πολλούς διαφορετικούς τομείς και βιομηχανίες, συμπεριλαμβανομένης της γεωργίας, της πληροφορικής [51]. Τα ΒΝΔ είναι απλώς ένα ΤΝΔ με πολλαπλά κρυμμένα στρώματα μεταξύ των επιπέδων εισόδου και εξόδου και μπορούν είτε να εποπτεύονται, να παρακολουθούνται μερικώς ή και να μην παρακολουθούνται. Ένας ευρέως γνωστός αλγόριθμος ΜΒ είναι το Συναινετικό Νευρωνικό Δίκτυο (ΣΝΔ), ο οποίος χρησιμοποιείται για την εκπαίδευση μοντέλων μηχανικής όρασης, μέσω εικόνων και βίντεο. Μια περιεκτική εισαγωγή όσο αφορά τα ΣΝΔ δίνεται στη βιβλιογραφία [52]. Άλλες τυπικές αρχιτεκτονικές ΜΒ περιλαμβάνουν τη βαθιά μηχανή Boltzmann, το δίκτυο βαθιών πεποιθήσεων [53] τους αυτόματους κωδικοποιητές [54] και τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα (ΕΝΔ) [55]. Στο Σχήμα 2- 8 και Σχήμα 2- 9 παρουσιάζονται παραδείγματα ταξινόμησης ΣΝΔ και ΕΝΔ αντίστοιχα.



Σχήμα 2- 8: Παράδειγμα ταξινόμησης ΣΝΔ



Σχήμα 2- 9: Παράδειγμα ταξινόμησης ΕΝΔ

## Κεφάλαιο 3. ΜΕΘΟΔΟΙ ΚΑΤΑΜΕΤΡΗΣΗΣ ΟΧΗΜΑΤΩΝ

---

Η συνεχόμενη αύξηση του πληθυσμού σε συνδυασμό με την αύξηση της κυκλοφορίας οχημάτων έχουν ως απόρροια την κυκλοφοριακή συμφόρηση, ειδικότερα στις μεγάλες μητροπόλεις, με τελικό αποτέλεσμα την διεύρυνση του προβλήματος της ατμοσφαιρικής ρύπανσης. Η επιλογή των κατάλληλων μέτρων για την μείωση της οδικής ρύπανσης εξαρτάται σε μεγάλο βαθμό από την παρακολούθηση της κυκλοφορίας και τον υπολογισμό των οχημάτων στους δρόμους.

Στο κεφάλαιο αυτό παρουσιάζεται μια βιβλιογραφική αναφορά κάποιων τύπων τεχνολογιών και μεθόδων που χρησιμοποιούνται για τον υπολογισμό της κυκλοφοριακής συμφόρησης. Συγκεκριμένα, οι τεχνολογίες με τις οποίες υπολογίζεται το σύνολο των οχημάτων στους δρόμους μπορούν να ταξινομηθούν στις ακόλουθες τέσσερις κατηγορίες.

1. Intrusive devices
2. Non-intrusive devices
3. Off-roadway devices
4. Sensor combinations devices


### 3.1 Intrusive Devices

Σε αυτή την τεχνολογία η τοποθέτηση των ανιχνευτών γίνεται στην επιφάνεια της οδού ή κάτω από αυτήν. Κατά την εγκατάσταση ή την επιδιόρθωση τέτοιων συσκευών διακόπτεται η κυκλοφορία των οχημάτων στο συγκεκριμένο δρόμο, προκαλώντας πιθανόν κυκλοφοριακή συμφόρηση. Ένα ακόμα μειονέκτημα αυτών των συσκευών είναι πως κατά την επιδιόρθωση του οδοστρώματος δημιουργείται η ανάγκη για επανεγκατάσταση αυτών. Η εφαρμογή τους σε μεγάλη κλίμακα περιορίζεται λόγω του μεγάλου κόστους και της μεγάλης κατανάλωσης ισχύος, ενώ δημιουργείται ανησυχία για την ασφάλεια των εργαζομένων που αναπτύσσουν τις συσκευές [56].

Ως Intrusive devices θεωρούνται οι επαγωγικοί βρόγχοι (inductive loop-IDL), οι μαγνητικοί ανιχνευτές (magnetic detectors), οι πιεζοηλεκτρικοί μηχανισμοί (piezoelectric devices) και οι πνευματικοί οδικοί σωλήνες (pneumatic road tubes).

Ζεύγη ανιχνευτών επαγωγικού βρόγχου που τοποθετούνται σε διάφορες θέσεις στο δρόμο μπορούν να χρησιμοποιηθούν για τον εντοπισμό οχημάτων με βάση την απόσταση των αξόνων [57]. Ο βρόχος χρησιμοποιεί την αρχή πως όταν ένα μαγνητικό πεδίο που εισάγεται κοντά σε έναν ηλεκτρικό αγωγό προκαλεί ηλεκτρικό ρεύμα. Στην περίπτωση


παρακολούθησης κυκλοφορίας, ένα όχημα λειτουργεί ως μαγνητικό πεδίο και ο επαγωγικός βρόχος ως ηλεκτρικός αγωγός. Μια συσκευή στο δρόμο καταγράφει τα παραγόμενα σήματα. Η τεχνική αυτήν είναι δαπανηρή για αυτό το λόγο η ευρεία εφαρμογή της είναι απαγορευτική. Στο Σχήμα 3- 1 φαίνονται τα στοιχεία ενός επαγωγικού βρόγχου και ο τρόπος λειτουργίας του.



Σχήμα 3- 1: Στοιχεία ενός επαγωγικού βρόγχου.

Οι μαγνητικοί ανιχνευτές (magnetic detectors) ανιχνεύουν τα οχήματα μετρώντας την αλλαγή στο μαγνητικό πεδίο της γης, καθώς τα οχήματα διέρχονται πάνω από τον ανιχνευτή. Αυτή η μέθοδος καταμέτρησης των οχημάτων προτάθηκε ως εναλλακτική μέθοδος χαμηλού κόστους για την αποφυγή χρήσης των επαγωγικών βρόγχων [58]. Με τη χρήση αυτών των συσκευών υπάρχει η πιθανότητα ο ανιχνευτής να δυσκολευτεί να κάνει τον διαχωρισμό δυο οχημάτων, εφόσον αυτά διέλθουν σε πολύ κοντινή απόσταση μεταξύ τους. Ένα ακόμα μειονέκτημα αυτής της μεθόδου είναι η αναξιόπιστη ανίχνευση των μοτοσικλετών [58]. Ένα παράδειγμα μαγνητικού ανιχνευτή απεικονίζεται στο Σχήμα 3- 2.





Σχήμα 3- 2: Παράδειγμα μαγνητικού ανιχνευτή

Οι πιεζοηλεκτρικοί μηχανισμοί (piezoelectric devices) καταγράφουν δεδομένα με την μετατροπή της μηχανικής σε ηλεκτρική ενέργεια. Κατά την διέλευση ενός οχήματος πάνω από τον αισθητήρα γίνεται συμπίεση του αισθητήρα και προκαλείται ένα σήμα τάσης, το οποίο κατά την απομάκρυνση του οχήματος αναστρέφεται. Η αλλαγή στην τάση χρησιμοποιείται για την καταμέτρηση των οχημάτων. Ο καταγραφέας των δεδομένων τοποθετείται στην άκρη του δρόμου. Το μέγεθος του σήματος είναι ανάλογο του βαθμού παραμόρφωσης του αισθητήρα και με αυτόν τον τρόπο γίνεται η αναγνώριση του τύπου του οχήματος. Στο παρακάτω Σχήμα 3- 3 φαίνεται ένας πιεζοηλεκτρικός μηχανισμός.



Σχήμα 3- 3: Παράδειγμα πιεζοηλεκτρικού μηχανισμού

Για την καταμέτρηση των οχημάτων με τους πνευματικούς οδικούς σωλήνες (pneumatic road tubes), ένας ή περισσότεροι ελαστικοί και εύκαμπτοι σωλήνες διασχίζουν κάθετα τον δρόμο και συνδέονται στο ένα άκρο με καταγραφικό μηχάνημα, ενώ το άλλο άκρο του σωλήνα είναι σφραγισμένο. Οι καταγραφές μετά φορτώνονται σε έναν υπολογιστή για περαιτέρω επεξεργασία. Σε κάθε δρόμο απαιτείται τουλάχιστον ένας οδικός σωλήνας για κάθε κατεύθυνση. Με το χτύπημα του σωλήνα από ένα ζευγάρι τροχών, η πίεση του αέρα στο σωλήνα ενεργοποιεί τον καταγραφέα και με αυτό τον τρόπο καταγράφεται η ώρα διέλευσης του οχήματος. Η κατεύθυνση του οχήματος μπορεί να καθοριστεί, καθώς ο καταγραφέας δεδομένων ανιχνεύει ποιο σωλήνα διέλευσε πρώτα το όχημα. Σε περίπτωση που δυο οχήματα διασχίζουν τους σωλήνες βρίσκονται πολύ κοντά μεταξύ τους, ο καταγραφέας μπορεί να τα θεωρήσει ως ένα multiaxle όχημα. Το μειονέκτημα της μεθόδους των πνευματικών οδικών σωλήνων είναι η αναποτελεσματικότητα σε αυτοκινητόδρομο μεγάλου όγκου κυκλοφορίες και πολλών λωρίδων. Το σχήμα 3-4 παρουσιάζει ένα πνευματικό οδικό σωλήνα καταμέτρησης οχημάτων.



Σχήμα 3- 4: Πνευματικός οδικός σωλήνας καταμέτρησης οχημάτων

### 3.2 Non-Intrusive Devices

Για την τοποθέτηση αυτών των συσκευών προκαλείται ελάχιστη διακοπή της κυκλοφορίας, καθώς τοποθετούνται πάνω στην επιφάνεια του δρόμου. Αυτήν η τεχνολογία είναι πιο αξιόπιστη και οικονομικά αποδοτική σε σύγκριση με τις συσκευές intrusive. Το μειονέκτημα αυτών των συσκευών είναι πως δεν λειτουργούν ικανοποιητικά υπό ορισμένες περιβαλλοντικές συνθήκες. Λόγω του υψηλού κόστους εγκατάστασης και συντήρησης περιορίζεται κατά μεγάλο βαθμό η ενσωμάτωση αυτών των συσκευών στα συστήματα επιτήρησης της κυκλοφορίας [59].

Στις non-intrusive τεχνολογίες περιλαμβάνονται τεχνολογίες όπως χειροκίνητες μέθοδοι (manual methods), ραντάρ Doppler (Doppler radar), παθητική υπέρυθρη ακτινοβολία (passive infrared), παθητική ακουστική συστοιχία (passive acoustic array) και επεξεργασία εικόνας βίντεο (video image processing).

Η χειροκίνητη μέθοδος (manual method), είναι μια απλή και ακριβής μέθοδος καταμέτρησης των οχημάτων στους δρόμους. Ένας άνθρωπος χρησιμοποιώντας ηλεκτρονικό υπολογιστή ή καταγράφοντας δεδομένα σε ένα φύλλο εγγραφής κάνει την καταμέτρηση της κυκλοφορίας. Συνήθως, αυτή η διαδικασία γίνεται μέσω τις παρακολούθησης ενός βίντεο του δρόμου και όχι με επιτόπια παρουσία. Με χειρωνακτικές μετρήσεις λαμβάνεται ένα μικρό δείγμα δεδομένων συνήθως λιγότερο από μία ημέρα και τα αποτελέσματα υποβάλλονται σε επέκταση για το υπόλοιπο του έτους ή την εποχή. Χρησιμοποιώντας

χειροκίνητη μέθοδο για την καταμέτρηση ενός τεράστιου όγκου κίνησης δημιουργούνται προβλήματα διαθεσιμότητας ανθρώπινου δυναμικού και ακρίβειας.


Οι συσκευές ανίχνευσης μικροκυμάτων Doppler (Doppler radar), μεταδίδουν ένα συνεχές σήμα ακτινοβολίας μικροκυμάτων χαμηλής ενέργειας σε μια περιοχή στόχου και στη συνέχεια αναλύουν το ανακλώμενο σήμα. Ο ανιχνευτής καταγράφει μια αλλαγή στη συχνότητα των κυμάτων όταν η πηγή μικροκυμάτων και το όχημα κινούνται το ένα σε σχέση με το άλλο. Αυτό επιτρέπει στη συσκευή να ανιχνεύει κινούμενα οχήματα. Το ραντάρ είναι ικανό να ανιχνεύει μακρινά αντικείμενα και να καθορίζει τη θέση και την ταχύτητα κίνησης τους. Με την ανίχνευση οχήματος, μια συσκευή κατευθύνει ραδιοκύματα υψηλής συχνότητας στο οδόστρωμα για να καθορίσει την καθυστέρηση του σήματος επιστροφής, υπολογίζοντας έτσι την απόσταση από το ανιχνευμένο όχημα. Στο Σχήμα 3- 5 φαίνεται ένα παράδειγμα ανιχνευτή μικροκυμάτων Doppler.



Σχήμα 3- 5: Ανιχνευτής μικροκυμάτων Doppler

Με τη τεχνολογία των παθητικών συσκευών υπέρυθρης ακτινοβολίας (passive infrared) η ανίχνευση των οχημάτων γίνεται με τη μέτρηση της εκπεμπόμενης υπέρυθρης ακτινοβολίας στη ζώνη ανίχνευσης. Με τη διέλευση ενός οχήματος η εκπεμπόμενη ενέργεια αλλάζει και έτσι γίνεται η καταμέτρηση. Οι αισθητήρες τέτοιας τεχνολογίας μπορούν να χρησιμοποιηθούν για την ανίχνευση οχημάτων σε μια έως δύο λωρίδες κυκλοφορίας. Αργές θερμοκρασιακές αλλαγές στην επιφάνεια του οδοστρώματος, που οφείλονται στις μεταβαλλόμενες καιρικές συνθήκες, αγνοούνται. Παρόλα αυτά σε απότομες αλλαγές θερμοκρασίας και σε συνθήκες ομίχλης μπορεί να επηρεαστεί η αποτελεσματικότητα αυτών

των συσκευών. Ο τρόπος λειτουργίας μιας παθητικής συσκευής υπέρυθρης ακτινοβολίας παρουσιάζεται στο Σχήμα 3- 6 που ακολουθεί.



Σχήμα 3- 6: Παθητική συσκευή υπέρυθρης ακτινοβολίας


Ο ακουστικός αισθητήρας ανιχνεύει τα οχήματα από τον ήχο που δημιουργείται κατά την διέλευση τους. Ο αισθητήρας είναι σε θέση να συλλέγει μετρήσεις για μία ή περισσότερες λωρίδες κυκλοφορίας. Είναι τοποθετημένος σε έναν πόλο στραμμένο προς την κυκλοφορία, δηλαδή προς τα κάτω. Στο Σχήμα 3- 7 φαίνεται ένας ακουστικός αισθητήρας καταμέτρησης οχημάτων.



Σχήμα 3- 7: Ακουστικός αισθητήρας για καταμέτρηση οχημάτων



Με τη μέθοδο επεξεργασίας εικόνας και video (video image processing) γίνεται αυτόματη ανάλυση εικόνων και videos καθώς τα οχήματα περνούν κάτω από μια τοποθετημένη κάμερα, ανιχνεύοντας οχήματα με παρόμοια ακρίβεια με τη μέθοδο της χειρωνακτικής καταμέτρησης. Αυτή η μέθοδος καταμέτρησης οχημάτων έχει αρκετά πλεονεκτήματα σε σχέση με άλλα αυτόματα συστήματα. Είναι αποδοτική ως προς το κόστος καθώς μπορεί να κάνει μέτρηση σε πολλές κατευθύνσεις ταυτόχρονα και χρειάζεται μόνο μία κάμερα για αρκετές λωρίδες ή έξοδο σε μια διασταύρωση. Εάν κρίνεται απαραίτητο με την τεχνολογία αυτήν υπάρχει η δυνατότητα μεταφόρτωσης των μετρήσεων της κυκλοφορίας σε πραγματικό χρόνο μέσω διαδικτύου. Η καταμέτρηση της κυκλοφορίας με αυτή τη μέθοδο γίνεται συνεχώς, καθ' όλη τη διάρκεια του έτους, δίνοντας ακριβή στοιχεία. Στο Σχήμα 3- 8 φαίνεται η αναγνώριση οχημάτων μέσω της μεθόδου επεξεργασίας εικόνας και video.



Σχήμα 3- 8: Μέθοδος επεξεργασίας εικόνας και video

### 3.3 Off-roadway devices

Αυτές οι συσκευές χρησιμοποιούν τις τεχνολογίες που δεν απαιτούν την τοποθέτηση υλικού κάτω από το οδόστρωμα. Οι συσκευές επιτρέπουν την παρακολούθηση της κυκλοφορίας μέσω του δορυφόρου, καθώς και την ανίχνευση των οχημάτων που είναι εφοδιασμένα με αυτόματη αναγνώριση οχήματος (Automatic Vehicle Location - AVL), Global Positioning System (GPS) και κινητά τηλέφωνα [60]. Οι συσκευές AVL παρέχουν είτε πληροφορίες θέσης όταν ένα όχημα κατάλληλα εξοπλισμένο περνάει ένα συγκεκριμένο σημείο στο δίκτυο, είτε συνεχείς πληροφορίες καθώς το όχημα μετακινείται μέσα σε ένα δίκτυο. Το σύστημα βασίζεται συνήθως σε κατάλληλα οχήματα που είναι εξοπλισμένα με αναμεταδότες που μεταδίδουν και λαμβάνουν πληροφορίες από οδικές μονάδες. Αυτές οι

τεχνολογίες μπορούν να βοηθήσουν στην επίτευξη του υψηλού ποσοστού κάλυψης των οδών. Ωστόσο, ένα από τα μειονεκτήματα αυτής της τεχνολογίας είναι η ανησυχία σχετικά με την προστασία της ιδιωτικής ζωής [61].

### **3.4 Sensor Combinations Devices**

Λόγω ορισμένων περιορισμών των μεμονωμένων τεχνολογιών, διάφορες μελέτες πρότειναν την εφαρμογή των συσκευών εκτός δρόμου (off-roadway devices) μαζί με περισσότερες από μία τεχνολογίες για την παρακολούθηση της κυκλοφοριακής ροής στο δρόμο. Οι εφαρμογές περιλαμβάνουν τον συνδυασμό παθητικών υπέρυθρων με υπερήχους και ραντάρ Doppler, που ενισχύουν την ακρίβεια για την ανίχνευση οχημάτων [59]. Ωστόσο, το κόστος ανάπτυξης και η πολυπλοκότητα αυτής της μεθόδου περιορίζουν την εκτεταμένη ανάπτυξη ενός δικτύου στις πόλεις.

### **3.5 Συμπεράσματα**

Συμπερασματικά, η παρακολούθηση της κυκλοφορίας είναι ζωτικής σημασίας, αλλά δύσκολη, καθώς για την κατασκευή χαρτών σχετικών με την κυκλοφοριακή πυκνότητα απαιτούνται παράμετροι όπως η μέτρηση των οχημάτων, η θέση, η ταχύτητα και η παρακολούθηση των οχημάτων. Μία από τις βασικές απαιτήσεις για αποτελεσματικά συστήματα κυκλοφορίας είναι η αξιόπιστη και σε πραγματικό χρόνο συλλογή δεδομένων από συσκευές που διευκολύνουν τη λήψη στιγμιαίων αποφάσεων.

Σε αυτό το κεφάλαιο παρουσιάστηκε μια βιβλιογραφική ανασκόπηση των μεθόδων που χρησιμοποιούνται για την καταμέτρηση της κυκλοφορίας στους δρόμους. Πρακτικά παρατηρήθηκε ότι οι intrusive αισθητήρες είναι σημαντικοί σε εφαρμογές κυκλοφορίας, κυρίως λόγω της ταχείας απόκρισης, της φθηνότερης λειτουργίας τους, καθώς και της ικανότητάς τους να ελέγχουν και να παρακολουθούν περιοχές με μεγάλο εύρος [62], αλλά έχουν αρκετά μειονεκτήματα, όπως παραδείγματος χάριν την απαίτηση εκσκαφής του δρόμου και ως εκ τούτου η εγκατάστασή τους είναι δαπανηρή. Οι non-intrusive τεχνολογίες παρέχουν ταυτόχρονη παρακολούθηση πολλών λωρίδων κυκλοφορίας δίνοντας πληροφορίες για την ταχύτητα και την τοποθεσία των οχημάτων, αλλά η ακρίβεια τους επηρεάζεται από τις περιβαλλοντικές συνθήκες. Η μεγάλη ακρίβεια και η επίτευξη μεγάλου ποσοστού κάλυψης των οδών αποτελούν τα κύρια πλεονεκτήματα των συσκευών off-road, αλλά με τη χρήση αυτών υπάρχει ανησυχία για την ιδιωτική ζωή των ανθρώπων

Στον ακόλουθο Πίνακα 1 παρουσιάζονται συγκεντρωτικά οι κατηγορίες των τεχνικών παρακολούθησης της κυκλοφορίας.

Τεχνολογία	Τοποθέτηση	Παραδείγματα	Πλεονεκτήματα	Μειονεκτήματα
<b>Intrusive</b>	Στην επιφάνεια του δρόμου ή κάτω από το δρόμο	Inductive loop Magnetic detectors Piezoelectric devices Pneumatic road tubes	Ταχεία απόκριση Ακρίβεια στην καταμέτρηση Φθηνή λειτουργία	Εκσκαφή του δρόμου και κλείσιμο λωρίδας για την τοποθέτηση Δαπανηρή εγκατάσταση
<b>Non-intrusive</b>	Συσκευές πάνω από το δρόμο	Manual methods Doppler radar Passive infrared Passive acoustic array	Πληροφορίες για ταχύτητα και θέση οχήματος, Παρακολούθηση πολλών λωρίδων ταυτόχρονα	Επιρροή των άσχημων περιβαλλοντικών συνθηκών στην απόδοση
<b>Off-road</b>	Τεχνολογίες που δεν απαιτούν τοποθέτηση υλικού κάτω από το οδόστρωμα	AVI GPS Κινητά τηλέφωνα	Μεγάλη ακρίβεια Υψηλό ποσοστό κάλυψης των οδών	Ανησυχία για την ιδιωτική ζωή, Ακριβή
<b>Sensor combinations</b>	Χρήση τους για να ξεπεραστούν περιορισμοί των μεμονωμένων τεχνολογιών	Passive infrared with ultrasound Infrared-Doppler microwave radar	Συνεργατικό αποτέλεσμα στην ενίσχυση της ακρίβειας	Περιορισμοί των μεμονωμένων τεχνολογιών, Ακριβή

Πίνακας 1: Συγκεντρωτικός πίνακας τεχνολογιών παρακολούθησης της τεχνολογίας

Οι τεχνικές επεξεργασίας εικόνας στη σημερινή εποχή κερδίζουν τις παραδοσιακές τεχνικές. Για αυτό το λόγο, στην παρούσα εργασία για την καταμέτρηση των οχημάτων στους δρόμους χρησιμοποιήθηκε η μέθοδος video image processing.



## Κεφάλαιο 4. ΜΕΤΡΗΣΗ ΟΔΙΚΩΝ ΡΥΠΩΝ

---

Καθώς η αστικοποίηση επιταχύνεται, τα περιβαλλοντικά ζητήματα που σχετίζονται με τις μεταφορές επιδεινώνονται. Η οδική κυκλοφορία αποτελεί μία από τις σημαντικότερες πηγές ατμοσφαιρικής ρύπανσης στις πόλεις. Το όχημα, ως πηγή εκπομπών, αποτελεί πολύ σημαντικό στοιχείο για την αξιολόγηση και την εκτίμηση των εξωτερικών περιβαλλοντικών επιπτώσεων στον τομέα των μεταφορών [63]. Πρόκειται για σημαντική ανθρωπογενή πηγή NO<sub>x</sub> [64], σωματιδίων (PM) και άλλων επιβλαβών ρύπων που επηρεάζουν την ανθρώπινη υγεία [4]. Η έκθεση στην ατμοσφαιρική ρύπανση που προκαλείται από την οδική κυκλοφορία μπορεί να οδηγήσει σε διάφορες διαταραχές της υγείας τόσο για την τρέχουσα όσο και για τη μελλοντική γενιά. Τα δεδομένα της κυκλοφορίας είναι μία από τις κρίσιμες μεταβλητές εισροών για προσεγγίσεις προσομοίωσης της ατμοσφαιρικής ρύπανσης [65],[7].

Στο κεφάλαιο αυτό παρουσιάζονται κάποιες από τις τεχνικές και τα μοντέλα που χρησιμοποιούνται για την μέτρηση των οδικών ρύπων. Συγκεκριμένα, οι τεχνικές που θα αναπτυχθούν είναι:

1. Portable emission measurement system (PEMS)
2. Plume chasing
3. Tunnel measurements
4. Remote sensing

Τα μοντέλα που θα αναπτυχθούν είναι τα ακόλουθα.

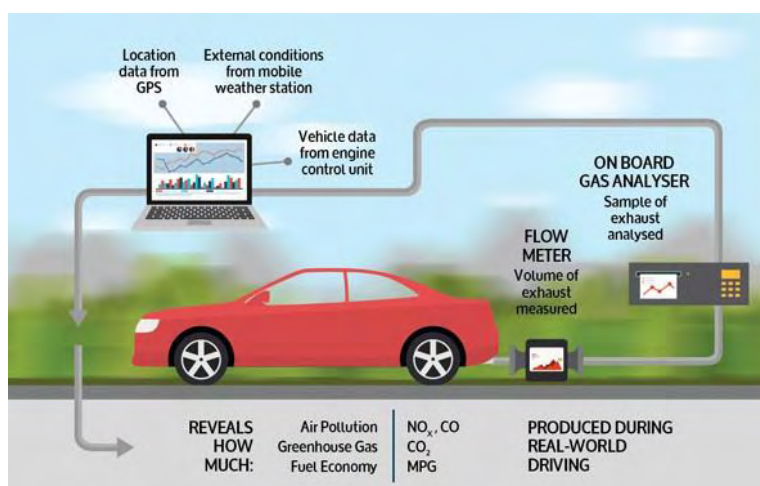
1. Μακροσκοπικά (MOBILE, EMFAC, COPERT)
2. Μικροσκοπικά (CMEC, MODEM, VERSIT+)

### 4.1 Τεχνικές μέτρησης ρύπων

Μια συνολική μέτρηση των οδικών ρύπων στα αστικά κέντρα είναι πολύ δύσκολη λόγω του μεγάλου αριθμού οχημάτων με διαφορετικά προφίλ εκπομπών, της μεγάλης χωρικής και χρονικής μεταβλητότητας στη δραστηριότητα των οχημάτων [66]. Παρόλο που οι μετρήσεις πραγματικών εκπομπών ενδέχεται να είναι λιγότερο ακριβείς από τις εργαστηριακές δοκιμές, διαδραματίζουν σημαντικό ρόλο στον έλεγχο των εκπομπών των οχημάτων. Για την μέτρηση των εκπομπών των οχημάτων σε πραγματικές συνθήκες χρησιμοποιούνται διάφοροι μέθοδοι, όπως η Portable Emission Measurement System (PEMS), η plume chasing, η tunnel measurement και η remote sensing.

#### 4.1.1 Portable Emission Measurement System (PEMS)

Το PEMS μετρά άμεσα τις εκπομπές των οχημάτων μεταφέροντας ένα σύνολο οργάνων μέτρησης εκπομπών ρύπων στο εσωτερικό του οχήματος. Σε σύγκριση με άλλες τεχνικές μέτρησης οδικής κυκλοφορίας το PEMS έχει τη μεγαλύτερη ακρίβεια. Ένα από τα βασικά πλεονεκτήματα αυτής της τεχνικής είναι ότι μπορεί να μετρήσει μια μακρά σειρά εκπομπών κάτω από ένα ευρύ φάσμα πραγματικών συνθηκών οδήγησης, συμπεριλαμβανομένων ορισμένων που θα ήταν δύσκολο να επαναληφθούν στο εργαστήριο (π.χ. μεγάλες διαδρομές και μεγάλα βαρέα οχήματα). Από την άλλη μεριά, όμως, το μεγάλο βάρος του PEMS μπορεί να αλλοιώσει τις μετρήσεις ειδικά σε ελαφρά οχήματα και να δώσει λανθασμένα αποτελέσματα. Οι μετρήσεις με αυτή τη μέθοδο είναι αρκετά δαπανηρές με απόρροια την αδυναμία χρήσης τους σε μεγάλο αριθμό οχημάτων. Παρόλα αυτά, κάποιες κυβερνητικές οργανώσεις όπως η USEPA, η Ευρωπαϊκή Ένωση και διάφορα κράτη και ιδιωτικές εταιρείες χρησιμοποιούν το PEMS για να μειώσουν τον χρόνο που απαιτείται για τη λήψη αποφάσεων σχετικά με τις εκπομπές ρύπων [67]. Στο Σχήμα 4- 1 παρουσιάζεται ο τρόπος λειτουργίας της μεθόδου PEMS και στο Σχήμα 4- 2 αναφέρονται τα πλεονεκτήματα και τα μειονεκτήματα της μεθόδου.



Σχήμα 4- 1: Τρόπος λειτουργίας της μεθόδου PEMS



Σχήμα 4- 2: Πλεονεκτήματα & μειονεκτήματα της μεθόδου PEMS

#### 4.1.2 Plume chasing

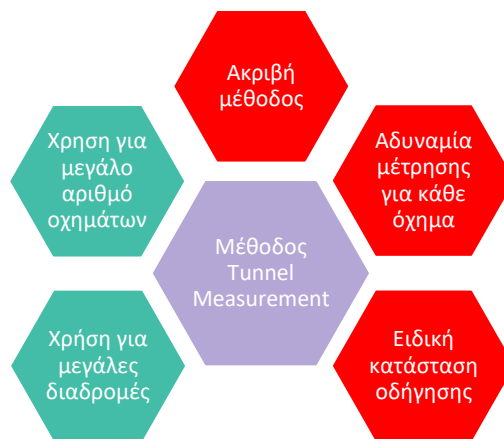
Μια παρόμοια τεχνική για τον υπολογισμό των οδικών ρύπων είναι η plume chasing, η οποία μετρά τις εκπομπές ρύπων του οχήματος-στόχου, αλλά τα όργανα μέτρησης είναι εγκατεστημένα σε ρυμουλκούμενο ή σε άλλο αυτοκίνητο που ακολουθεί το όχημα-στόχος [68]. Αυτήν η μέθοδος έχει σχεδόν τα ίδια χαρακτηριστικά με τη μέθοδο PEMS. Συγκεκριμένα, και αυτή η τεχνική μπορεί να χρησιμοποιηθεί για μεγάλες διαδρομές, που δεν είναι εύκολο να επαναληφθούν, αλλά το υψηλό κόστος δεν επιτρέπει τη χρήση της σε πολλά οχήματα. Ταυτόχρονα, αυτήν η μέθοδος για λόγους ασφαλείας έχει περιορισμό στην ταχύτητα του οχήματος καθώς και στην απόσταση μεταξύ του οχήματος-στόχο και του οχήματος που κάνει τη μέτρηση. Τα πλεονεκτήματα και μειονεκτήματα της μεθόδου Plume Chasing παρουσιάζονται στο Σχήμα 4- 3.



Σχήμα 4- 3: Πλεονεκτήματα & μειονεκτήματα της μεθόδου Plume Chasing

#### 4.1.3 Tunnel measurement


Η μέθοδος tunnel measurement μετρά τις συγκεντρώσεις ρύπων στην είσοδο και στην έξοδο της σήραγγας [69]. Οι συντελεστές εκπομπής ρύπων υπολογίζονται από τη διαφορά συγκέντρωσης, σε συνδυασμό με κάποια χαρακτηριστικά της σήραγγας, όπως το μήκος της σήραγγας, τις συνθήκες κυκλοφορίας και τον άνεμο. Αυτήν η τεχνική είναι σε θέση να υπολογίσει τις εκπομπές ρύπων μεγάλου αριθμού οχημάτων υπό σχετικά ελεγχόμενες συνθήκες, με αποτέλεσμα την επαρκή καταγραφή της μεταβλητότητας των εκπομπών στα οχήματα. Ωστόσο, δεν μπορεί να καθορίσει τις εκπομπές συγκεκριμένων κατηγοριών οχημάτων. Για την σωστή μέτρηση μέσω αυτής της μεθόδου χρειάζονται συγκεκριμένες καταστάσεις οδήγησης, όπως η σταθερή ταχύτητα του οχήματος. Κατά συνέπεια, τα αποτελέσματα των μετρήσεων δεν μπορούν να γενικευτούν και για κοινές αστικές συνθήκες οδήγησης όπου η ταχύτητα των οχημάτων είναι διαφορετική. Ο μέσος χρόνος μέτρησης είναι συνήθως μία ώρα και οι συνολικοί χρόνοι δειγματοληψίας κυμαίνονται από 10 ώρες έως ένα μήνα [70]. Το Σχήμα 4- 4 παρουσιάζει σχηματικά τα πλεονεκτήματα και μειονεκτήματα της συγκεκριμένης μεθόδου.



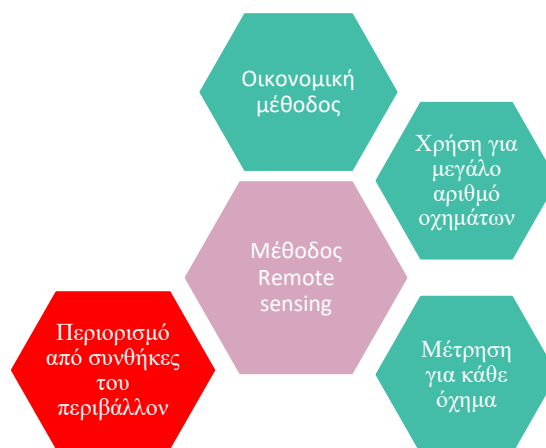
Σχήμα 4- 4: Πλεονεκτήματα & μειονεκτήματα της μεθόδου Tunnel Measurement

#### 4.1.4 Remote sensing system

Η μέθοδος remote sensing είναι ένα αποτελεσματικό και οικονομικό εργαλείο για την παρακολούθηση και τον έλεγχο των εκπομπών ρύπων των οχημάτων. Μέσω αυτής της μεθόδου δίνεται η δυνατότητα να μετρηθούν οι εκπομπές ρύπων τυπικά χιλιάδων οχημάτων καθημερινά τόσο για μεμονωμένα οχήματα όσο και για συγκεκριμένες κατηγορίες οχημάτων. Η μέθοδος remote sensing μπορεί να μετρήσει στιγμιαίες εκπομπές ρύπων χιλιάδων οχημάτων την ημέρα σε πραγματικές συνθήκες χωρίς παρεμβολές στην οδήγηση. Χαρακτηρίζεται ως η πιο οικονομική μέθοδος για την καταμέτρηση των οδικών ρύπων με βάση το κόστος ανά όχημα [67]. Οι μετρήσεις μέσω αυτής της μεθόδους μπορεί να επηρεαστούν από τις περιβαλλοντικές συνθήκες και να μην γίνουν σωστές και με ακρίβεια μετρήσεις. Ένα παράδειγμα του τρόπου λειτουργίας αυτής της μεθόδους καθώς και τα αρνητικά και θετικά αυτής παρουσιάζονται στο Σχήμα 4- 5 και Σχήμα 4- 6 αντίστοιχα.



Σχήμα 4- 5: Τρόπος λειτουργίας της μεθόδου Remote Sensing



Σχήμα 4- 6: Πλεονεκτήματα & μειονεκτήματα της μεθόδου Remote Sensing

## 4.2 Μοντέλα μέτρησης ρύπων

Καθώς οι ακριβείς εκπομπές ρύπων και η κατανάλωση καυσίμων μπορούν να μετρηθούν μόνο με επαγγελματικό εξοπλισμό εγκατεστημένο σε επιμέρους οχήματα, η μέτρηση αυτή δύσκολα μπορεί να εφαρμοστεί στην πράξη. Ως εκ τούτου, οι προσεγγίσεις εκτίμησης εκπομπών και κατανάλωσης καυσίμου έχουν αναπτυχθεί ευρέως τις τελευταίες δεκαετίες, με αποτέλεσμα την ανάπτυξη εκτεταμένων μοντέλων εκτίμησης εκπομπών ρύπων. Τα μαθηματικά μοντέλα είναι ένας τρόπος που χρησιμοποιείται για την πρόβλεψη των συγκεντρώσεων διαφόρων ρύπων. Έχουν αναπτυχθεί πολλά μοντέλα παγκοσμίως για την πρόβλεψη εκπομπών οχημάτων για διαφορετικές συνθήκες δρόμου, κατάσταση


οχημάτων και τρόπους οδήγησης [71]. Δεδομένου ότι τα μοντέλα είναι απλοποιήσεις της πραγματικότητας, οι περιορισμοί και η ακρίβειά τους πρέπει να είναι πλήρως καθορισμένα.

Σύμφωνα με την κλίμακα ακρίβειας, τα μοντέλα εκπομπών ρύπων χωρίζονται στις ακόλουθες κατηγορίες:

1. Μακροσκοπική (περιφερειακή)
2. Μικροσκοπική (διασταυρώσεις, τμήματα δρόμων)

Τα μακροσκοπικά μοντέλα χρησιμοποιούν μέσες συνολικές παραμέτρους δικτύου για την εκτίμηση των ποσοστών εκπομπών σε επίπεδο δικτύου. Από την άλλη μεριά, τα μικροσκοπικά μοντέλα υπολογίζουν στιγμιαία την κατανάλωση καυσίμου των οχημάτων και τους ρυθμούς εκπομπής ρύπων, τα οποία συγκεντρώνονται για να εκτιμηθούν τα μέτρα αποτελεσματικότητας σε όλο το δίκτυο [72]. Ταυτόχρονα, όμως, τα υφιστάμενα μοντέλα εκπομπών διακρίνονται σε μοντέλα που χρησιμοποιούν παραμέτρους οδικής κυκλοφορίας, όπως επιτάχυνση, πέδηση, συνεχής οδήγηση και ρελαντί και σε μοντέλα που βασίζονται στην παράμετρο της μέσης ταχύτητας.

Στην παρούσα εργασία θα αναφερθούν μοντέλα που ανήκουν και στις δύο κατηγορίες. Ως μακροσκοπικά μοντέλα θα αναφερθούν τα MOBILE, EMFAC και COPERT. Ως μικροσκοπικά μοντέλα θα αναφερθούν τα CMEC, MODEM και VERSIT+. Στο ακόλουθο Σχήμα 4- 7 παρουσιάζονται τα μοντέλα μέτρησης ρύπων και οι κατηγορίες που ανήκουν.



Σχήμα 4- 7: Μοντέλα μέτρησης ρύπων

#### 4.2.1 Μακροσκοπικά μοντέλα

Τα μακροσκοπικά μοντέλα βασίζονται κυρίως στην παράμετρο της μέσης ταχύτητας στα τμήματα του οδικού δικτύου [73]. Χρησιμοποιούνται για την εκτίμηση της κατανάλωσης καυσίμων και των περιβαλλοντικών επιπτώσεων από τις οδικές μεταφορές προκειμένου να προσδιοριστεί ο αντίκτυπος της συνολικής κατανάλωσης ενέργειας από τα έργα και τις στρατηγικές ανάπτυξης των οδικών υποδομών και να εκτιμηθεί ο αντίκτυπος των εκπομπών αερίων θερμοκηπίου στην ερευνητική περιοχή. Όπως αναφέρθηκε και παραπάνω, παραδείγματα τέτοιων μοντέλων είναι το MOBILE, το EMFAC και το COmputer Program to calculate Emissions from Road Traffic (COPERT).

##### 4.2.1.1 Μοντέλο MOBILE

Το μοντέλο που επιτρέπει τον υπολογισμό των εκπομπών για τα δεδομένα των ΗΠΑ είναι το MOBILE, το οποίο αναπτύχθηκε από τον Οργανισμό Προστασίας Περιβάλλοντος (EPA). Χρησιμοποιεί δεδομένα που συλλέγονται από τους EPA, κατασκευαστές αυτοκινήτων, καθώς και από δοκιμές επιθεώρησης της κυκλοφορίας, που συλλέγονται σε διάφορες πολιτείες. Η εκπομπή για συγκεκριμένες κατηγορίες οχημάτων είναι προϊόν του όγκου κυκλοφορίας και των συντελεστών εκπομπών [71]. Η μεθοδολογία που χρησιμοποιείται για τον υπολογισμό των εκπομπών λαμβάνει υπόψη διάφορους παράγοντες που βαθμονομούν το μοντέλο, όπως το περιβάλλον, τα χρησιμοποιούμενα οχήματα και την κατάσταση λειτουργίας τους. Το συγκεκριμένο μοντέλο υπολογίζει τρεις ρύπους: υδρογονάνθρακες (HC), μονοξείδιο του άνθρακα (CO) και οξείδια του αζώτου (NO<sub>x</sub>). Το συγκεκριμένο ποσοστό εκπομπών που υπολογίζεται από το μοντέλο πολλαπλασιάζεται με κάποιες δραστηριότητες του οχήματος και προκύπτει το τελικό ποσοστό ρύπων.

Το μοντέλο MOBILE έχει αρκετά μειονεκτήματα. Για την εκτίμηση των εκπομπών ρύπων χρησιμοποιείται ένα περιορισμένο σύνολο κύκλων οδήγησης, οι οποίοι δεν αντιπροσωπεύουν επαρκώς συγκεκριμένες συνθήκες κυκλοφοριακής ροής. Ένα άλλο πρόβλημα με τις εκτιμήσεις των εκπομπών είναι ότι το μοντέλο προβλέπει ποσοστά εκπομπών με βάση τις μεταβολές της μέσης ταχύτητας μεταξύ των χαρακτηριστικών ροής κυκλοφορίας. Οι μέσες ταχύτητες ταξιδιού, όμως, δεν ισοδυναμούν με τις ταχύτητες που αφορούν συγκεκριμένα τμήματα ταξιδιών του οχήματος.



#### 4.2.1.2 Μοντέλο EMFAC

Ένα ακόμα κύριο μοντέλο εκπομπών ρύπων που χρησιμοποιείται στις ΗΠΑ, και συγκεκριμένα στην Καλιφόρνια, είναι το EMFAC της California Air Resources Board (CARB). Τα ποσοστά ρύπων υπολογίζονται βάσει του τύπου οχήματος, της μέσης ταχύτητας του οχήματος, της θερμοκρασίας του περιβάλλοντος και του τρόπου λειτουργίας του οχήματος [71]. Όπως και το μοντέλο MOBILE, το EMFAC υπολογίζει συγκεκριμένο ποσοστό εκπομπών, το οποίο πολλαπλασιάζεται με δραστηριότητες του οχήματος, παραδείγματος χάριν τον αριθμό των ταξιδιών, με στόχο τον υπολογισμό των συνολικών ρύπων. Οι εκτιμήσεις εκπομπών ρύπων των οχημάτων που παράγονται από το μοντέλο EMFAC χρησιμοποιούν ως μέση τιμή τις μέσες ταχύτητες ταξιδιού για να επιλέξουν συγκεκριμένους παράγοντες εκπομπής ταξιδιού που υπολογίζονται με τη δοκιμή οχημάτων μέσω περιορισμένου αριθμού κύκλων οδήγησης [72].

Το συγκεκριμένο μοντέλο παρουσιάζει τα ίδια μειονεκτήματα με το μοντέλο MOBILE. Ένα μειονέκτημα του μοντέλου EMFAC είναι η χρήση ενός περιορισμένου αριθμού κύκλων οδήγησης για την εκτίμηση των ποσοστών εκπομπών ρύπων. Η χρήση της μέσης ταχύτητας ενός οχήματος δεν μπορεί να αντιπροσωπεύει την κατανομή των ταχυτήτων και επιταχύνσεων ενός ταξιδιού, οι οποίες ποικίλλουν ανάλογα με τον τύπο του δρόμου και το επίπεδο συμφόρησης [74].

#### 4.2.1.3 Μοντέλο COPERT

Ένα ακόμα χαρακτηριστικό παράδειγμα μακροσκοπικού μοντέλου μέτρησης ρύπων είναι το πρόγραμμα COPERT, το οποίο είναι ένα εργαλείο λογισμικού που χρησιμοποιείται παγκοσμίως για τον υπολογισμό των εκπομπών ρύπων και αερίων θερμοκηπίου που παράγονται από τις οδικές μεταφορές και η επιστημονική του ανάπτυξη διευθύνεται από την Ευρωπαϊκή Επιτροπή. Το μοντέλο εφαρμόζεται κυρίως σε εκτιμήσεις εκπομπών μέσης και μεγάλης κλίμακας με τη χρήση μέσων συντελεστών εκπομπών που εξαρτώνται από την ταχύτητα [71]. Αυτός ο τύπος μοντέλου δεν είναι ευαίσθητος στις μεταβολές των τρόπων λειτουργίας των οχημάτων, καθώς εξαρτάται κυρίως από τη μέση ταχύτητα χωρίς να λαμβάνεται υπόψη η επιρροή της επιτάχυνσης και της επιβράδυνσης [75]. Για αυτό το λόγο, τέτοια μοντέλα δεν εφαρμόζονται σε περιπτώσεις που συναντώνται μεταβολές των τρόπων λειτουργίας. Μια αυστραλιανή έκδοση του COPERT αναπτύχθηκε ώστε να αντικατοπτρίζει τη

σύνθεση των τοπικών χαρακτηριστικών οδήγησης και να παρέχει εκτιμήσεις εκπομπών οχημάτων για την κατάσταση της Αυστραλίας

#### **4.2.2 Μικροσκοπικά μοντέλα**

Τα μικροσκοπικά μοντέλα υπολογισμού εκπομπών απαιτούν πολλά δεδομένα που βασίζονται στη συνεχή μέτρηση των βασικών παραμέτρων του οχήματος, όπως η ταχύτητα, η επιτάχυνση, η κλίση του εδάφους και οι συντεταγμένες θέσης. Υπολογίζουν συνεχώς τις εκπομπές σε μια συγκεκριμένη μονάδα χρόνου, συνήθως 1 δευτερόλεπτο [76]. Αυτά τα μοντέλα είναι ευαίσθητα στις μεταβολές της επιτάχυνσης του οχήματος και μπορούν έτσι να χρησιμοποιηθούν για την αξιολόγηση έργων μεταφοράς σε επιχειρησιακό επίπεδο, όπως μοντελοποίηση σταθμών διοδίων και μοντελοποίηση τμημάτων αυτοκινητοδρόμων [72]. Στην παρούσα εργασία θα αναφερθούν τα μοντέλα Comprehensive Modal Emissions Model (CMEM), MODelling of Emissions and consumption in urban area (MODEM) και το VERSIT +.

##### **4.2.2.1 Μοντέλο CMEM**

Ένα παράδειγμα μοντέλου που βασίζεται στην ισχύ του οχήματος είναι το CMEM, το οποίο αναπτύχθηκε από ερευνητές του Πανεπιστημίου Riverside της Καλιφόρνιας. Το μοντέλο CMEM υπολογίζει τις εκπομπές LDV ως συνάρτηση του τρόπου λειτουργίας του οχήματος. Το μοντέλο έχει την ικανότητα να προβλέπει εκπομπές ρύπων για διάφορες καταστάσεις λειτουργίας, όπως σωστή λειτουργία και δυσλειτουργία. Το CMEM προβλέπει εκπομπές καυσαερίων ανά δευτερόλεπτο και κατανάλωση καυσίμου για ένα ευρύ φάσμα κατηγοριών οχημάτων / τεχνολογίας [77]. Το μοντέλο αποτελείται από έξι μονάδες που προβλέπουν την ισχύ του κινητήρα, την ταχύτητα του κινητήρα, την αναλογία αέρα προς καύσιμο, τη χρήση καυσίμου, τις εκπομπές από την μηχανή και το κλάσμα περατώσεως του καταλύτη. Οι μεταβλητές οχήματος και λειτουργίας (π.χ. ταχύτητα, επιτάχυνση και οδός) και οι βαθμονομημένες παράμετροι μοντέλου (π.χ. συντελεστές κρύας εκκίνησης και συντελεστής τριβής κινητήρα) εισάγονται στο μοντέλο για την σωστή πρόβλεψη των εκπομπών ρύπων [77].

##### **4.2.2.2 Μοντέλο MODEM**

Το μοντέλο MODEM είναι ένα ακόμα μικροσκοπικό μοντέλο υπολογισμού των εκπομπών ρύπων των οχημάτων. Η ανάπτυξη αυτού του μοντέλου βασίστηκε στην

χρησιμοποίηση της ταχύτητας και της επιτάχυνσης του οχήματος [71]. Τα δεδομένα για τις εκπομπές και την κατανάλωση καυσίμου ταξινομήθηκαν σε διαφορετικές κατηγορίες προϊόντων επιτάχυνσης-ταχύτητας και ταχύτητας. Οι στιγμιαίες εκπομπές υπολογίζονται στη συνέχεια επιλέγοντας τιμές από τους αντίστοιχους συνδυασμούς προϊόντων επιτάχυνσης-ταχύτητας και ταχύτητας. Αυτές οι προσεγγίσεις μοντελοποίησης είναι ιδιαίτερα δύσκολες και απαιτούν χρόνο και εργατικό δυναμικό για τη συλλογή των δεδομένων.

#### 4.2.2.3 Μοντέλο VERSIT+

Το μοντέλο εκπομπών VERSIT +, το οποίο χρησιμοποιείται στο πρόγραμμα Enriver, είναι ένα πολυπαραγοντικό μοντέλο παλινδρόμησης στο οποίο ο κύκλος οδήγησης ενός συγκεκριμένου οχήματος είναι μεταβλητός. Αυτό απαιτεί νωρίτερα την απόκτηση προφίλ ταχύτητας στο πρόγραμμα Vissim και την μεταγενέστερη χρήση του για την εκτίμηση των συντελεστών εκπομπών (g / km) για διαφορετικές κατηγορίες οχημάτων [78]. Τα προφίλ ταχύτητας που χρησιμοποιούνται σε αυτό το μοντέλο είναι αντιπροσωπευτικά των πραγματικών οδικών συνθηκών [79].

### **4.3 Συμπεράσματα**

Συμπερασματικά, η μέθοδος remote sensing συνδυάζει τα πλεονεκτήματα των προαναφερθέντων τεχνικών και για αυτό το λόγο είναι ιδανικό εργαλείο για διάφορες επιπρόσθετες εφαρμογές, όπως ο εντοπισμός των οχημάτων υψηλής εκπομπής ρύπων για επιθεώρηση και συντήρηση. Στον ακόλουθο Πίνακας 2 παρουσιάζονται συγκεντρωτικά τα πλεονεκτήματα και μειονεκτήματα κάθε μεθόδου για την καταμέτρηση των οχημάτων σε πραγματικές συνθήκες.

Μέθοδος	Πλεονεκτήματα	Μειονεκτήματα
<b>PEMS</b>	Μεγάλη ακρίβεια Χρήση για μεγάλες διαδρομές Μέτρηση για κάθε όχημα	Ακριβή Μεγάλο βάρος που μπορεί να επηρεάσει τις μετρήσεις Χρήση σε μικρό αριθμό οχημάτων
<b>Plume chasing</b>	Χρήση για μεγάλες διαδρομές Μέτρηση για κάθε όχημα	Ακριβή Περιορισμένη ταχύτητα οχήματος Απόσταση ασφαλείας
<b>Tunnel measurement</b>	Υπολογισμός ρύπων για μεγάλο αριθμό οχημάτων Χρήση για μεγάλες διαδρομές	Αδυναμία καθορισμού εκπομπών συγκεκριμένου οχήματος Ακριβή μέθοδος Ειδική κατάσταση οδήγησης
<b>Remote sensing</b>	Οικονομική μέθοδος Υπολογισμός ρύπων για μεγάλο αριθμό οχημάτων Μετρήσεις για κάθε όχημα	Περιορισμούς από περιβαλλοντικές συνθήκες

Πίνακας 2: Συγκεντρωτικός πίνακας μεθόδων καταμέτρησης οχημάτων

Καθώς η μέτρηση των ρύπων σε πραγματικές συνθήκες είναι μια δύσκολη διαδικασία αναπτύχθηκαν τα μοντέλα εκτίμησης εκπομπών ρύπων. Τα μακροσκοπικά μοντέλα χρησιμοποιούν για τον υπολογισμό των ρύπων κατά κύριο λόγο τη μέση ταχύτητα του οχήματος και η μεταβολή της επιτάχυνσης δε διαδραματίζει σημαντικό ρόλο στο μοντέλο. Από την άλλη μεριά, τα μικροσκοπικά μοντέλα παρουσιάζουν μεγάλη ευαισθησία στις μεταβολές της επιτάχυνσης του οχήματος και πραγματοποιούν στιγμιαίο υπολογισμό των εκπομπών ρύπων του οχήματος. Στο Σχήμα 4- 8 που ακολουθεί παρουσιάζονται τα χαρακτηριστικά των μοντέλων μέτρησης ρύπων.



Σχήμα 4- 8: Χαρακτηριστικά των Μακροσκοπικών και Μικροσκοπικών Μοντέλων

## Κεφάλαιο 5. ΜΕΘΟΔΟΛΟΓΙΑ

---

Στο κεφάλαιο αυτό παρουσιάζεται η μεθοδολογία η οποία αναπτύχθηκε με στόχο την δημιουργία του υπολογιστικού μοντέλου μάθησης σε βάθος υπολογισμού ρύπων οχημάτων CTEC (Car Truck Emissions Computation). Συγκεκριμένα, γίνεται εκτεταμένη αναφορά στην γλώσσα προγραμματισμού, στα εργαλεία και στα γραφικά περιβάλλοντα χρήστη που χρησιμοποιήθηκαν. Ακόμη, αναφέρονται αναλυτικά όλες οι βιβλιοθήκες που εγκαταστάθηκαν και ο λόγος χρήσης τους. Παρουσιάζονται και αναλύονται οι τεχνικές που χρησιμοποιήθηκαν για την δημιουργία του συνόλου δεδομένων, καθώς και, το μέγεθος, το είδος και ο τύπος του σετ δεδομένων. Τέλος, παρουσιάζεται ο αλγόριθμος μάθησης σε βάθος που χρησιμοποιήθηκε, για την εκπαίδευση, επαλήθευση και δοκιμή του μοντέλου CTEC.

### 5.1 Γλώσσα προγραμματισμού

Το υπολογιστικό μοντέλο CTEC αναπτύχθηκε με την χρήση της γλώσσας προγραμματισμού Python. Οι λόγοι για τον οποίο χρησιμοποιήθηκε η Python είναι, ότι αποτελεί μια γλώσσα προγραμματισμού υψηλού επιπέδου ανοικτού κώδικα, η οποία παρέχει στον χρήστη αναγνωσιμότητα του κώδικα και κυρίως ευκολία στην χρήση της. Διακρίνεται ακόμη για τον μεγάλο αριθμό βιβλιοθηκών της οι οποίες διευκολύνουν ιδιαίτερα τον χρήστη, όπως μαθηματικά μοντέλα, αλγορίθμους μάθησης σε βάθος, και είναι πολύ εύκολες στην διασύνδεση τους με γραφικά περιβάλλοντα χρήστη και εργαλεία.

### 5.2 Εργαλεία για την ανάπτυξη του μοντέλου

Το υπολογιστικό μοντέλο CTEC, το οποίο αναγνωρίζει αυτοκίνητα και φορτηγά και υπολογίζει τους ρύπους τους, δημιουργήθηκε με την χρήση των εργαλείων Anaconda Cloud: Python, CUDA (Compute Unified Device Architecture) Toolkit και LablelImg. Ο κύριος λόγος χρήσης αυτών των εργαλείων είναι ότι το μοντέλο μπορεί μέσω αυτών των εργαλείων να δημιουργηθεί σε ποικίλα εικονικά περιβάλλοντα και με την δυνατότητα χρήσης παράλληλου προγραμματισμού μέσω της υπολογιστικής ισχύς της κάρτας γραφικών. Η παραπάνω διαδικασία δίνει το πλεονέκτημα στον χρήστη να χρησιμοποιεί μεγάλες σε όγκο βάσεις δεδομένων και πολύπλοκους αλγορίθμους μάθησης σε βάθος, χωρίς να χρειάζεται να εγκαθιστά και να επανεγκαθιστά διάφορες εκδόσεις βιβλιοθηκών, προσφέροντας εκπαίδευση, επαλήθευση και δοκιμή του μοντέλου σε πολύ μικρό χρονικό διάστημα, χωρίς

να υπάρχει η ανάγκη αγοράς υπέρογκων υπολογιστικών συστημάτων με υψηλό κόστος και χαμηλότερη υπολογιστική ισχύ.

Το εργαλείο Anaconda Cloud: Python αποτελεί εργαλείο ανοιχτού κώδικα το οποίο επιτρέπει στον χρήστη την δημιουργία και την διαχείριση εικονικών περιβαλλόντων και την ευκολία εγκατάστασης πακέτων σε αυτά. Χρησιμοποιείται ευρέως από το πεδίο της επιστήμης της πληροφορικής, για την ανάπτυξη μοντέλων μηχανικής μάθησης και μάθησης σε βάθος, καθώς και για την ανάλυση και την επεξεργασία μεγάλων βάσεων δεδομένων.

Η CUDA είναι μια παράλληλη πλατφόρμα υπολογισμών και μοντέλο διεπαφής προγραμματισμού εφαρμογών (API) που δημιουργήθηκε από την εταιρία Nvidia. Επιτρέπει στους προγραμματιστές να χρησιμοποιούν την επεξεργαστική ισχύ των πυρήνων της κάρτας γραφικών, για γενική και εξειδικευμένη επεξεργασία. Πλέον χρόνο με τον χρόνο το εργαλείο CUDA χρησιμοποιείται όλο και πιο συχνά για την δημιουργία μοντέλων μηχανικής μάθησης και μάθησης σε βάθος, τα οποία στηρίζονται σε δύσκολες αρχιτεκτονικές και μεγάλα σε όγκο σύνολα δεδομένων. Για παράδειγμα, γίνεται η χρήση της CUDA, για την δημιουργία μοντέλων μάθησης σε βάθος τα οποία μπορούν να ανιχνεύουν οντότητες και αντικείμενα μέσω εικόνων, βίντεο και βίντεο σε πραγματικό χρόνο. Για την ανάπτυξη αυτών των μοντέλων εφαρμόζονται οι αρχιτεκτονικές μάθησης σε βάθος όπως, CNNs (Convolutional Neural Networks) και RNNs (Recurrent Neural Networks), οι οποίες αναλόγως το σύνολο δεδομένων που θα χρησιμοποιηθούν, μπορεί να χρειαστούν υψηλών επιδόσεων υπολογιστικά συστήματα, για την εκπαίδευση, την επαλήθευση και την δοκιμή νέων μοντέλων. Έτσι αντί, να χρησιμοποιούνται κλασικοί, υψηλών επιδόσεων υπολογιστές με πολύ-πύρινους επεξεργαστές και υπέρογκο κόστος, μπορούν να χρησιμοποιηθούν μεσαίων επιδόσεων υπολογιστές, με υψηλών επιδόσεων κάρτες γραφικών και με κατά πολύ μειωμένο κόστος και μεγαλύτερη επεξεργαστική ισχύ.

Το εργαλείο Labellmg είναι ένα εργαλείο γραφικού χαρακτηρισμού εικόνας και ετικέτας, το οποίο δίνει την δυνατότητα στον χρήστη να μπορεί να οριοθετεί σχήματα-κουτιά στις εικόνες που θα χρησιμοποιηθούν σαν σύνολο δεδομένων. Με αυτό τον τρόπο το μοντέλο μπορεί να αντιληφθεί το ακριβές μέγεθος ενός αντικειμένου ή οντότητας, με βάση του οποίου θα γίνει η εκπαίδευση, επαλήθευση και δοκιμή του μοντέλου.

### 5.3 Γραφικά περιβάλλοντα χρήστη

Για την ανάπτυξη του μοντέλου CTEC χρησιμοποιήθηκαν τα περιβάλλοντα γραφικών χρήστη, Visual Studio Code και Spyder. Το Visual Studio Code είναι ένα ανοικτού κώδικα γραφικό περιβάλλον επεξεργασίας πηγαίου κώδικα, το οποίο δίνει την δυνατότητα στον χρήστη να αναπτύξει κώδικα σε ποικίλες γλώσσες προγραμματισμού με την δυνατότητα της εύκολης ενσωμάτωσης ποικίλων βιβλιοθηκών και πρόσθετων υπηρεσιών. Ακολούθως το Spyder είναι και αυτό ένα ανοικτού κώδικα περιβάλλον επεξεργασίας κώδικα αλλά αποκλειστικά για την γλώσσα προγραμματισμού Python. Το περιβάλλον Spyder δίνει την δυνατότητα στον χρήστη να εκτελεί γραμμή-γραμμή των πηγαίο κώδικα που έχει δημιουργήσει, εμφανίζοντας ταυτόχρονα τα αποτελέσματα για κάθε βήμα εκτέλεσης του. Έτσι ο χρήστης μπορεί να βλέπει αν το κάθε βήμα κώδικα που έχει αναπτύξει δουλεύει ή όχι και να εκτυπώνει μεμονωμένα διαγράμματα ή τμήματα κώδικα, χωρίς να χρειάζεται να επανεκτελέσει όλο τον κώδικα από την αρχή.

### 5.4 Βιβλιοθήκες

Όπως είδαμε στα προαναφερθέντα για την δημιουργία του υπολογιστικού μοντέλου μάθησης σε βάθος αναγνώρισης αυτοκινήτων και φορτηγών CTEC, χρησιμοποιήθηκαν η γλώσσα προγραμματισμού Python, τα εργαλεία Anaconda Cloud: Python, CUDA και Labelling, καθώς και τα περιβάλλοντα επεξεργασίας πηγαίου κώδικα που χρησιμοποιήθηκαν για την ανάπτυξη του μοντέλου. Όλα τα παραπάνω δίνουν την δυνατότητα στο μοντέλο να εκπαιδεύεται, να επαληθεύεται και να δοκιμάζεται μέσω της υπολογιστικής ισχύς της κάρτας γραφικών, πράγμα που επιτρέπει με εξοικονόμηση χρημάτων και ταχύτητα επεξεργασίας στον χρήστη. Σε αυτό το υπό-κεφάλαιο αναφέρονται οι πιο σημαντικές βιβλιοθήκες που χρησιμοποιήθηκαν για την τελική δημιουργία του μοντέλου.

Για την δημιουργία του μοντέλου χρησιμοποιήθηκαν ποικίλες βιβλιοθήκες για την γλώσσα προγραμματισμού Python, από αυτές κάποιες είναι μαθηματικές, άλλες χρησιμοποιούνται για την απεικόνιση διαγραμμάτων και οι πιο σημαντικές είναι βιβλιοθήκες για την δημιουργία μοντέλων μηχανικής μάθησης-μάθησης σε βάθος, καθώς και βιβλιοθήκες μηχανικής όρασης.

Αναλυτικότερα, οι πιο σημαντικές βιβλιοθήκες για την δημιουργία του τελικού μοντέλου CTEC είναι η βιβλιοθήκη Protobuf, η οποία χρησιμοποιείται για την δημιουργία και την μετατροπή της βάσης δεδομένων που θα χρησιμοποιηθεί, για την εκπαίδευση, την



επαλήθευση και την δοκιμή του μοντέλου. Έπειτα χρησιμοποιήθηκε η μαθηματική βιβλιοθήκη Matplotlib, η οποία χρησιμοποιείται για την ευκολία εισαγωγής και επεξεργασίας σύνθετων μαθηματικών πράξεων, καθώς και για την επεξεργασία και την απεικόνιση ποικίλων σύνθετων και μη διαγραμμάτων. Ακόμη, χρησιμοποιήθηκε η βιβλιοθήκη cuDNN, η οποία παρέχει την δυνατότητα στον χρήστη να δημιουργήσει το μοντέλο μέσω των πυρήνων της κάρτας γραφικών σε συνδυασμό με το εργαλείο CUDA.

Η πιο σημαντική από όλες τις βιβλιοθήκες είναι η βιβλιοθήκη ανοικτού κώδικα μηχανικής μάθησης Tensorflow. Η βιβλιοθήκη αυτή παρέχει μεθόδους μηχανικής μάθησης-μάθησης σε βάθος αιχμής επιτρέποντας στον χρήστη να μπορεί να δημιουργήσει τα δικά του μοντέλα μηχανικής μάθησης σε ένα φιλικό, με πολλά πακέτα και πρόσθετα καθώς και κέντρα οδηγίων περιβάλλον. Στην συγκεκριμένη διπλωματική χρησιμοποιήθηκε η βιβλιοθήκη Tensorflow Gru η οποία δίνει την δυνατότητα μαζί με την βιβλιοθήκη cuDNN και το εργαλείο CUDA στον χρήστη να μπορεί να εκπαιδεύσει και να δοκιμάσει τα μοντέλα που έχει αναπτύξει μέσω της υπολογιστικής ισχύς των πυρήνων της κάρτας γραφικών. Τέλος, χρησιμοποιήθηκε η βιβλιοθήκη ανοικτού κώδικα μηχανικής όρασης OpenCV. Συγκεκριμένα η βιβλιοθήκη αυτή επιτρέπει την οπτική απεικόνιση των αναγνωρισμένων οντοτήτων και αντικειμένων μέσω ζωντανής εικόνας, βίντεο και φωτογραφίας, στα δημιουργηθέντα μοντέλα μηχανικής μάθησης οπτικής αναγνώρισης. Το μοντέλο CTEC αφού εκπαιδεύτηκε και δοκιμάστηκε μέσω της βιβλιοθήκης Tensorflow Gru, έπειτα συνδυάστηκε με την βιβλιοθήκη OpenCV, ώστε να μπορεί το μοντέλο να απεικονίσει, να μετρήσει και να καταγράψει τα αναγνωρισμένα αυτοκίνητα και φορτηγά, είτε μέσω της ανάγνωσης μιας φωτογραφίας ή βίντεο είτε μέσω ενός βίντεο σε πραγματικό χρόνο.

## **5.5 Βάση δεδομένων**

Στόχος της συγκεκριμένης διατριβής ήταν η ανάπτυξη ενός ισχυρού υπολογιστικού μοντέλου, βασισμένο σε αλγορίθμους αιχμής, μάθηση σε βάθος, ικανό να διακρίνει τα αυτοκίνητα από τα φορτηγά μέχρι 14 τόνους και να τα καταμετρήσει, με τελικό στόχο τον υπολογισμό των ρύπων τους. Προκειμένου να δημιουργηθεί ένα ισχυρό μοντέλο πρόβλεψης των ρύπων, απαιτούνται υψηλής ποιότητας φωτογραφίες απεικόνισης αυτοκινήτων και φορτηγών. Έτσι, δημιουργήθηκε και χρησιμοποιήθηκε ένα σύνολο δεδομένων έγχρωμων φωτογραφιών από αυτοκίνητα και φορτηγά.

Συνολικά, η βάση δεδομένων που χρησιμοποιήθηκε για την δημιουργία του μοντέλου, αποτελείται από 1.200 έγχρωμες φωτογραφίες υψηλής ανάλυσης 800x600 pixels τύπου jpeg, από τις οποίες οι 600 απεικονίζουν αυτοκίνητα και οι υπόλοιπες 600 φορτηγά. Συγκεκριμένα, το σετ φωτογραφιών αυτοκινήτων αποτελείται αντίστοιχα από 200 φωτογραφίες απεικόνισης αυτοκινήτων από την μπροστινή πλευρά τους, 200 φωτογραφίες απεικόνισης αυτοκινήτων από τα πλάγια και 200 φωτογραφίες απεικόνισης αυτοκινήτων από την πίσω πλευρά τους, σύνολο 600 έγχρωμες φωτογραφίες. Αντίστοιχα το σετ φωτογραφιών για τα φορτηγά χωρίζεται με τον ίδιο τρόπο.

Για την δημιουργία του μοντέλου CTEC, όπως αναφέρθηκε χρησιμοποιήθηκε ένα σύνολο δεδομένων από 1.200 έγχρωμες φωτογραφίες, οι οποίες αφού πρώτα μετατράπηκε η ανάλυσή τους σε 240x240 pixels έπειτα το σύνολο χωρίστηκε το 80% για την εκπαίδευση και την επικύρωση του μοντέλου και το υπόλοιπο 20% για την δοκιμή. Το σύνολο δεδομένων εκπαίδευσης αποτελείται από 480 έγχρωμες φωτογραφίες αυτοκινήτων και 480 έγχρωμες φωτογραφίες φορτηγών, σύνολο 960 έγχρωμες φωτογραφίες. Το σύνολο δεδομένων δοκιμής αποτελείται συνολικά από 240 έγχρωμες φωτογραφίες, 120 έγχρωμες φωτογραφίες αυτοκινήτων και 120 έγχρωμες φωτογραφίες φορτηγών. Τόσο το σύνολο δεδομένων εκπαίδευσης όσο και το σύνολο δεδομένων δοκιμής δημιουργήθηκε ύστερα από αναζήτηση φωτογραφιών που απεικονίζονται αυτοκίνητα ή φορτηγά, μέσω των φυλλομετρητών Google και Duck Duck Go και τις ιστοσελίδες Car.gr και Mobile.de.

Για την δημιουργία της βάσης δεδομένων χρησιμοποιήθηκε το εργαλείο Labellmg. Όπως αναφέρθηκε στην παράγραφο 5.2, το εργαλείο Labellmg δίνει την δυνατότητα στον χρήστη να μαρκάρει ακριβώς την περιοχή στην οποία απεικονίζεται σε μια φωτογραφία το αντικείμενο που θέλει το μοντέλο να εκπαιδευτεί και να αναγνωρίσει. Έτσι και για το σύνολο εκπαίδευσης 960 έγχρωμες φωτογραφίες και για το σύνολο δοκιμής 240 έγχρωμες φωτογραφίες, χρησιμοποιήθηκε το εργαλείο Labellmg, ώστε να δοθεί το ακριβές σημείο απεικόνισης των αυτοκινήτων και των φορτηγών. Με αυτή την τεχνική δίνεται η δυνατότητα στο μοντέλο να αναγνωρίσει με μεγαλύτερη ακρίβεια και ταχύτητα το σχήμα, το χρώμα και την κατεύθυνση των αυτοκινήτων και φορτηγών. Τα πλέον τροποποιημένα σύνολα εκπαίδευσης και δοκιμής, 960 και 240 έγχρωμες φωτογραφίες, δόθηκαν για την εκπαίδευση και την δοκιμή του μοντέλου CTEC. Παρακάτω στο Σχήμα 5- 1 και στο Σχήμα 5- 2 παρουσιάζονται παραδείγματα από τις φωτογραφίες για τις δύο κατηγορίες οχημάτων που χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου.



Σχήμα 5- 1: Παράδειγμα φωτογραφιών αυτοκινήτων που χρησιμοποιήθηκαν στο μοντέλο



Σχήμα 5- 2: Παράδειγμα φωτογραφιών φορτηγών που χρησιμοποιήθηκαν στο μοντέλο

## 5.6 Περιγραφή του αλγορίθμου

Στόχος του μοντέλου CTEC είναι να προχωρήσει πέρα από την τελευταία λέξη της τεχνολογίας όσο αφορά το επιστημονικό ερευνητικό θέμα της αναγνώρισης των ρύπων οχημάτων, χωρίς την ανάγκη χρήσης σύνθετων, χρονοβόρων στην εγκατάσταση και πολυδάπανων αισθητήρων, αλλά με την χρήση των ήδη υπάρχουσών καμερών παρακολούθησης οδικής κυκλοφορίας.

Για να υλοποιηθεί το υπολογιστικό μοντέλο ρύπων CTEC, αρχικά δημιουργήθηκε, εκπαιδεύτηκε, επαληθεύτηκε και δοκιμάστηκε ένα μοντέλο αναγνώρισης αυτοκινήτων και φορτηγών βασιζόμενο σε υπερσύγχρονες αρχιτεκτονικές μηχανικής μάθησης σε βάθος. Έπειτα αναπτύχθηκε ένα υπό πρόγραμμα το οποίο κάνει καταμέτρηση τα αυτοκίνητα και τα φορτηγά, τα οποία αναγνωρίζονται από το μοντέλο CTEC και ένα δεύτερο υπό πρόγραμμα που συγκεντρώνει τα συνολικά καταγεγραμμένα αυτοκίνητα και φορτηγά και αποδίδει τους ρύπους για τις δύο κατηγορίες σε δύο τελικά αρχεία. Ένα αρχείο που καταγράφει τους ρύπους για τα αυτοκίνητα και ένα για τα φορτηγά. Παρακάτω παρουσιάζεται το υπολογιστικό μοντέλο ρύπων CTEC βήμα-βήμα.

Αξίζει να σημειθούν τα χαρακτηριστικά του υπολογιστικού μηχανήματος και το λογισμικό το οποίο χρησιμοποιήθηκε για την δημιουργία του μοντέλου CTEC.

Το υπολογιστικό σύστημα στο οποίο δημιουργήθηκε το μοντέλο CTEC, είχε επεξεργαστή Intel Core i7-7740X CPU 4.30GHz, μνήμη RAM 16GB, δίσκο SSD 1TB με ταχύτητα

εγγραφής 520 MB/s και ανάγνωσης 550 MB/s και κάρτα γραφικών GeForce GTX 1080 Ti, η οποία έχει μνήμη 11GB, επεξεργαστή 1,5GHz και 3584 πυρήνες.

### **5.6.1 Αναγνώριση και Ταξινόμηση αυτοκινήτων και φορτηγών**

Για την δημιουργία του μοντέλου CTEC χρησιμοποιήθηκε ο αλγόριθμος αιχμής μάθησης σε βάθος Συναινετικά Νευρωνικά Δίκτυα (ΣΝΔ), ο οποίος είναι ένας από τους πιο σύγχρονους και κατάλληλους αλγορίθμους για την δημιουργία μοντέλων αναγνώρισης και ταξινόμησης εικόνων.

Πιο αναλυτικά, ο αλγόριθμος μπορεί να πάρει σαν είσοδο μια εικόνα και είναι σε θέση να καταγράψει με επιτυχία τις χωρικές και προσωρινές εξαρτήσεις της εικόνας μέσω της χρήσης σχετικών φίλτρων. Ο αλγόριθμος αυτός έχει καλύτερη προσαρμογή σε ένα σύνολο δεδομένων από εικόνες λόγω της μείωσης των αριθμών των παραμέτρων που εμπλέκονται και της επαναχρησιμοποίησης τους. Δηλαδή, το νευρωνικό δίκτυο έχει την δυνατότητα να εκπαιδευτεί ώστε να μπορεί να καταλάβει σε βάθος μια πιο περίπλοκη εικόνα. Αυτό επιτυγχάνεται με την μείωση της εικόνας σε μια μορφή που είναι ευκολότερη να επεξεργαστεί από τον υπολογιστή, χωρίς όμως να χαθούν τα χαρακτηριστικά τα οποία είναι σημαντικά για την επίτευξη μιας καλής πρόβλεψης, πράγμα σημαντικό όταν δημιουργείται ένα μοντέλο το οποίο πρέπει να μαθαίνει με ακρίβεια χαρακτηριστικά για μεγάλα σύνολα βάσεων δεδομένων.

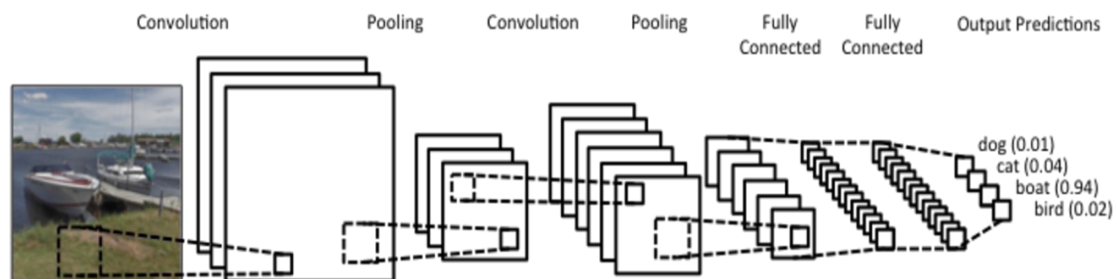
Η αρχιτεκτονική των συναινετικών νευρωνικών δικτύων αποτελείται από το συναινετικό επίπεδο (convolution) ή πυρήνα, το συγκεντρωτικό επίπεδο (pooling) και το άρρηκτα συνδεδεμένο επίπεδο (full connected).

Το συναινετικό επίπεδο (convolution) επιλέγει μια περιοχή από την εικόνα, την σαρώνει και δημιουργεί τιμές σε πίνακες με βάση τα χαρακτηριστικά της εικόνας που πήρε σαν είσοδο. Αυτές οι τιμές χρησιμοποιούνται για την εκμάθηση της πληροφορίας της εικόνας σε βάθος. Έτσι, στόχος του συναινετικού επιπέδου είναι η εξαγωγή χαρακτηριστικών υψηλού επιπέδου από την εικόνα, λεπτομέρειες όπως οι άκρες μιας εικόνας και γεωμετρικά σχήματα, αλλά και η εξαγωγή χαμηλού επιπέδου χαρακτηριστικών όπως, χρώμα, κατεύθυνση και κλίση, δίνοντας στο μοντέλο μια πλήρη περιγραφή και κατανόηση της εικόνας, παρόμοια με τον ανθρώπινο εγκέφαλο.

Το επίπεδο συγκέντρωσης (pooling) αποτελείται από δύο είδη, τη μέγιστη και μέσου όρου συγκέντρωση. Στόχος αυτού του επιπέδου είναι η μείωση του χωροταξικού επιπέδου

που προκύπτει από τα χαρακτηριστικά των τιμών του συναινετικού επιπέδου. Έτσι μειώνεται η υπολογιστική ισχύς που χρειάζεται για την επεξεργασία των δεδομένων και διατηρούνται τα κυρίαρχα χαρακτηριστικά, προσφέροντας αποτελεσματική και άμεση εκπαίδευση στο μοντέλο. Η μέγιστη συγκέντρωση επιστρέφει την μέγιστη τιμή από το συναινετικό επίπεδο και η μέση συγκέντρωση τον μέσο όρο όλων των τιμών του συναινετικού επιπέδου.


Ακόμη, όπως αναφέρθηκε υπάρχει και το άρρηκτα συνδεδεμένο επίπεδο, το οποίο παίρνει σαν είσοδο τις εξόδους όλων των συναινετικών και συγκεντρωτικών επιπέδων και το μετατρέπει σε ένα μονοδιάστατο διάνυσμα, ώστε να δοθεί μία τελική τιμή πρόβλεψης των αντικειμένων και οντοτήτων με βάση τα οποία έχει εκπαιδευτεί το μοντέλο. Παρακάτω στο Σχήμα 5- 3 παρουσιάζεται ένα παράδειγμα αρχιτεκτονικής συναινετικών νευρωνικών δικτύων.




Σχήμα 5- 3: Παράδειγμα αρχιτεκτονικής ΣΝΔ

Για να γίνει ακόμη πιο γρήγορη και με μεγαλύτερη ακρίβεια η εκπαίδευση των μοντέλων χρησιμοποιούνται οι συναρτήσεις ενεργοποίησης (activation functions). Αυτές ορίζουν το εύρος τιμών στο καρτεσιανό σύστημα που θα εκπαιδευτεί ένα μοντέλο μάθησης σε βάθος. Αν για παράδειγμα στην βάση δεδομένων που θα εκπαιδευτεί ένα μοντέλο υπάρχουν και αρνητικές και θετικές τιμές, τότε η συνάρτηση ενεργοποίησης πρέπει να οριστεί για εύρος τιμών από μείον ένα έως ένα (-1, 1). Πρέπει να τονιστεί εδώ ότι όσο μεγαλύτερο το εύρος τιμών τόσο περισσότερο χρόνο και υπολογιστικούς πόρους χρειάζεται ένα μοντέλο για να εκπαιδευτεί. Έτσι, όσο αφορά την ανάπτυξη μοντέλων για την αναγνώριση εικόνων και βίντεο εφαρμόζεται η συνάρτηση ενεργοποίησης (activation function) ReLU (Rectified Linear Unit). Η ReLU παίρνει εύρος τιμών από μηδέν έως ένα (0, 1), διότι οι εικόνες δεν έχουν αρνητικές τιμές. Με αυτό τον τρόπο το μοντέλο δεν χρειάζεται να γνωρίζει αρνητικές τιμές και έτσι η εκπαίδευση του μοντέλου χρειάζεται λιγότερο χρόνο και υπολογιστικούς πόρους για να επιτευχθεί. Παρακάτω στο Σχήμα 5- 5 παρουσιάζονται όλες οι

συναρτήσεις ενεργοποίησης και στο Σχήμα 5- 4 παρουσιάζεται το εύρος τιμών για την συνάρτηση ενεργοποίησης ReLU.



Σχήμα 5- 5: Συναρτήσεις ενεργοποίησης



Σχήμα 5- 4: Συνάρτηση ReLU


Τα τρία επίπεδα που χρησιμοποιούνται στα Συναινετικά Νευρωνικά Δίκτυα για την εκπαίδευση ενός μοντέλου, παράγουν πίνακες μόνο με ακέραιες τιμές. Έτσι δημιουργείται το εξής πρόβλημα, το μοντέλο δεν μπορεί να παράγει τελικές τιμές πρόβλεψης. Για να λυθεί αυτό το πρόβλημα, στο τέλος της αρχιτεκτονικής ενός μοντέλου αναγνώρισης εικόνων και βίντεο, θα πρέπει να χρησιμοποιηθεί μια συνάρτηση κανονικοποίησης τιμών (normalization function) γνωστή όσο αφορά αρχιτεκτονικές μάθησης σε βάθος ΣΝΔ ως Softmax συνάρτηση. Αυτή η συνάρτηση χρησιμοποιείται στο τέλος της αρχιτεκτονικής ενός μοντέλου και μετατρέπει τους ακέραιους αριθμούς σε τιμές πιθανοτήτων από μηδέν έως ένα (0, 1). Ο τύπος της συνάρτησης αυτής είναι:

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad \text{for } i = 1, \dots, K \text{ and } z = (z_1, \dots, z_K) \in \mathbb{R}^K$$

Σύμφωνα λοιπόν με όλα τα παραπάνω δημιουργήθηκε μια ισχυρή αρχιτεκτονική για την ανάπτυξη του μοντέλου CTEC, ώστε το μοντέλο να μπορεί να αναγνωρίσει και να ταξινομήσει με την μέγιστη ακρίβεια ακόμη και τις πιο σύνθετες λεπτομέρειες από τις φωτογραφίες που απεικονίζουν αυτοκίνητα και φορτηγά, με τελικό στόχο την έγκυρη καταμέτρηση των ρύπων. Ταυτόχρονα όμως το μοντέλο έπρεπε να εκπαιδευτεί με ταχύτητα και εγκυρότητα αλλά και με την χρήση των λιγότερων υπολογιστικών πόρων. Όστε να μπορεί να είναι έγκυρο και ευέλικτο για μελλοντική χρήση.

Έτσι, για την δημιουργία του μοντέλου έγινε χρήση του αλγορίθμου μάθησης σε βάθος ΣΝΔ μπροστινής τροφοδοσίας (feedforward). Δηλαδή, η πληροφορία σε αυτό το

δίκτυο μεταδίδεται μόνο προς τα μπροστά, από την είσοδο προς τα συναινετικά επίπεδα, επίπεδα συγκέντρωσης, άρρητα επίπεδα και προς την έξοδο. Η αρχιτεκτονική του μοντέλου αποτελείται συνολικά από την είσοδο της έγχρωμης εικόνας, δεκατρία (13) συναινετικά επίπεδα σε συνδυασμό με την συνάρτηση ενεργοποίησης ReLU, (γαλάζιο χρώμα), πέντε μέγιστα επίπεδα συγκέντρωσης (πράσινο χρώμα) και τρία (3) άρρηκτα συνδεδεμένα επίπεδα σε συνδυασμό με την συνάρτηση ενεργοποίησης ReLU (κίτρινο χρώμα). Τέλος, για την μετατροπή των ακέραιων τιμών σε τιμές πρόβλεψης χρησιμοποιήθηκε η συνάρτηση κανονικοποίησης Softmax (κόκκινο χρώμα). Στο Σχήμα 5- 6 παρουσιάζεται η τελική μορφή της αρχιτεκτονικής του μοντέλου CTEC.



Σχήμα 5- 6: Αρχιτεκτονική μορφή του μοντέλου CTEC

Όπως προκύπτει από το σχήμα οι εικόνες έχουν ανάλυση 240x240 και επί τρία (3) επειδή είναι έγχρωμες τύπου Red Green Blue (RGB), έτσι έχουμε για κάθε μια εικόνα μια ανάλυση επί τρία (3) χρώματα. Έπειτα, δημιουργούνται δύο (2) συναινετικά επίπεδα με μέγεθος 224x224x64 βάθος, ακολουθεί ένα επίπεδο μέγιστης συγκέντρωσης μεγέθους 112x112x128 και δύο συναινετικά επίπεδα του ίδιου μεγέθους. Ακολουθεί επίπεδο μέγιστης συγκέντρωσης μεγέθους 56x56x256 και τρία συναινετικά επίπεδα του ίδιου μεγέθους. Ακόμη, ακολουθεί το ίδιο μοτίβο, ένα επίπεδο μέγιστης συγκέντρωσης και τρία συναινετικά επίπεδα με μέγεθος 28x28x512 και αντίστοιχα ένα επίπεδο μέγιστης συγκέντρωσης και τρία συναινετικά επίπεδα με μέγεθος 14x14x512. Η αρχιτεκτονική συνεχίζεται με το τελευταίο επίπεδο μέγιστης συγκέντρωσης με μέγεθος 7x7x512 και έπειτα ακολουθούν τρία (3) άρρηκτα συνδεδεμένα επίπεδα. Τα δύο (2) πρώτα με μέγεθος 1x1x4096 και το τρίτο με μέγεθος 1x1x1000. Τέλος, η αρχιτεκτονική τελειώνει με την κανονικοποίηση των τιμών των προηγούμενων επιπέδων μέσω της συνάρτησης κανονικοποίησης Softmax.

Όπως παρατηρείται, το μέγεθος των επιπέδων μικραίνει ενώ το βάθος τους μεγαλώνει. Αυτό συμβαίνει διότι το μοντέλο πρέπει να εκπαιδευτεί με ταχύτητα αλλά ταυτόχρονα να μάθει σε βάθος και τις πιο περίπλοκες λεπτομέρειες μεταξύ των δύο κατηγοριών. Στα τελευταία στάδια ακολουθούν τα άρρηκτα συνδεδεμένα επίπεδα τα οποία μαζεύουν σε ένα μονοδιάστατο διάνυσμα όλες τις πληροφορίες από τα προηγούμενα επίπεδα ώστε να δοθεί για κάθε εικόνα μια τιμή πρόβλεψης. Τέλος, η συνάρτηση κανονικοποίησης Softmax μετατρέπει τις τιμές των χαρακτηριστικών από κάθε εικόνα σε τιμή πρόβλεψης, για να μπορεί να αποδοθεί η ακρίβεια αναγνώρισης των αντικειμένων και των οντοτήτων που εμφανίζονται στην εικόνα.

### **5.6.2 Μαθηματικό μοντέλο υπολογισμού ρύπων**

Οι κατασκευαστές οχημάτων βελτιώνουν συνέχεια τις τεχνολογίες των κινητήρων και εισάγουν διάφορα συστήματα ελέγχου εκπομπών, καθώς θα πρέπει να ανταποκρίνονται στις απαιτήσεις της νομοθεσίας. Τα οδικά οχήματα κατηγοριοποιούνται σύμφωνα με το επίπεδο της τεχνολογίας ελέγχου των εκπομπών που διαθέτουν, όπου μετά το 1992 τα πρότυπα που νομοθετήθηκαν ονομάστηκαν “Euro”. Στην παρούσα εργασία γίνεται καταμέτρηση των ρύπων για δυο κατηγορίες οχημάτων, βενζινοκίνητα ελαφρά επαγγελματικά οχήματα (αυτοκίνητα < 3,5 τόνους) τεχνολογίας Euro5 και πετρελαιοκίνητα βαρέα επαγγελματικά οχήματα (φορτηγά < 14 τόνους) τεχνολογίας EuroV.

Όσον αφορά τα βενζινοκίνητα ελαφρά επαγγελματικά οχήματα (αυτοκίνητα < 3,5 τόνους) η τεχνολογία Euro5 υποχρεώνει μείωση των εκπομπών NOx 25% σε σύγκριση με την τεχνολογία Euro4 και εφαρμόστηκε από το 2015 και μετά. Η τεχνολογία ελέγχου των εκπομπών που χρησιμοποιείται στα ελαφρά επαγγελματικά οχήματα ακολουθεί γενικά την τεχνολογία των επιβατικών αυτοκινήτων με καθυστέρηση 1-2 ετών. Τα πρότυπα EuroV για τα πετρελαιοκίνητα βαρέα επαγγελματικά οχήματα (φορτηγά < 14 τόνους) εφαρμόστηκαν το 2008 και απαιτούν μείωση των εκπομπών NOx άνω του 70% και μείωση των εκπομπών PM άνω του 85% σε σύγκριση με τα πρότυπα EuroII. Αυτό επιτυγχάνεται με τον συντονισμό των κινητήρων και τους καταλύτες οξείδωσης για τον έλεγχο των PM και την επιλεκτική καταλυτική αναγωγή (SCR) για τον έλεγχο των NOx. Στον Πίνακα 3 που παρατίθεται παρακάτω παρουσιάζονται οι κατηγορίες των οχημάτων σε συνδυασμό με τις χρονολογίες εφαρμογής των προτύπων Euro.



Κατηγορία οχήματος	Τύπος	Πρότυπο Euro	Χρονολογία εφαρμογής
Ελαφρά Επαγγελματικά Οχήματα (αυτοκίνητα < 3,5 τόνους)	Petrol N1-I Petrol N1-II Petrol N1-III	Conventional	1973
		Euro1	1993
		Euro2	1997
		Euro3	2001
		Euro4	2006
		Euro5	2010
		Euro6 (μέχρι 2017)	2010
		Euro6 (2018-2020)	2010
		Euro6 (2021+)	2010
Βαρέα Επαγγελματικά Οχήματα (φορτηγά < 14 τόνους)	Petrol > 3.5tn	Conventional	1988
	All Rigid/ Articulated Categories	Conventional	1988
		EuroI	1992
		EuroII	1996
		EuroIII	2000
		EuroIV	2005
		EuroV	2008
		EuroVI	2013

Πίνακας 3: Κατηγορίες οχημάτων & χρονολογία εφαρμογής των προτύπων Euro

Τα δεδομένα των μέσων εκπομπών των οχημάτων που χρησιμοποιήθηκαν για τον τελικό υπολογισμό των ρύπων δόθηκαν από τον Ευρωπαϊκό Οργανισμό Περιβάλλοντος, όπου είχαν υπολογισθεί μέσω της μεθόδου Tier 3. Στη συγκεκριμένη μέθοδο οι εκπομπές υπολογίζονται χρησιμοποιώντας ένα συνδυασμό σταθερών τεχνικών δεδομένων και δεδομένων δραστηριότητας. Συγκεκριμένα, οι συνολικές εκπομπές καυσαερίων από τις οδικές μεταφορές υπολογίζονται ως το άθροισμα των θερμών εκπομπών (όταν ο κινητήρας βρίσκεται στην κανονική τους θερμοκρασία λειτουργίας) και των εκπομπών κατά τη λειτουργία της μεταβατικής θερμικής μηχανής (ονομαζόμενες εκπομπές "ψυχρής εκκίνησης"). Οι συνολικές εκπομπές μπορούν να υπολογιστούν με την ακόλουθη εξίσωση:

$$E_{TOTAL} = E_{HOT} + E_{COLD}$$

όπου  $E_{HOT}$  = εκπομπές κατά τη διάρκεια της θερμής λειτουργίας του κινητήρα

$E_{COLD}$  = εκπομπές κατά τη διάρκεια της προσωρινής λειτουργίας του θερμικού κινητήρα (ψυχρή εκκίνηση).

Σύμφωνα με τα παραπάνω, οι μέσες εκπομπές του κάθε οχήματος παρουσιάζονται στον ακόλουθο Πίνακα 4, όπου ΕΕΟ είναι τα ελαφρά επαγγελματικά οχήματα (αυτοκίνητα < 3,5 τόνους) και ΒΕΟ είναι βαρέα επαγγελματικά οχήματα (φορτηγά < 14 τόνους).

Είδος Ρύπου	Τιμή ρύπου (gr/km)	
	ΕΕΟ	ΒΕΟ
FC	183,3735	340,059
CO <sub>2</sub>	581,1105	1077,6308
CH <sub>4</sub>	0,0020	1,7254
CO	0,9964	0,0026
N <sub>2</sub> O	N/A	0,0150
NH <sub>3</sub>	N/A	0,0110
NO <sub>x</sub>	0,0344	8,9559
PM	0,0011	0,0535
VOC	0,0162	0,3141
SO <sub>2</sub>	0,0006	0,0012

Πίνακας 4: Μέσες τιμές ρύπων κάθε οχήματος

### 5.6.3 Καταμέτρηση και υπολογισμός ρύπων

Όπως έχει ήδη αναφερθεί ο σκοπός της συγκεκριμένης διατριβής ήταν η δημιουργία ενός ισχυρού υπολογιστικού μοντέλου υπολογισμού ρύπων οχημάτων, τύπου αυτοκινήτων και φορτηγών, μέσω αλγορίθμων αιχμής MB. Για να γίνει αυτό, αρχικά δημιουργήθηκε ένα μοντέλο αναγνώρισης και κατηγοριοποίησης των δυο τύπων οχημάτων, μέσω εικόνων, βίντεο και πραγματικού χρόνου βίντεο.

Για την καταμέτρηση των οχημάτων δημιουργήθηκε ένα υπο πρόγραμμα το οποίο δημιουργεί μέσω του μοντέλου CTEC, δύο πίνακες έναν για την καταμέτρηση της κάθε κατηγορίας οχήματος. Πιο συγκεκριμένα, δύο μετρητές ένας για αυτοκίνητα και ένας για φορτηγά προστίθενται όταν το μοντέλο CTEC αναγνωρίσει με επιτυχία τα είδη των προαναφερθέντων οχημάτων και αποθηκεύει το σύνολο των αναγνωρισμένων και καταμετρημένων οχημάτων σε δύο διαφορετικούς πίνακες, έναν για κάθε κατηγορία.

Τέλος, για τον υπολογισμό των ρύπων χρησιμοποιείται ένα δεύτερο υπο-πρόγραμμα το οποίο καλεί τους δύο πίνακες με τα σύνολα των καταμετρημένων οχημάτων της κάθε κατηγορίας και υπολογίζει δέκα (10) διαφορετικά είδη ρύπων ανά τιμή ρύπου (gr/km). Τα δέκα είδη ρύπων όπως αναφέρθηκε είναι FC, CO<sub>2</sub>, CH<sub>4</sub>, CO, N<sub>2</sub>O, NH<sub>3</sub>, NO<sub>x</sub>, PM, VOC και SO<sub>2</sub>. Το υπο-πρόγραμμα επιστρέφει στον χρήστη δύο αρχεία ανάγνωσης, ένα το οποίο περιέχει τον υπολογισμό των ρύπων για τα αυτοκίνητα και ένα το οποίο περιέχει τον υπολογισμό των ρύπων για φορτηγά.

## Κεφάλαιο 6. ΑΠΟΤΕΛΕΣΜΑΤΑ

Ο σκοπός αυτού του κεφαλαίου είναι η παρουσίαση των αποτελεσμάτων του μοντέλου υπολογισμού ρύπων αυτοκινήτων και φορτηγών CTEC. Όπως αναφέρθηκε για την εκπαίδευση του μοντέλου χρησιμοποιήθηκε το σύνολο εκπαίδευσης μεγέθους 960 έγχρωμων φωτογραφιών και το σύνολο δοκιμής μεγέθους 240 έγχρωμων φωτογραφιών.

Για να γίνει η σύγκριση του μοντέλου CTEC και να φανεί το πόσο καλά εκπαιδεύτηκε και το πόσο καλά μπορεί να προβλέψει τις δύο κατηγορίες, χρησιμοποιήθηκαν κάποια μαθηματικά-στατιστικά μοντέλα και μια συνάρτηση. Η συνάρτηση που χρησιμοποιήθηκε για την απόδοση του μοντέλου είναι η συνάρτηση απώλειας (Loss function) καθώς και το διάγραμμα της, το οποίο παρουσιάζει το σύνολο της συνάρτησης απώλειας ανά εποχή (TotalLoss per Epoch). Έπειτα, χρησιμοποιήθηκαν το μαθηματικό-στατιστικό μοντέλο υπολογισμού λαθών, Μέσο Τετράγωνο Σφάλμα (Mean Squared Error-MSE), το μαθηματικό-στατιστικό μοντέλο υπολογισμού λαθών Μέσο Απόλυτο Σφάλμα (Mean Absolute Error-MAE) και το μαθηματικό-στατιστικό μοντέλο μέσης ακρίβειας (Average Precision-AP), ένα πολύ δημοφιλές σύστημα μέτρησης της ακρίβειας για μοντέλα μάθησης σε βάθος που ανιχνεύουν αντικείμενα και οντότητες μέσω εικόνων και βίντεο. Τέλος, καταγράφηκε η απόδοση του μοντέλου και για τη φάση εκπαίδευσης-επαλήθευσης και για την φάση δοκιμής σε συγκεντρωτικούς πίνακες. Πρέπει να σημειωθεί εδώ ότι την απόδοση του μοντέλου κρίνεται με βάση την φάση δοκιμής, την φάση δηλαδή κατά την οποία δίνονται στο ήδη εκπαιδευμένο μοντέλο, εικόνες που τις επεξεργάζεται για πρώτη φορά. Δηλαδή, είναι άγνωστες ως προς αυτό, δεν εκπαιδεύτηκε με βάση αυτές και τις βλέπει για πρώτη φορά.

### 6.1 Συνάρτηση απώλειας

Η συνάρτηση απώλειας καταγράφει διαισθητικά ένα συμβάν ή τις τιμές μιας ή περισσότερων μεταβλητών σε έναν πραγματικό αριθμό, αντιπροσωπεύοντας κάποια "απώλεια-κόστος τιμής" που σχετίζεται με το συμβάν. Για την μέτρηση της απόδοσης του μοντέλου CTEC χρησιμοποιήθηκε το παράδειγμα της 0-1 συνάρτησης απώλειας. Ο μαθηματικός τύπος της παρουσιάζεται παρακάτω, όπου το  $y$  είναι οι κατηγορίες που έχουν δοθεί για εκπαίδευση στο μοντέλο.

$$\sum_{i=1}^{i=3} y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)$$

Το διάγραμμα σύνολο της συνάρτησης απώλειας ανά εποχή (TotalLoss per Epoch) παρουσιάζει το πόσο καλά μπορεί να προβλέψει το μοντέλο CTEC τις αληθινές τιμές από τις κατηγορίες που παρουσιάζονται σε μια εικόνα που του έχει δοθεί, ανά μια εποχή εκπαίδευσης. Σαν εποχή εννοείται, όταν όλο το σύνολο εκπαίδευσης περνάει προς τα εμπρός και πίσω σε όλο το νευρωνικό δίκτυο. Λόγω του τεράστιου όγκου που κατέχουν τα σύνολα δεδομένων που αποτελούνται από εικόνες, είναι δύσκολο να τροφοδοτηθούν ολόκληρα προς τα μπρος και πίσω σε ένα νευρωνικό δίκτυο. Γι' αυτό το λόγο, για να βελτιστοποιηθεί η εκπαίδευση του μοντέλου χρησιμοποιούνται οι εποχές, δηλαδή μικρότερα κατακερματισμένα σε μέγεθος πακέτα δεδομένων που προκύπτουν από το αρχικό σύνολο δεδομένων.

## 6.2 Μέσο Τετραγωνικό Σφάλμα (MSE)

Το Μέσο Τετραγωνικό Σφάλμα μετρά τον μέσο όρο των τετραγώνων σφαλμάτων, δηλαδή τη μέση τετραγωνική διαφορά μεταξύ των εκτιμώμενων τιμών από τις πραγματικές τιμές ενός συνόλου δεδομένων που έχουν χρησιμοποιηθεί για την δημιουργία ενός μοντέλου μηχανικής μάθησης-μάθησης σε βάθος. Το Μέσο Τετραγωνικό Σφάλμα αποτελεί ένα μέτρο εκτίμησης απόδοσης, βγάζει μόνο θετικές τιμές και οι καλύτερες τιμές είναι όσο πιο κοντά στο μηδέν. Παρακάτω παρουσιάζεται η μαθηματική φόρμουλα για τον υπολογισμό του μέσου τετραγωνικού σφάλματος. Όπου το  $n$  είναι το σύνολο δεδομένων,  $Y$  είναι οι πραγματικές τιμές και  $\hat{Y}_i$  είναι οι εκτιμώμενες τιμές.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

## 6.3 Μέσο Απόλυτο Σφάλμα (MAE)

Το Μέσο Απόλυτο Σφάλμα αποτελεί ένα μέτρο διαφοράς μεταξύ δύο συνεχών μεταβλητών. Η μαθηματική φόρμουλα για τον υπολογισμό του μέσου απόλυτου σφάλματος αναφέρεται ακολούθως, όπου το  $n$  είναι το σύνολο των σημείων και  $(x_i, y_i)$  οι συντεταγμένες του σημείου  $i$ .


$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} = \frac{\sum_{i=1}^n |e_i|}{n}$$

Το Μέσο Απόλυτο Σφάλμα είναι ένας μέσος όρος των απόλυτων σφαλμάτων:

$$|e_i| = |y_i - x_i|$$

## 6.4 Μέση Ακρίβεια (AP)

Η μέση ακρίβεια AP υπολογίζει τη μέση τιμή ακρίβειας (Precision) για την τιμή ανάκλασης (Recall) από μηδέν έως 1 (0, 1). Η ακρίβεια υπολογίζει το πόσο ακριβές είναι οι προβλέψεις του μοντέλου, ενώ η ανάκλαση το πόσο καλά ανιχνεύονται όλες οι θετικές τιμές, όπου θετικές τιμές ορίζονται οι κατηγορίες οχημάτων που όντως παρουσιάζονται σε μια εικόνα. Αρχικά, οι τιμές ανάκλασης που βρίσκονται από 0-1 χωρίζονται σε 11 σημεία 0, 0.1, 0.2 έως 1.0. Έπειτα, όπως φαίνεται και από το διάγραμμα στο Σχήμα 6- 1 η μέση ακρίβεια υπολογίζεται από τον υπολογισμό των μεγαλύτερων τιμών ακρίβειας για τα 11 σημεία της ανάκλασης.



Σχήμα 6- 1: Διάγραμμα μέσης ακρίβειας

Παρακάτω παρουσιάζονται οι μαθηματικές φόρμουλες για την ακρίβεια και την ανάκλαση και η μαθηματική φόρμουλα για την μέση ακρίβεια.

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$TP$  = True positive

$TN$  = True negative

$FP$  = False positive

$FN$  = False negative

$$AP = \int_0^1 p(r) dr$$

## 6.5 Τελικά αποτελέσματα

Σε αυτό το υπό κεφάλαιο παρουσιάζονται τα τελικά αποτελέσματα για τον υπολογισμό της απόδοσης του μοντέλου CTEC. Όπως παρουσιάστηκε στα προηγούμενα υπό κεφάλαια για να υπολογίσουμε την απόδοση του μοντέλου, χρησιμοποιήθηκε η συνθήκη συνολικής απώλειας ανά εποχή, το μέσο τετραγωνικό σφάλμα, το μέσο απόλυτο σφάλμα και η μέση ακρίβεια. Στο Σχήμα 6- 2 παρουσιάζεται το διάγραμμα συνολικής απώλειας ανά εποχή.



Σχήμα 6- 2: Διάγραμμα συνολικής απώλειας ανά εποχή

Όπως προκύπτει από το παραπάνω διάγραμμα το καλύτερο αποτέλεσμα απόδοσης του μοντέλου προκύπτει στην εποχή 105.000 χιλιάδες, όπου η συνολική απώλεια είναι 0,39. Όσο μικρότερη η τιμή της συνολικής απώλειας τόσο καλύτερα αποδίδει το μοντέλο, δηλαδή μπορεί και αναγνωρίζει τα σύνολα εκπαίδευσης και δοκιμής με μεγαλύτερη ακρίβεια.

Για να επαληθευτεί και να εγκυροποιηθεί η απόδοση χρειάζονται και οι τιμές από τα μαθηματικό-στατιστικά μοντέλα, μέσο τετραγωνικό σφάλμα, μέσο απόλυτο σφάλμα και μέση ακρίβεια. Στον Πίνακα 5 παρουσιάζονται οι τιμές για τα προαναφερθέντα μαθηματικο-στατιστικά μοντέλα για το σύνολο δεδομένων εκπαίδευσης και δοκιμής καθώς και οι τιμές απόδοσης των δύο κατηγοριών, αυτοκινήτων και φορτηγών.


Μέθοδος	Σύνολο δεδομένων	TotalLoss	MSE	MAE	AP %	Αυτοκίνητο %	Φορτηγό %
CTEC	Σύνολο εκπαίδευσης 960 έγχρωμες εικόνες	0.39	0.48	0.52	72%	74%	70%
CTEC	Σύνολο δοκιμής 240 έγχρωμες εικόνες	0.44	0.59	0.64	64%	65%	63%

Πίνακας 5: Συγκεντρωτικός πίνακας για τη μέθοδο CTEC



Όπως προκύπτει από τον παραπάνω πίνακα το μοντέλο CTEC για το σύνολο δεδομένων εκπαίδευσης, έχει ακρίβεια αναγνώρισης για τα αυτοκίνητα 74.0% και για τα φορτηγά 70%. Αυτό σημαίνει ότι το μοντέλο αναγνώρισε σωστά το 74% των αληθινών τιμών του σετ εκπαίδευσης αυτοκινήτων και 70% τις αληθινές τιμές του σετ εκπαίδευσης φορτηγών. Τέλος, το μοντέλο CTEC για το σύνολο δεδομένων δοκιμής, αναγνώρισε σωστά το 65% των αληθινών τιμών του σετ αυτοκινήτων και 63% τις αληθινές τιμές του σετ δοκιμής φορτηγών.

## 6.6 Παραδείγματα πρόβλεψης εικόνων

Σε αυτή την κατηγορία παρουσιάζονται μερικά παραδείγματα με τις αληθινές εικόνες αυτοκινήτων και φορτηγών από το σετ δοκιμής και πώς αυτές προβλέφθηκαν από το μοντέλο CTEC. Εδώ πρέπει να σημειωθεί ότι το σκορ πρόβλεψης είναι μεγαλύτερο από τους μέσους όρους τιμών που παρουσιάστηκαν στο τελικό πίνακα, διότι αλλάζουν οι τιμές ανά γωνία θέασης και εστίασης του αντικειμένου. Οι τιμές αυτές, δεν αποτελούν τον μέσο όρο, αλλά αναφέρονται σε στιγμιαία τιμή πρόβλεψης. Παρακάτω παρουσιάζονται εικόνες δοκιμής πριν και μετά την πρόβλεψη, για τις δύο κατηγορίες αυτοκίνητα και φορτηγά και για τις τρεις γωνίες θέασης, μπροστά, πλάγια, πίσω. Στο Σχήμα 6- 3 παρουσιάζονται τα αποτελέσματα για την πρόβλεψη της κατηγορίας αυτοκινήτων και στο Σχήμα 6- 4 τα αποτελέσματα για την κατηγορία φορτηγών.







Σχήμα 6- 3: Παραδείγματα αποτελεσμάτων για την πρόβλεψη αυτοκίνητου





Σχήμα 6- 4: Παραδείγματα αποτελεσμάτων για την πρόβλεψη φορτηγού

## 6.7 Παραδείγματα υπολογισμού ρύπων

Παρακάτω παρουσιάζεται ο τρόπος με τον οποίο γίνεται η καταμέτρηση των ρύπων για αυτοκίνητα και φορτηγά μέσω του υπολογιστικού μοντέλου ρύπων αυτοκινήτων και φορτηγών CTEC. Αφού το μοντέλο τελειώσει την ανάγνωση μιας εικόνας, βίντεο ή ενός βίντεο πραγματικού χρόνου, αποθηκεύει στην αντίστοιχη μορφή την πρόβλεψη που έχει εφαρμόσει. Έπειτα εκτελεί το υπό πρόγραμμα καταμέτρησης οχημάτων, το οποίο μετράει τα συνολικά αυτοκίνητα και φορτηγά που αναγνωρίστηκαν μέσω του μοντέλου μάθησης σε βάθος CTEC. Τέλος, εκτελείται το υπό πρόγραμμα υπολογισμού και αποθήκευσης ρύπων, το οποίο αποθηκεύει σε ξεχωριστά αρχεία ανάγνωσης τους ρύπους για την κάθε κατηγορία. Το τελικό αρχείο για την κάθε κατηγορία περιέχει το σύνολο των οχημάτων της κάθε κατηγορίας τα οποία καταμετρήθηκαν, το σύνολο των ρύπων FC (gr/km), CO<sub>2</sub> (gr/km), CH<sub>4</sub> (gr/km), CO (gr/km), N<sub>2</sub>O (gr/km), NH<sub>3</sub> (gr/km), NO<sub>x</sub> (gr/km), PM (gr/km), PM (gr/km) και SO<sub>2</sub> (gr/km).

Για την δοκιμή του μοντέλου CTEC δόθηκε ένα βίντεο από αυτοκινητόδρομο διάρκειας δέκα δευτερολέπτων, με στόχο να υπολογίσει το υπολογιστικό μοντέλο τους ρύπους των οχημάτων που καταγράφηκαν στο βίντεο. Το υπολογιστικό μοντέλο έδωσε σαν έξοδο το βίντεο με τις αναγνωρισμένες κατηγορίες αυτοκινήτων και φορτηγών και δύο αρχεία υπολογισμού ρύπων, ένα για κάθε κατηγορία. Παρακάτω παρουσιάζονται δύο πίνακες, ο Πίνακας 6 παρουσιάζει την τελική μορφή που έχει το αρχείο για τον υπολογισμό των ρύπων αυτοκινήτων και ο Πίνακας 7 την τελική μορφή που έχει το αρχείο για τον υπολογισμό των ρύπων φορτηγών.

<b>Total Car</b>	<b>FC</b> (gr/km)	<b>CO2</b> (gr/km)	<b>CH4</b> (gr/km)	<b>CO</b> (gr/km)	<b>N2O</b> (gr/km)	<b>NH3</b> (gr/km)	<b>NOx</b> (gr/km)	<b>PM</b> (gr/km)	<b>VOC</b> (gr/km)	<b>SO2</b> (gr/km)
30	5501.2036	17433.3144	0.06	17433.3144	N/A	N/A	1.0318	0.0320	0.4873	0.0191

Πίνακας 6: Τελική μορφή του υπολογισμού των ρύπων των αυτοκινήτων

<b>Total Truck</b>	<b>FC</b> (gr/km)	<b>CO2</b> (gr/km)	<b>CH4</b> (gr/km)	<b>CO</b> (gr/km)	<b>N2O</b> (gr/km)	<b>NH3</b> (gr/km)	<b>NOx</b> (gr/km)	<b>PM</b> (gr/km)	<b>VOC</b> (gr/km)	<b>SO2</b> (gr/km)
2	680.1077	2155.2615	3.4507	2155.2615	0.03	0.022	17.9118	0.1070	0.6281	0.0023

Πίνακας 7: Τελική μορφή του υπολογισμού των ρύπων των φορτηγών

## Κεφάλαιο 7. ΣΥΜΠΕΡΑΣΜΑΤΑ

---

Στην συγκεκριμένη διπλωματική παρουσιάστηκε ένα νέο ισχυρό υπολογιστικό μοντέλο, βασιζόμενο σε αλγόριθμο μάθησης σε βάθος και πιο συγκεκριμένα μέσω του αλγορίθμου αιχμής μάθησης σε βάθος Συναινετικών Νευρωνικών Δικτύων. Το υπολογιστικό μοντέλο δημιουργήθηκε ώστε να μπορεί να υπολογίσει τους ρύπους για δύο κλάσεις οχημάτων, βενζινοκίνητα αυτοκίνητα τεχνολογίας Euro5 και πετρελαιοκίνητα φορτηγά μέχρι 14 τόνους τεχνολογίας EuroV. Για την υλοποίηση του παραπάνω στόχου αρχικά αναπτύχθηκε ένα μοντέλο μάθησης σε βάθος με την ονομασία CTEC το οποίο εκπαιδεύτηκε για να μπορεί να αναγνωρίσει με ακρίβεια τις δυο κατηγορίες οχημάτων, μέσω εικόνας, βίντεο και βίντεο πραγματικού χρόνου. Για να ολοκληρωθεί το υπολογιστικό μοντέλο ρύπων, αναπτυχθήκαν δύο ακόμα μαθηματικά μοντέλα, ένα που υπολογίζει την καταμέτρηση των συνολικών αναγνωρισμένων οχημάτων και ένα το οποίο υπολογίζει τους συνολικούς ρύπους που παράγονται από αυτά.

Για την εκπαίδευση και την δοκιμή του CTEC χρησιμοποιήθηκε ένα συνολικό σετ φωτογραφιών με μέγεθος 1.200 έγχρωμες φωτογραφίες. Αυτό χωρίστηκε σε δύο σύνολα, ένα σύνολο εκπαίδευσης-επαλήθευσης με μέγεθος 960 έγχρωμες φωτογραφίες και ένα σύνολο δοκιμής με μέγεθος 240 έγχρωμες φωτογραφίες.

Τα αποτελέσματα έδειξαν ότι το ισχυρό υπολογιστικό μοντέλο υπολογισμού ρύπων CTEC μπορεί και αναγνωρίζει το σετ δοκιμής με μέση ακρίβεια, αυτό συμβαίνει λόγω του μικρού μεγέθους συνόλου εκπαίδευσης και δοκιμής.

Ακόμη, αξίζει να σημειωθεί ότι αποτελεί καινοτομία το γεγονός ότι το μοντέλο δημιουργήθηκε με την υποστήριξη της υπολογιστικής ισχύος των πυρήνων της κάρτας γραφικών 1080Ti NVidia. Το μειονέκτημα της παραπάνω διαδικασίας αποτελεί το γεγονός ότι είναι εξειδικευμένη και δύσκολη στην χρήση και στη υλοποίηση της σε σχέση με τις κλασσικές τεχνικές που χρησιμοποιούν την υπολογιστική ισχύ των πυρήνων του επεξεργαστή. Τα πλεονεκτήματα της είναι η δημιουργία και η εκπαίδευση μοντέλων με την χρήση απαιτητικών αλγορίθμων μάθησης σε βάθος αιχμής και μεγάλων σε μέγεθος συνόλων δεδομένων, σε μικρότερο χρόνο εκμάθησης και με λιγότερο οικονομικό κόστος κατασκευής. Διότι, αντί να χρησιμοποιηθούν ακριβά κλασσικά υπολογιστικά μηχανήματα τεραστίου κόστους, χρησιμοποιείται ένα μεσαίο επιδόσεων υπολογιστικό σύστημα με μια ισχυρή κάρτα γραφικών.

## Κεφάλαιο 8. ΜΕΛΛΟΝΤΙΚΗ ΕΡΕΥΝΑ

---

Σύμφωνα με τα προαναφερθέντα κύριος μελλοντικός στόχος είναι η αύξηση της ακρίβειας της αναγνώρισης των δύο κύριων κλάσεων οχημάτων, αυτοκινήτων και φορτηγών, με στόχο τον ακριβή υπολογισμό των ρύπων που παράγονται από τις δύο κατηγορίες οχημάτων.

Για να γίνει αυτό θα δημιουργηθούν μεγαλύτερα σύνολα έγχρωμων φωτογραφιών από εικόνες που απεικονίζουν τις δύο κατηγορίες οχημάτων. Ιδανικά θα ήταν ωφέλιμο να δημιουργεί ένα σύνολο εκπαίδευσης και δοκιμής με μέγεθος 100.000 χιλιάδες και πάνω από έγχρωμες φωτογραφίες που απεικονίζουν τις δύο κατηγορίες οχημάτων σε ποικίλες γωνίες θέασης, χρώματα και αποστάσεις

Θα αναπτυχθούν και θα δοκιμαστούν νέα μοντέλα μάθησης σε βάθος, σε ποικίλες μεθόδους αιχμής μάθησης σε βάθος, όπως Recurrent Neural Networks (RNN) καθώς και τον συνδυασμό περισσότερων μεθόδων. Θα δημιουργηθούν πιο σύνθετες και μεγαλύτερες σε μέγεθος αρχιτεκτονικές επιπέδων. Με στόχο την αύξηση της ανίχνευσης των κατηγοριών των οχημάτων και παράλληλα των ρύπων, αλλά και την ικανότητα πρόγνωσης των ρύπων σε μια περιοχή για τις επόμενες ημέρες.

Τέλος, θα προστεθούν νέες κατηγορίες οχημάτων όπως λεωφορεία και μηχανές για την βελτιστοποίηση τον υπολογισμό των ρύπων σε αστικά και μη αστικά κέντρα.

Τελικός στόχος όλων των παραπάνω θα είναι η δημιουργία ενός ιστότοπου ο οποίος θα ενημερώνει σε πραγματικό χρόνο μέσω χαρτών τις αρμόδιες αρχές σχετικά με τις εκπομπές των ρύπων σε περιοχές που γίνεται η χρήση του μοντέλου CTEC. Καθώς θα γίνεται και η μελλοντική πρόγνωση των ρύπων για ένα προκαθορισμένο εύρος ημερών. Έτσι θα είναι σε θέση οι αρχές να ενημερώνονται και να αποθηκεύουν τις μετρήσεις των ρύπων για τις περιοχές που καλύπτονται από το μοντέλο, με στόχο την λήψη αποφάσεων για την αύξηση της ποιότητας ζωής των ανθρώπων σε αστικά και μη κέντρα.



## ΒΙΒΛΙΟΓΡΑΦΙΑ

---

- [1] K. G. Liakos, P. Busato, D. Moshou, S. Pearson, and D. Bochtis, "Machine learning in agriculture: A review," *Sensors (Switzerland)*. 2018.
- [2] Y. LeCun, Y. Bengio, G. Hinton, L. Y., B. Y., and H. G., "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [3] A. L. Samuel, "Some Studies in Machine Learning Using the Game of Checkers," *IBM J. Res. Dev.*, vol. 44, no. 1.2, pp. 206–226, 1959.
- [4] S. Gupta, A. Hamzin, and A. Degbelo, "A low-cost open hardware system for collecting traffic data using wi-fi signal strength," *Sensors (Switzerland)*, vol. 18, no. 11, 2018.
- [5] M. Grote, I. Williams, J. Preston, and S. Kemp, "A practical model for predicting road traffic carbon dioxide emissions using Inductive Loop Detector data," *Transp. Res. Part D Transp. Environ.*, vol. 63, no. July, pp. 809–825, 2018.
- [6] G. K. D. Saharidis, G. Kolomvos, and G. Liberopoulos, "Modeling and solution approach for the environmental traveling salesman problem," *Eng. Lett.*, vol. 22, no. 2, pp. 70–74, 2014.
- [7] H. Forehead and N. Huynh, "Review of modelling air pollution from traffic at street-level - The state of the science," *Environmental Pollution*. 2018.
- [8] D. McIntyre, F. Wolff, C. Papachristou, S. Bhunia, and D. Weyer, "Dynamic evaluation of hardware trust," in *2009 IEEE International Workshop on Hardware-Oriented Security and Trust, HOST 2009*, 2009.
- [9] H. Salmani, M. Tehranipoor, and J. Plusquellic, "A novel technique for improving hardware trojan detection and reducing trojan activation time," *IEEE Trans. Very Large Scale Integr. Syst.*, 2012.
- [10] H. Salmani and M. Tehranipoor, "Layout-aware switching activity localization to enhance hardware trojan detection," *IEEE Trans. Inf. Forensics Secur.*, 2012.
- [11] Y. Jin, D. Maliuk, and Y. Makris, "Post-deployment trust evaluation in wireless cryptographic ICs," in *Proceedings -Design, Automation and Test in Europe, DATE*, 2012.
- [12] C. Bao, D. Forte, and A. Srivastava, "On application of one-class SVM to reverse engineering-based hardware Trojan detection," in *Proceedings - International Symposium on Quality Electronic Design, ISQED*, 2014.
- [13] L. Moutinho, G. Hutcheson, G. Hutcheson, and G. Hutcheson, "Ordinary Least-Squares Regression," in *The SAGE Dictionary of Quantitative Management Research*, 2014.
- [14] J. R. Quinlan, "Learning with continuous classes," *Mach. Learn.*, 1992.
- [15] W. S. Cleveland, "Robust locally weighted regression and smoothing scatterplots," *J. Am. Stat. Assoc.*, 1979.
- [16] R. Rad, J. Plusquellic, and M. Tehranipoor, "A sensitivity analysis of power signal methods for detecting hardware trojans under real process and environmental conditions," *IEEE Trans. Very Large Scale Integr. Syst.*, 2010.
- [17] J. Aarestad, D. Acharyya, R. Rad, and J. Plusquellic, "Detecting trojans through leakage current analysis using multiple supply pad IDDQs," *IEEE Trans. Inf. Forensics Secur.*, 2010.
- [18] S. Wei, S. Meguerdichian, and M. Potkonjak, "Malicious circuitry detection using thermal conditioning," *IEEE Trans. Inf. Forensics Secur.*, 2011.
- [19] F. Koushanfar and A. Mirhoseini, "A unified framework for multimodal submodular integrated circuits trojan detection," *IEEE Trans. Inf. Forensics Secur.*, 2011.
- [20] A. Ligeza, "Artificial Intelligence: A Modern Approach (Book Review)," *Neurocomputing*, vol. 9, pp. 215–219, 1995.

- [21] R. M. R. B. Clarke, "Review Author ( s ): M . R . B . Clarke Source : Journal of the Royal Statistical Society . Series A ( General ), Vol . 137 , No . 3 ( 1974 ), Published by : Wiley for the Royal Statistical Society Stable URL : <http://www.jstor.org/stable/2344977> Accessed," vol. 137, no. 3, pp. 442–443, 2016.
- [22] R. E. Neapolitan, "Models for reasoning under uncertainty," *Appl. Artif. Intell.*, vol. 1, no. 4, pp. 337–366, 1987.
- [23] S. Narasimhan *et al.*, "Hardware trojan detection by multiple-parameter side-channel analysis," *IEEE Trans. Comput.*, vol. 62, no. 11, pp. 2183–2195, 2013.
- [24] R. S. Chakraborty and S. Bhunia, "Security against hardware Trojan attacks using key-based design obfuscation," *J. Electron. Test. Theory Appl.*, 2011.
- [25] A. Waksman, M. Suozzo, and S. Sethumadhavan, "FANCI: Identification of stealthy malicious logic using boolean functional analysis," in *Proceedings of the ACM Conference on Computer and Communications Security*, 2013.
- [26] J. Zhang, F. Yuan, L. Wei, Y. Liu, and Q. Xu, "VeriTrust: Verification for hardware trust," *IEEE Trans. Comput. Des. Integr. Circuits Syst.*, vol. 34, no. 7, pp. 1148–1161, 2015.
- [27] L. Breiman, J. H. Friedman, R. A. Olshen, and C. J. Stone, *Classification and regression trees*. 2017.
- [28] G. V. Kass, "An Exploratory Technique for Investigating Large Quantities of Categorical Data," *Appl. Stat.*, vol. 29, no. 2, p. 119, 1980.
- [29] J. R. Quinlan, "J. Ross Quinlan\_C4.5\_ Programs for Machine Learning.pdf," *Morgan Kaufmann*. 1993.
- [30] B. Zhou, W. Zhang, S. Thambipillai, and J. K. J. Teo, "A low cost acceleration method for hardware trojan detection based on fan-out cone analysis," in *2014 International Conference on Hardware/Software Codesign and System Synthesis, CODES+ISSS 2014*, 2014.
- [31] F. Imeson, A. Emtenan, S. Garg, and M. V Tripunitara, "Securing Computer Hardware Using 3D Integrated Circuit (IC) Technology and Split Manufacturing for Obfuscation," *USENIX Secur.*, 2013.
- [32] A. Smola, "Regression estimation with support vector learning machines," *Master's thesis, Tech. Univ. M unchen*, pp. 1–78, 1996.
- [33] J. A. K. Suykens, T. Van Gestel, J. De Brabanter, B. De Moor, and J. Vandewalle, "Basic Methods of Least Squares Support Vector Machines," in *Least Squares Support Vector Machines*, 2002.
- [34] R. K. H. Galvão *et al.*, "A variable elimination method to improve the parsimony of MLR models using the successive projections algorithm," *Chemom. Intell. Lab. Syst.*, vol. 92, no. 1, pp. 83–91, 2008.
- [35] L. Breiman, "Random Forests - Random Features, Tecnical Report 567, Statistic Department, University of California, Berkeley, (<https://www.stat.berkeley.edu/~breiman/random-forests.pdf>, 08.10.2018'de erişildi)," pp. 1–29, 1999.
- [36] Y. Freund, R. E. Schapire, and M. Hill, "Experiments with a New Boosting Algorithm Rooms f 2B-428 , 2A-424 g," 1996.
- [37] L. Breiman, "Bagging Predictors, URL: <https://link.springer.com/article/10.1007%2FBF00058655>," *Mach. Learn.*, vol. 24, no. 421, pp. 123–140, 1996.
- [38] A. Kulkarni, Y. Pino, and T. Mohsenin, "Adaptive real-time Trojan detection framework through machine learning," in *Proceedings of the 2016 IEEE International Symposium on Hardware Oriented Security and Trust, HOST 2016*, 2016.

- [39] F. Rosenblatt, "The perceptron: A probabilistic model for information storage and organization in the brain," *Psychol. Rev.*, vol. 65, no. 6, pp. 386–408, 1958.
- [40] S. Linnainmaa, "Taylor expansion of the accumulated rounding error," *Bit*, vol. 16, no. 2, pp. 146–160, 1976.
- [41] M. Riedmiller and H. Braun, "Direct adaptive method for faster backpropagation learning: The RPROP algorithm," *1993 IEEE Int. Conf. Neural Networks*, pp. 586–591, 1993.
- [42] R. Hecht-Nielsen, "Counterpropagation Networks.," vol. 26, no. 23, pp. 4979–4984, 1987.
- [43] J. S. R. Jang, "ANFIS: Adaptive-Neuro-Fuzzy Inference System," *IEEE Trans. Syst. Man Cybern.*, vol. 23, no. 3, pp. 665–685, 1993.
- [44] W. Melssen, R. Wehrens, and L. Buydens, "Supervised Kohonen networks for classification problems," *Chemom. Intell. Lab. Syst.*, vol. 83, no. 2, pp. 99–113, 2006.
- [45] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities.," *Proc. Natl. Acad. Sci. U. S. A.*, vol. 79, no. 8, pp. 2554–2558, 1982.
- [46] S. K. Pal, "NSankar 1992.pdf," *IEEE Transactions on Neural Networks*, vol. 3, no. 5, p. 683 696, 1992.
- [47] T. Kohonen, "The Self-Organizing Map," *Proc. IEEE*, vol. 78, no. 9, pp. 1464–1480, 1990.
- [48] G. Bin Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: Theory and applications," *Neurocomputing*, vol. 70, no. 1–3, pp. 489–501, 2006.
- [49] M. Gholamrezaei and K. Ghorbanian, "Rotated general regression neural network," *IEEE Int. Conf. Neural Networks - Conf. Proc.*, vol. 2, no. 6, pp. 1959–1964, 2007.
- [50] H. Mardani Kamali, K. Zamiri Azar, K. Gaj, H. Homayoun, and A. Sasan, "LUT-Lock: A novel LUT-based logic obfuscation for FPGA-Bitstream and ASIC-hardware protection," *Proc. IEEE Comput. Soc. Annu. Symp. VLSI, ISVLSI*, vol. 2018-July, pp. 405–410, 2018.
- [51] K. G. Liakos and G. Georgakilas, "Machine Learning for Hardware Trojan Detection : A Review," 2019, no. November.
- [52] H. M. Kamali, K. Z. Azar, H. Homayoun, and A. Sasan, "Full-Lock: Hard distributions of SAT instances for obfuscating circuits using fully configurable logic and routing blocks," *Proc. - Des. Autom. Conf.*, 2019.
- [53] K. Xiao, D. Forte, and M. Tehranipoor, "A novel built-in self-authentication technique to prevent inserting hardware trojans," *IEEE Trans. Comput. Des. Integr. Circuits Syst.*, 2014.
- [54] B. Khaleghi, A. Ahari, H. Asadi, and S. Bayat-Sarmadi, "FPGA-based protection scheme against hardware trojan horse insertion using dummy logic," *IEEE Embed. Syst. Lett.*, 2015.
- [55] F. J. Pineda, "Recurrent backpropagation networks," in *Chauvin, Yves (Ed); Rumelhart, David E. (Ed). (1995). Backpropagation: Theory, architectures, and applications. Developments in connectionist theory. (pp. 99 135). Hillsdale, NJ, England: Lawrence Erlbaum Associates, Inc. x, 561 pp.SEE BOOK*, 1995.
- [56] W. Balid, H. Tafish, and H. H. Refai, "Intelligent Vehicle Counting and Classification Sensor for Real-Time Traffic Surveillance," *IEEE Trans. Intell. Transp. Syst.*, 2018.
- [57] B. Coifman and M. Cassidy, "Vehicle reidentification and travel time measurement on congested freeways," *Transp. Res. Part A Policy Pract.*, 2002.
- [58] S. Y. Cheung, S. Coleri, B. Dundar, S. Ganesh, C. W. Tan, and P. Varaiya, "Traffic measurement and vehicle classification with single magnetic sensor," *Transp. Res. Rec.*, no. 1917, pp. 173–181, 2005.



- [59] L. E. Y. Mimbela and L. a Klein, "Summary Of Vehicle Detection And Surveillance Technologies Used In Intelligent Transportation Systems," *UC Berkeley Transp. Libr.*, 2000.
- [60] P. T. Martin, "Detector Technology Evaluation (MPC-03-154)," no. November, p. 140, 2003.
- [61] S. Cheung, "Traffic Surveillance by Wireless Sensor Networks : Final Report," *Calif. Path Progr. Inst. Transp. Stud. Univ. California, Berkeley*, vol. 1, no. January, p. 161, 2007.
- [62] J. P. Jodoin, G. A. Bilodeau, and N. Saunier, "Tracking All Road Users at Multimodal Urban Traffic Intersections," *IEEE Trans. Intell. Transp. Syst.*, 2016.
- [63] G. K. D. Saharidis, "Environmental Externalities Score: a new emission factor to model green vehicle routing problem," *Energy Syst.*, vol. 8, no. 4, pp. 673–691, 2017.
- [64] M. Mertens, A. Kerkweg, V. Grewe, and P. Jöckel, "Impact of road traffic emissions on tropospheric ozone in Europe for present day and future scenarios," vol. 18, pp. EPSC2016-10100, 2016.
- [65] J. Gulliver *et al.*, "Land use regression models for the oxidative potential of fine particles (PM<sub>2.5</sub>) in five European areas," *Environ. Res.*, 2018.
- [66] R. Smit, A. L. Brown, and Y. C. Chan, "Do air pollution emissions and fuel consumption models for roadways include the effects of congestion in the roadway traffic flow?," *Environ. Model. Softw.*, vol. 23, no. 10–11, pp. 1262–1270, 2008.
- [67] Y. Huang *et al.*, "Remote sensing of on-road vehicle emissions: Mechanism, applications and a case study from Hong Kong," *Atmos. Environ.*, vol. 182, pp. 58–74, 2018.
- [68] C. F. Lau *et al.*, "Evaluation of diesel fleet emissions and control policies from plume chasing measurements of on-road vehicles," *Atmos. Environ.*, 2015.
- [69] R. Smit, P. Kingston, D. H. Wainwright, and R. Tooker, "A tunnel study to validate motor vehicle emission prediction software in Australia," *Atmos. Environ.*, vol. 151, pp. 188–199, 2017.
- [70] R. Smit, L. Ntziachristos, and P. Boulter, "Validation of road vehicle and traffic emission models - A review and meta-analysis," *Atmospheric Environment*. 2010.
- [71] S. Abo-Qudais and H. A. Qdais, "Performance evaluation of vehicles emissions prediction models," *Clean Technol. Environ. Policy*, vol. 7, no. 4, pp. 279–284, 2005.
- [72] H. Rakha, K. Ahn, and A. Trani, "Comparison of MOBILE5a, MOBILE6, VT-MICRO, and CMEM models for estimating hot-stabilized light-duty gasoline vehicle emissions," *Can. J. Civ. Eng.*, vol. 30, no. 6, pp. 1010–1021, 2003.
- [73] R. Akcelik and M. Besley, "Operating cost, fuel consumption, and emission models in aaSIDRA and aaMOTION," *Conf. Aust. Institutes Transport Res.*, 2003.
- [74] C. Frey, N. Rouphail, A. Unal, and J. Colyar, "Measurement of On-Road Tailpipe CO, NO, and Hydrocarbon Emissions Using a Portable Instrument," *Annu. Meet. Air Waste Manag. Assoc.*, 2001.
- [75] M. Barth, F. An, and J. Norbeck, "Modal Emissions Modeling :," *Transp. Res. Rec.*, no. 6, pp. 81–88.
- [76] A. Jaworski, M. Mądziel, and K. Lejda, "Creating an emission model based on portable emission measurement system for the purpose of a roundabout," *Environ. Sci. Pollut. Res.*, vol. 26, no. 21, pp. 21641–21654, 2019.
- [77] M. Barth *et al.*, "Development of a Comprehensive Modal Emissions Model," *Natl. Coop. Highw. Res. Progr.*, no. April, 2000.
- [78] R. Smit and J. McBroom, "Use of microscopic simulation models to predict traffic emissions," *Road Transp. Res.*, 2009.
- [79] M. Rexeis and S. Hausberger, "Trend of vehicle emission levels until 2020 - Prognosis

based on current vehicle measurements and future emission legislation,” *Atmos. Environ.*, 2009.