



# ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

---

## Μηχανική Μάθηση στη Βιομηχανία Αυτοκινούμενων Οχημάτων

---

Επιμέλεια:  
Νικόλαος Μόκας

Επιβλέπων:  
Καθηγητής Π.Θ Γεώργιος Σταμούλης

*Μια διπλωματική εργασία που υποβλήθηκε για την εκπλήρωση των  
απαιτήσεων για το πτυχίο της Διπλωματικής Εργασίας  
στο*

**Τμήμα Ηλεκτρολόγων Μηχανικών και  
Μηχανικών Υπολογιστών  
Βόλος, 2022**



**UNIVERSITY OF THESSALY**

---

**Applications Of Machine Learning In  
Automotive Industry**

---

Author:  
**Nikolaos Mokas**

Supervisor:  
Professor **George Stamoulis**

*A thesis submitted in fulfillment of the requirements  
for the degree of Diploma Thesis*

*in the*

**Department of Electrical and Computer Engineering**

**Volos, 2022**

*“The only way to define your limits is by going beyond them.”*

*-Arthur C. Clarke*

This Thesis is dedicated to my family.

# ΥΠΕΥΘΥΝΗ ΔΗΛΩΣΗ ΠΕΡΙ ΑΚΑΔΗΜΑΪΚΗΣ ΔΕΟΝΤΟΛΟΓΙΑΣ ΚΑΙ ΠΝΕΥΜΑΤΙΚΩΝ ΔΙΚΑΙΩΜΑΤΩΝ

«Με πλήρη επίγνωση των συνεπειών του νόμου περί πνευματικών δικαιωμάτων, δηλώνω ρητά ότι η παρούσα διπλωματική εργασία, καθώς και τα ηλεκτρονικά αρχεία και πηγαίοι κώδικες που αναπτύχθηκαν ή τροποποιήθηκαν στα πλαίσια αυτής της εργασίας, αποτελεί αποκλειστικά προϊόν προσωπικής μου εργασίας, δεν προσβάλλει κάθε μορφής δικαιώματα διανοητικής ιδιοκτησίας, προσωπικότητας και προσωπικών δεδομένων τρίτων, δεν περιέχει έργα/εισφορές τρίτων για τα οποία απαιτείται άδεια των δημιουργών/δικαιούχων και δεν είναι προϊόν μερικής ή ολικής αντιγραφής, οι πηγές δε που χρησιμοποιήθηκαν περιορίζονται στις βιβλιογραφικές αναφορές και μόνον και πληρούν τους κανόνες της επιστημονικής παράθεσης. Τα σημεία όπου έχω χρησιμοποιήσει ιδέες, κείμενο, αρχεία ή/και πηγές άλλων συγγραφέων, αναφέρονται ευδιάκριτα στο κείμενο με την κατάλληλη παραπομπή και η σχετική αναφορά περιλαμβάνεται στο τμήμα των βιβλιογραφικών αναφορών με πλήρη περιγραφή. Αναλαμβάνω πλήρως, ατομικά και προσωπικά, όλες τις νομικές και διοικητικές συνέπειες που δύναται να προκύψουν στην περίπτωση κατά την οποία αποδειχθεί, διαχρονικά, ότι η εργασία αυτή ή τμήμα της δεν μου ανήκει διότι είναι προϊόν λογοκλοπής».

Ο Δηλών

Μόκας Νικόλαος

1/18/2022





## **Ευχαριστίες**

Σε αυτό το σημείο θα ήθελα να ευχαριστήσω θερμά των καθηγητή κ. Γεώργιο Σταμούλη για τις συμβουλές και την στήριξη που παρείχαν σε όλα τα στάδια της παρούσας διπλωματικής εργασίας. Παράλληλα θα ήθελα να ευχαριστήσω την οικογένεια μου και συγγενικά πρόσωπα για την υποστήριξη που μου πρόσφεραν καθ'όλη την διάρκεια των σπουδών μου.

## Περίληψη

Η γρήγορη εξέλιξη της αυτοκινητοβιομηχανίας μαζί με άλλες τεχνολογίες έχει οδηγήσει στη συνεργασία και την ανάπτυξη σε πολλούς τομείς. Προκειμένου να μειωθούν οι εκπομπές διοξειδίου του άνθρακα, οι χώρες σε όλο τον κόσμο κινούνται όλο και περισσότερο προς την παραγωγή ηλεκτρικών αυτοκινήτων. Οι βιομηχανίες των αυτοκινήτων βλέπουν μια απότομη μετάβαση από τις μηχανικές εφαρμογές στις ηλεκτρικές, ψηφιοποιώντας τις περισσότερες από τις λειτουργίες της. Οι ερευνητές είδαν την ευκαιρία να αναπτύξουν πιο εξελιγμένους αλγόριθμους και μαθηματικές μεθόδους σε μια μεγάλη ποικιλία εφαρμογών, όπως χαρακτηριστικά ασφαλείας, συνδεσιμότητας και συστήματα ψυχαγωγίας.

Η Τεχνητή Νοημοσύνη συνδυάζει μια τεράστια ποικιλία επιμέρους πεδίων. Υπάρχει ευρεία ανάπτυξη της τεχνητής νοημοσύνης σε παιχνίδια όπως το σκάκι, σε μαθηματικές θεωρίες, στη σύνθεση μουσικής και στη ιατρική διάγνωση. Αυτή η διπλωματική εργασία κάνει μια βουτιά στις μεθόδους μηχανικής μάθησης που χρησιμοποιούνται στα συστήματα ελέγχου, τον εντοπισμό και τον σχεδιασμό διαδρομής για οχήματα χωρίς οδηγό. Εξετάζουμε τεχνολογίες και αισθητήρες όπως RADAR, LiDAR, κάμερες και συνδυάζουμε τα δεδομένα με Sensor Fusion για να επιτύχουμε τοπική αντίληψη. Αργότερα, διερευνούμε την επιθυμία για πιο ακριβείς αλγόριθμους εντοπισμού και πώς μπορεί να επιτευχθεί χρησιμοποιώντας το SLAM που είναι σημαντικό για τον προγραμματισμό διαδρομής που θα συζητηθεί αργότερα με αλγόριθμους εύρεσης συντομότερης διαδρομής και μεθόδους βαθιάς μάθησης. Στο τέλος θα απεικονιστεί η συγχώνευση όλων των αναφερόμενων τεχνολογιών για την παροχή ενός λειτουργικού αυτοοδηγούμενου αυτοκινήτου, ένα επιστημονικό θαύμα που μελετάται από το 1900 και εφαρμόζεται στον πραγματικό κόσμο την τελευταία δεκαετία.



## **Abstract**

The fast paced evolution of the automotive industry along with other technologies has led to the cooperation and development across many fields. In order to reduce the carbon dioxide emissions, countries around the world, are increasingly moving towards electric car production. The industry of automobiles sees a steep transition from mechanical applications to electrical, digitalizing most of its functions. Researchers saw an opportunity to develop more sophisticated algorithms and mathematical methods in a wide variety of applications such as safety features, connectivity and infotainment systems.

Artificial Intelligence combines a huge variety of individual fields. There is widespread deployment of AI in games like chess, mathematical theories, composition of music and medical diagnosis. This diploma thesis takes a dive into the machine learning methods used in control systems, localization and path planning for driverless vehicles. We look into the technologies and sensors such as RADAR, LiDAR, cameras and combine the data with Sensor Fusion to achieve locale perception. Later, we explore the urge for more accurate localization algorithms and how it can be obtained using SLAM to apply into the later discussed route planning with shortest path finder algorithms and deep reinforced learning methods. The conclusion will illustrate the merging of all the mentioned technologies to provide an operational self-driving car, a scientific marvel being studied since the 1900's, applied in the real world.

# Περιεχόμενα

<b>Περίληψη</b>	<b>7</b>
<b>Abstract</b>	<b>9</b>
<b>Περιεχόμενα</b>	<b>1</b>
<b>Κεφάλαιο 1</b>	<b>3</b>
1.1 Κίνητρο	3
1.2 Στόχοι	4
1.3 Δομή Διπλωματικής Εργασίας	5
<b>Κεφάλαιο 2</b>	<b>9</b>
2.1 Κάμερες	9
2.1.1 Ανίχνευση εμποδίων και σηματοδοτών	10
2.1.2 Ανίχνευση λωρίδων κυκλοφορίας	13
2.1.3 Εκτίμηση αποστάσεων	17
2.2 LiDAR (Light and Range Detection)	19
2.2.1 Σχετικά με το LiDAR	20
2.2.2 3D ανίχνευση αντικειμένων	21
2.3 RADAR (Radio Detection and Ranging)	24
2.3.1 Διαφορές LiDAR και RADAR	24
2.3.2 Τεχνικές εκτίμησης ταχύτητας και εμποδίων	24
2.4 Sensor Fusion	27
2.4.1 Κάμερα με LIDAR	28
2.4.2 Κάμερα με RADAR	29

2.4.3 Κάμερα, LIDAR και RADAR	32
<b>Κεφάλαιο 3</b>	<b>34</b>
3.1 Ταυτόχρονο εντοπισμό και χαρτογράφηση (SLAM)	34
3.1.1 Παγκόσμιο Δορυφορικό Σύστημα Πλοήγησης (GNSS)	34
3.1.2 Το πρόβλημα με τα δορυφορικά συστήματα πλοήγησης	35
3.2 Αδρανειακή μονάδα μέτρησης	35
3.2.1 Φίλτρο Kalman	36
3.2.2 Visual - SLAM με χρήση IMU	37
<b>Κεφάλαιο 4</b>	<b>39</b>
4.1 Σχεδιασμός και επιλογή διαδρομής	39
4.1.1 Imitation Learning στον σχεδιασμό διαδρομής	40
4.1.2 Deep Reinforced Learning για την επιλογή διαδρομής	43
4.2 Προγραμματισμός συμπεριφοράς - Vehicle Controls	44
<b>Κεφάλαιο 5 - Συμπεράσματα</b>	<b>46</b>
<b>Βιβλιογραφία</b>	<b>47</b>

# Κεφάλαιο 1

## Εισαγωγή

### 1.1 Κίνητρο

Ανέκαθεν η ανθρωπότητα έψαχνε τρόπους να παραγάγει όσο περισσότερο έργο γίνεται καταναλώνοντας την λιγότερη δυνατή ενέργεια. Η βιομηχανική επανάσταση του 1765 σηματοδοτήσει τη πρώτη μηχανοποίηση της εργασίας, διεγείροντας το ερώτημα στους επιστήμονες για την επιτευξιμότητα των μηχανών να γίνουν αυτόνομες. Μία από τις μεθόδους που χρησιμοποιούνται για την επίλυση διαδικασιών, που για έναν άνθρωπο είναι αυτόματες αλλά εξαιρετικά περίπλοκες μηχανικά, είναι η τεχνητή νοημοσύνη [1]. Για αρκετές δεκαετίες η τεχνολογία της τεχνητής νοημοσύνης έχει προβληματίσει την επιστημονική κοινότητα όσον αφορά την ευστοχία στην επίλυση προβλημάτων. Πρόκειται για μία επιστημονική μέθοδο βασισμένη στην λειτουργία των νευρωνικών δικτύων του ανθρώπινου εγκεφάλου, στον μηχανισμό για την λήψη λογικών αποφάσεων ή και στο ανθρώπινο σύστημα συλλογής και επεξεργασίας πληροφοριών. Η επιτυχία ορίζεται στην ευστοχία κατασκευής ψηφιακών πρακτόρων ικανοί να διατηρούνται και να ανταποκρίνονται στις αλλαγές του περιβάλλοντος



δυναμικά χωρίς ανθρώπινη παρέμβαση. Υπάρχει πληθώρα τεχνικών που χρησιμοποιούνται σε αυτόματα συστήματα όπως είναι τα τεχνητά νευρωνικά δίκτυα, μηχανική μάθηση, πολυπρακτορικά συστήματα, συμβατικοί αλγόριθμοι σε καταναμημένα συστήματα ή συνδυασμός των προαναφερθέντων [6]. Η μηχανική μάθηση επικρατεί στους περισσότερους τομείς και ειδικά στην αυτοκινούμενη βιομηχανία με την οποία θα ασχοληθούμε.

Η ραγδαία ανάπτυξη της τεχνολογίας και η εύκολη πρόσβαση σε προσωπικά οχήματα έχει ως αποτέλεσμα κυκλοφοριακή συμφόρηση, αυξημένο αριθμό ατυχημάτων και ρύπων στο περιβάλλον. Το 24% των εκπομπών διοξειδίου του άνθρακα σε παγκόσμια κλίμακα οφείλεται στα μέσα μεταφοράς [9]. Τουλάχιστον το 90% των αυτοκινητιστικών ατυχημάτων οφείλεται σε ανθρώπινα λάθη. Το μεγαλύτερο ποσοστό ατυχημάτων δεν ευθύνεται η επήρεια ουσιών αλλά ο περιορισμός των ανθρώπινων δυνατοτήτων, όπως τα αργά αντανακλαστικά ή η απόσπαση προσοχής [8]. Γνωρίζοντας αυτά τα προβλήματα, εταιρείες-κολοσσοί όπως η Google, θυγατρική της Waymo, Tesla, Apple και πλέον συμβατικές αυτοκινητιστικές εταιρίες όπως Kia-Hyundai, Ford και Audi, συμβάλλουν στην ανάπτυξη αυτόνομων οχημάτων τα οποία θα έχουν ισχυρή επίδραση στην ανθρώπινη ασφάλεια σε αστικές ζώνες και στα περιβαλλοντικά προβλήματα που προκαλούνται από τον ανθρώπινο παράγοντα [7].

## 1.2 Στόχοι

Ο σκοπός της διπλωματικής εργασίας είναι να εξερευνήσει τις τεχνικές τεχνητής νοημοσύνης που χρησιμοποιούνται στην βιομηχανία παραγωγής αυτόνομων οχημάτων που έχουν ως σκοπό την ασφάλεια την ανθρώπινης ζωής, την καταπολέμηση της κλιματικής αλλαγής και την αποσυμφόρηση των πόλεων. Θα αναλυθεί η μεθοδολογία της μηχανικής όρασης κάνοντας χρήση εξειδικευμένων αισθητήρων και εικονοληπτικών μηχανών, παραχωρώντας στο όχημα την αντίληψη του χώρου. Στην συνέχεια θα προβάλλουμε την τεχνική της τοπικοποίησης με ακρίβεια εκατοστών σε αντίθεση με το GPS που έχει αποκλίσεις μέτρων σε ορισμένες συνθήκες,

σημαντικό για την προσαρμογή της συμπεριφοράς του οχήματος την οποία θα εξερευνήσουμε αργότερα. Τέλος, αφού αντιλαμβανόμαστε τον χώρο μαζί με τα εμπόδια του και γνωρίζουμε με ακρίβεια την θέση μας στον κόσμο, θα δούμε πως προχωράμε στον σχεδιασμό πορείας και προγραμματισμό συμπεριφοράς.

### 1.3 Δομή Διπλωματικής Εργασίας

#### Κεφάλαιο 2: Τεχνολογίες οπτικής αντίληψης

Η οπτική αντίληψη είναι ο πυλώνας ενός self-driving οχήματος και χρησιμοποιούνται τεχνικές μηχανικής μάθησης για την αναγνώριση εμποδίων, γραμμών κυκλοφορίας, σηματοδοτών, φαναριών και ανθρώπων. Για την αποπεράτωση αυτών γίνεται χρήση οργάνων, ικανά για την ανίχνευση αντικειμένων με εικονοληπτική μέθοδο, με υπερηχητικά συστήματα ή χρήση ηλεκτρομαγνητικής ακτινοβολίας [2]. Πιο συγκεκριμένα θα μιλήσουμε για:

- Κάμερες  
Αποτελεί την πιο ελκυστική επιλογή για τις βιομηχανίες αυτοκινήτων στον τομέα των αυτόνομων οχημάτων. Χρησιμοποιούνται κυρίως για την διάκριση διαχωριστικών γραμμών στο οδόστρωμα, φωτεινούς σηματοδότες και αναγνώριση ανθρώπινων ή ζωικών μορφών.
- LiDAR (Light Detection and Ranging) [11]

Πρόκειται για μία σύγχρονη μέθοδος προσδιορισμού διαστάσεων και απόστασης αντικειμένων χρησιμοποιώντας ηλεκτρομαγνητική ακτινοβολία. Συχνή

εκμετάλλευση της τεχνολογίας γίνεται για την ακριβή χαρτογράφηση ή απεικόνιση περιοχών σε περιβάλλον τριών διαστάσεων.

- RADAR (Radio Detection and Ranging) and SONAR (Sound Navigation and Ranging)

Το RADAR [12] έχει ίδια λειτουργία με το LiDAR με την διαφορά ότι το RADAR εκπέμπει ραδιοκύματα σε αντίθεση με το LiDAR που εκπέμπει ηλεκτρομαγνητική ακτινοβολία στο υπέρυθρο φάσμα. Προσδίδει μεγαλύτερη ακτίνα τοπογράφησης αλλά με μικρότερη ακρίβεια.

- Sensor Fusion

Τα παραπάνω όργανα που εγκαθίστανται στα οχήματα έχουν ως σκοπό την προσομοίωση της ανθρώπινης όρασης. Κάθε όργανο μας παρέχει δεδομένα που συγχωνεύονται για να δημιουργήσουν μια αποτελεσματική τοπογράφηση με υψηλή ακρίβεια [13].

### Κεφάλαιο 3: Τοπικοποίηση

Την εύρεση τοποθεσίας με μεγάλη ευστοχία και το πρώτο σύστημα παγκόσμιας δορυφορικής πλοήγησης την έφερε ο Αμερικάνικος στρατός με ένα αστερισμό δορυφόρων με την ονομασία GPS το οποίο χρησιμοποιείται ακόμα και σήμερα [16]. Με καθαρό ουρανό, τα συστήματα δορυφορικής πλοήγησης έχουν απόκλιση μέχρι και 0.1 μέτρα. Τα δεδομένα όμως γίνονται πιο δυσμενή όταν χάνεται η άμεση επαφή με τον δορυφόρο, με τις απώλειες να αγγίζουν τα 4 μέτρα, αποδεικνύοντας πως αυτή η μέθοδος δεν είναι όσο αποτελεσματική

απαιτείται για να καλύψει τις ανάγκες ακριβής τοποθεσίας ενός αυτόνομου οχήματος [17]. Για την επίλυση του προβλήματος οι εταιρείες έχουν αναπτύξει μεθόδους όπως είναι τα:

- GNSS και INS

Στα σύγχρονα οχήματα τα συμβατικά δορυφορικά συστήματα πλοήγησης χρησιμοποιούν όργανα ταχυμετρίας και προσανατολισμού για πιο εύκολη και ακριβή προσέγγιση της τοποθεσίας του. Ονομάζονται αδρανειακά συστήματα πλοήγησης (INS, Inertial Navigation System) και χρησιμοποιούνται στην υποθαλάσσια και αεροναυτιλιακή πλοήγηση [19].

- SLAM

Η ταυτόχρονη χαρτογράφηση και εντοπισμού είναι τεχνολογία με ανιχνευτές που καλύπτει τις ανάγκες της τοποθέτησης [20] αλλά και χαρτογράφησης όταν τα συμβατικά μέσα δεν είναι αποτελεσματικά [16], [17].

Σε αυτό το κεφάλαιο θα αναπτύξουμε πως η μηχανική μάθηση δένει αυτές τις τεχνολογίες μεταξύ τους, προσδίδοντας την ακριβή θέση του οχήματος, που απαιτείται για τον σχεδιασμό διαδρομής, το οποίο θέμα θα αναπτυχθεί παρακάτω.

#### Κεφάλαιο 4: Σχεδιασμός διαδρομής και προγραμματισμός συμπεριφοράς

Αν η οπτική και τοποθετική αντίληψη είναι οι «αισθήσεις» ενός αυτόνομου οχήματος, τότε τα επόμενα δύο κεφάλαια, ο προγραμματισμός αποφάσεων και συμπεριφοράς, είναι ο «εγκέφαλος».

Για αστικές ανάγκες, η επιλογή διαδρομής από την αφετηρία έως τον τελικό προορισμό αποτελεί από τις πιο απλές διαδικασίες στον κόσμο των αυτόνομων οχημάτων αφού

μπορεί γίνει χρήση αλγορίθμων εύρεσης συντομότερων διαδρομών, όπως είναι ο αλγόριθμος A\* [22]. Υπάρχουν και μέθοδοι τεχνητής νοημοσύνης πιθανολογικής φύσης με την πιο δημοφιλή μέθοδο, με παραλλαγές, να είναι η διαδικασία στοχαστικού ελέγχου διακριτού χρόνου Markov (MDP) [21]. Όσο για τον προγραμματισμό συμπεριφοράς, είναι το κυριότερο στοιχείο στον τομέα των αυτόνομων οχημάτων. Από το πόσο ώθηση θα δοθεί ή πόσο θα στρίψει το τιμόνι μέχρι τον τρόπο αποφυγής εμποδίων ή και άλλων οχημάτων [23]. Θα αναλυθούν τεχνικές μηχανικής μάθησης, όπως βαθιά μάθηση ενίσχυσης (DRL) και μάθηση με απομίμηση (IL) που έχουν σκοπό να μιμηθούν τον ανθρώπινο τρόπο λήψης αποφάσεων σε πολύπλοκα σενάρια [24].

## Κεφάλαιο 5: Συμπεράσματα

# Κεφάλαιο 2

## Τεχνολογίες οπτικής αντίληψης

### 2.1 Κάμερες

Τα εικονοληπτικά σύστημα είναι τα μάτια των αυτόνομων οχημάτων. Είναι όργανα που σε δυσμενείς καιρικές συνθήκες υπολειτουργούν αλλά είναι αναγκαία αφού η αναγνώριση σημάτων, λωρίδων κυκλοφορίας και στάσιμων πεζών είναι αδύνατη μόνο με υπερηχητικούς και ηλεκτρομαγνητικούς αισθητήρες. Βρίσκονται συνήθως στο μπροστινό μέρος του οχήματος ή και στην οροφή, προσφέροντας περιφερειακή όραση [25] όπως στην εικόνα fig 2.1.

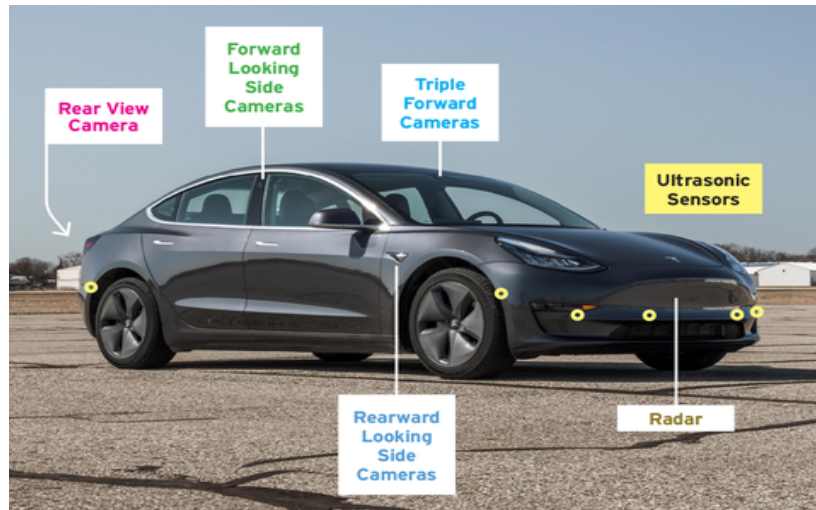


Figure 2.1: Θέσεις καμερών και αισθητήρων στο Tesla 3 [26]

### 2.1.1 Ανίχνευση εμποδίων και σηματοδοτών

Για την επίλυση προβλημάτων ταυτοποίησης αντικειμένων τα τελευταία χρόνια έχει γίνει δημοφιλή η χρήση των συνελκτικών νευρωνικών δικτύων (CNNs) [27]. Αλγόριθμοι όπως YOLO [29], SSD [30], RetinaNet [29] και EfficientDet προτιμούνται στην ανάπτυξη αυτόνομων οχημάτων, αφού είναι πρωτοπόροι στις δύο πιο σημαντικές παραμέτρους: την ευστοχία και την ταχύτητα αναγνώρισης. Στο προσκήνιο είναι ο αλγόριθμος της Google AI με την ονομασία «EfficientDet» [28], και το δίκτυο «YOLO Net» το οποίο παίρνει μέρος και σε ιατρικές εφαρμογές. Κατατάσσονται στην κατηγορία των one-stage detector, δηλαδή κάνουν την ανίχνευση αντικειμένων και την ταυτοποίηση σε ένα νευρωνικό δίκτυο, σε αντίθεση με την κατηγορία αλγορίθμων two-stage detector που διαχωρίζει αυτές τις δύο διαδικασίες όπως φαίνεται στο σχεδιαστικό διάγραμμα fig 2.2. Οι one-stage detectors είναι ελάχιστα λιγότερο ακριβείς σε σύγκριση με την δεύτερη κατηγορία αλλά επιλέγονται χάρη στην αξιοσημείωτη διαφορά στην κατανάλωση πόρων [31].

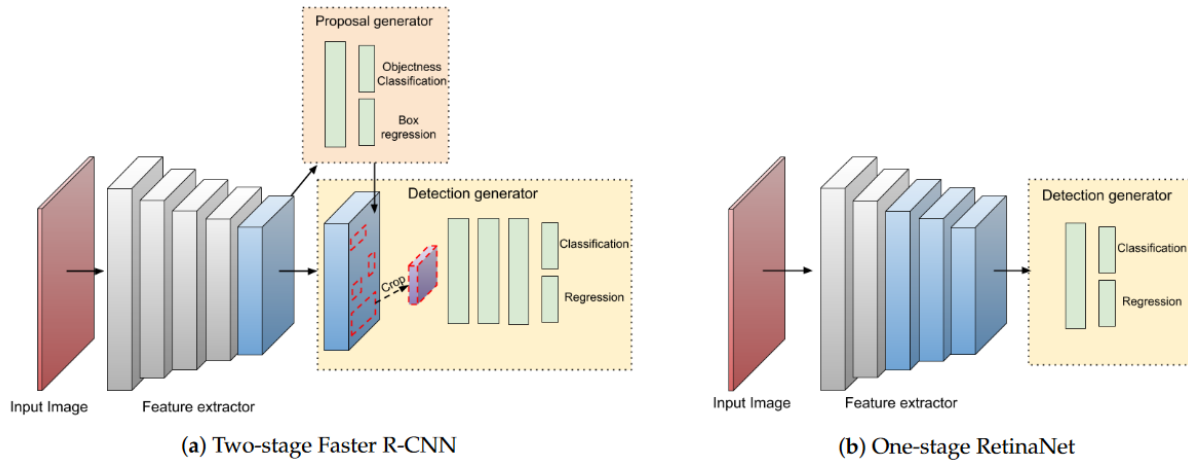


Figure 2.2 Αρχιτεκτονικές one-stage και two-stage ανιχνευτών αντικειμένων [31].

Οι αλγόριθμοι χρησιμοποιούν την ίδια βασική μεθοδολογία ως προς την εκπαίδευση του συστήματος. Ξεκινάνε από την ομαδοποίηση των δεδομένων σε μία συγκεκριμένη κλίμακα μεγέθους και ανάλυσης και συνεχίζουν με την εκπαίδευση του νευρωνικού δικτύου, τροφοδοτώντας το με ήδη ταυτοποιημένα αντικείμενα, ώστε να είναι σε θέση να αναγνωρίζει τις κλάσεις που έχουν δοθεί, δηλαδή σηματοδότες και εμπόδια όπως άνθρωποι, ζώα και οχήματα. Το τελικό αποτέλεσμα είναι η κατηγοριοποίηση και η τοποθεσία των αντικειμένων προς αναζήτηση, όπως φαίνεται στο Figure 2.3, μοντέλο του αλγορίθμου «YOLO» [32].






Figure 2.3: YOLO Αλγόριθμος όπου (1) αλλάζει το μέγεθος της εισαγόμενης εικόνας, (2) επεξεργάζεται από το συνελκτικό νευρωνικό δίκτυο και (3) υπογράφει τα ταυτοποιημένα αντικείμενα [33].

Η διαδικασία αναγνώρισης ξεκινάει από την διαίρεση της εικόνας σε ένα πλέγμα κελιών διάσταση  $S \times S$ . Κάθε κελί μπορεί να προβλέψει  $B$  αριθμό αντικειμένων και την πιθανότητα αξιοπιστίας. Η πιθανότητα αξιοπιστίας υπολογίζεται από το γινόμενο της πιθανότητας εμφάνισης του αντικειμένου στο συγκεκριμένο κελί με τον δείκτη  $IoU$  (Intersection over Union) που υπολογίζεται με την προβλεπόμενη περιοχή.

$$Conf(Obj) = Pr(Obj) * IOU^{truth}$$

Το τελικό αποτέλεσμα όπως απεικονίζεται στο fig 2.4, σε μορφή πίνακα, από κάθε εικόνα μετά την επεξεργασία της μέσω του νευρωνικού δικτύου είναι:

$$S \times S \times B \times [P_c, P_x, P_y, P_h, P_w, Conf(obj)]$$

Όπου  $P_c$  η πιθανότητα ύπαρξης αντικειμένου στο δεδομένο κελί,  $P_x$  και  $P_y$  οι συντεταγμένες του κέντρου του αντικειμένου και  $P_h, P_w$  οι διαστάσεις του αντικειμένου (ύψος και πλάτος) [32], [33].





Figure 2.4: Διαδικασία αναγνώρισης πεζών [32].

### 2.1.2 Ανίχνευση λωρίδων κυκλοφορίας

Σαν πρώτη σκέψη θα μπορούσε το πρόβλημα ανίχνευσης διαχωριστικών λωρίδων να θεωρηθεί απλό και να λυθεί με τις ίδιες μεθόδους που χρησιμοποιούνται στην ταυτοποίηση εμποδίων. Το κοινό χαρακτηριστικό των εμποδίων που αναλύθηκαν στο προηγούμενο τμήμα, είναι ότι οι κλάσεις προς αναγνώριση είναι συμπαγείς, κάτι που δεν ισχύει για λωρίδες. Οπότε για την επίλυση του προβλήματος η επεξεργασία γίνεται μέσα σε ένα νευρωνικό δίκτυο για κάθε pixel της εικόνας, ανιχνεύοντας και προβλέποντας την τροχιά των λωρίδων κυκλοφορίας. Για την ευκολότερη εκπόνηση της διεργασίας, γίνεται αλλαγή χρωμάτων της φωτογραφίας ώστε να εξαλειφθεί ο θόρυβος, ανεβάζοντας έτσι τον βαθμό ακριβείας της μεθόδου [36]. Για παράδειγμα, είναι γνωστό πως οι λωρίδες δεν είναι πουθενά μπλε ή πράσινες. Στις περισσότερες χώρες είναι είτε λευκό, είτε κίτρινο χρώμα και σε σπάνιες περιπτώσεις κόκκινο.

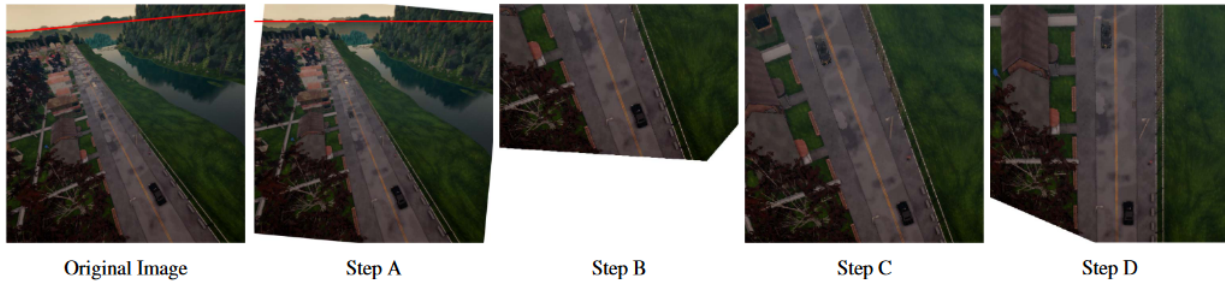
Κάθε μέθοδος προσαρμόζει την παραμόρφωση εικόνας στα μέτρα του νευρωνικού δικτύου του όπως στο παρακάτω παράδειγμα (fig 2.5).



*Figure 2.5: Επεξεργασία εικόνων πριν την χρήση της για την ανίχνευση λωρίδων. (α) Αρχικές εικόνες, (β) Μετά από χρωματική κατάτμηση, (γ) Κλίμακα του γκρι [34].*

Το νευρωνικό δίκτυο LaneNet [35], μετά από end-to-end εκπαίδευση, παράγει την ίδια φωτογραφία με τονισμένες λωρίδες, προβλέποντας και την πορεία τους και όταν υπάρχουν εμπόδια, όπως ένα διερχόμενο όχημα. Πρόκειται δηλαδή για μία συλλογή pixel που δηλώνουν την προβλεπόμενη θέση των λωρίδων κυκλοφορίας. Η δυσκολία στη διαδικασία είναι στην καμπυλότητα των γραμμών, η οποία επίλυση της προέρχεται μετατρέποντας την ληφθέν

φωτογραφία από μπροστινή όψη, σε ψευτο-εναέρια πανοραμική (fig 2.6). Με αυτό τον τρόπο οι καμπυλότητες σχεδόν μηδενίζονται, κάνοντας το πρόβλημα γραμμικό.



*Figure 2.6: Μετατροπή εικόνας από μπροστινή οπτική γωνία σε bird-eye όψη [37].*

Για την ταυτοποίηση ευθειών χρησιμοποιείται η μετατροπή του Hough. Μία ευθεία σε πολικές συντεταγμένες ορίζεται από την εξίσωση:

$$\rho = x \sin \theta + y \cos \theta$$

Από κάθε σημείο  $x, y$  μπορούν να περάσουν άπειρες ευθείες. Σε έναν παραμετρικό χώρο δύο διαστάσεων, ή αλλιώς «Hough space», σχηματίζεται μια καμπύλη με όλες τις πιθανές ευθείες που περνάνε από κάποιο σημείο. Παρόλα αυτά μόνο μια ευθεία μπορεί να ενώσει δύο σημεία όπως διακρίνεται στις γραφικές παραστάσεις του fig 2.7. Σε αυτή την περίπτωση έχουμε πολλά σημεία οπότε θα πρέπει να επιλεγεί η πιο εύστοχη ευθεία [38].




Figure 2.7: (a) Ένας αριθμός συγγραμμικών σημείων, (b) σύνολο ευθειών για κάθε σημείο με παράμετρο την κλίση της κάθε ευθείας, (c) σύνολο ημιτονοειδών καμπύλων των ευθειών από το (b) με παραμετροποίηση πολικών συντεταγμένων  $\rho - \theta$ . [38]

Παράγεται ένα γράφημα για κάθε pixel όπου ανήκει σε λωρίδα, παραμετροποιημένο με πολικές συντεταγμένες και διασπάται σε ένα πλέγμα με κελιά, με μηδενικό βάρος για κάθε κελί. Όταν μία καμπύλη διασταυρώνεται με κάποια άλλη στο συγκεκριμένο κελί, αυξάνεται κατά ένα. Το κελί με το μεγαλύτερο βάρος, άρα και τις περισσότερες διασταυρώσεις δηλώνει την πιο εύστοχη ευθεία. Παρακάτω απεικονίζεται το αποτέλεσμα της μετατροπή Hough (fig 2.8).

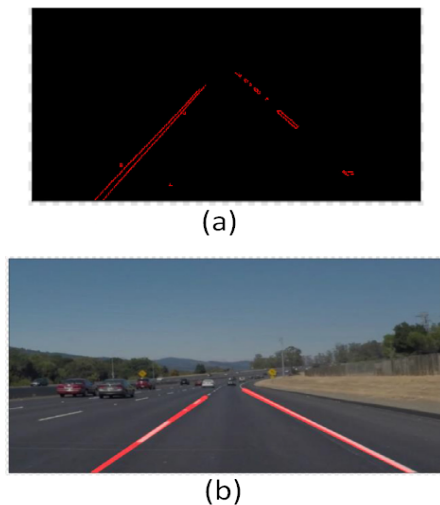


Figure 2.8: (a) Ευθείες με μετατροπή Hough, (b) αποτέλεσμα ταυτοποίησης [36]

### 2.1.3 Εκτίμηση αποστάσεων

Η προβολή μιας φωτογραφίας είναι εξ'ορισμού σε δύο διαστάσεις με αποτέλεσμα να μην υπάρχουν πληροφορίες βάθους για τα αντικείμενα που απεικονίζονται. Η απάντηση για το πρόβλημα της εκτίμησης αποστάσεων με εικονοληπτικά μέσα βρίσκεται στην φύση. Ολά τα ζώα, και προφανώς και ο άνθρωπος, έχουν δύο μάτια, ακριβώς για αυτό τον σκοπό. Με χρήση γραμμικής άλγεβρας και δύο καμερών (fig 2.9), η μια δίπλα στην άλλη με τις κατάλληλες ρυθμίσεις [39], πετυχαίνουμε τον υπολογισμό απόστασης εμποδίων που έχουν ταυτοποιηθεί ήδη, με τις τεχνικές που αναλύθηκαν στο 2.1.1.





Figure 2.9: Σχηματικό διάγραμμα από δύο κάμερες τοποθετημένες παράλληλα σε απόσταση  $b$ .

Έστω  $T$  σημείο που μας ενδιαφέρει, είτε κάποιο εμπόδιο στο δρόμο, είτε σηματοδότης, είτε άλλο όχημα. Το σημείο θα βρίσκεται σε απόσταση  $x_1$  από την αριστερή κάμερα, και  $x_2$  από την δεξιά. Η απόσταση του αντικειμένου ορίζεται από τον τύπο:

$$D = \frac{bx_0}{2 \tan \left( \frac{\theta_0}{2} + \varphi \right) (x_2 - x_1)}$$

Οπού  $D$  η απόσταση που αναζητούμε,  $b$  η απόσταση μεταξύ των δύο καμερών,  $x_0$  το πλάτος την φωτογραφίας σε πλάτος,  $\theta_0$  η κοινή γωνία λήψης,  $\varphi$  οι διορθώσεις ευθυγράμμισης των δύο καμερών και  $x_1, x_2$  η ανομοιότητα των δύο φωτογραφιών σε pixel [40].

Σε ένα νευρωνικό σύστημα ταυτοποίησης εμποδίων με δύο κάμερες το αποτέλεσμα φαίνεται στο *Figure 2.10*.



*Figure 2.10: Stereo-camera της Nvidia με αναγνώριση πεζών/οχημάτων και εκτίμηση αποστάσεων [41].*

Παρά την απλότητα και τις χαμηλές υπολογιστικές ανάγκες της stereo-vision μεθόδου, τα σφάλματα μπορούν να αγγίξουν και το ποσοστό του 7%, κάτι που καθιστά την διαδικασία εκτίμησης με δύο κάμερες αναξιόπιστη [39].

## 2.2 LiDAR (Light and Range Detection)

Η στέρεο όραση με κάμερες σε συνδυασμό με αλγορίθμους μηχανικής μάθησης έχει αποδειχθεί η πιο φερέγγυα μέθοδος για την ταυτοποίηση εμποδίων, αλλά όχι για την λήψη άλλων αναγκαίων πληροφοριών όπως την απόσταση ή την ταχύτητα τους. Επιπλέον, σε μεγάλες αποστάσεις υπάρχει πολύ «θόρυβος» στις πληροφορίες που παρέχει ένα εικονοληπτικό μέσο [42]. Για αυτό σε ένα αυτόνομο κινούμενο σύστημα έχουν εισαχθεί επιπλέον εργαλεία που συλλέγουν τις ζητούμενες πληροφορίες, συμβάλλοντας έτσι και στην τοπογραφία της περιοχής γύρω από το όχημα. Ένα από αυτά τα εργαλεία-όργανα είναι το LiDAR.



## 2.2.1 Σχετικά με το LiDAR

Πρόκειται για ένα σύστημα εκπομπής ακτίνων λέιζερ, το οποίο μετράει τον χρόνο που χρειάζεται μια ακτίνα να χτυπήσει κάποιο αντικείμενο και να γυρίσει πίσω (fig 2.11), υπολογίζοντας έτσι την ακριβή απόσταση του αντικειμένου, με τον τύπο:

$$Distance = \frac{TimeOfTravel * SpeedOfLight}{2}$$




Figure 2.11: Σχεδιαστικό διάγραμμα παλμικού συστήματος LiDAR [43].

Λόγω του τρόπου λειτουργίας τους, σε αντίθεση με τις κάμερες, η αποτελεσματικότητά τους δεν επηρεάζεται από τις συνθήκες φωτισμού αλλά σε περιπτώσεις άστατου καιρού, όπως βροχή και


ομίχλη, τα δεδομένα που λαμβάνει είναι διεφθαρμένα [44]. Ένα αυτόνομο όχημα έχει απαιτητική ευστοχία αναγνώρισης και ταυτοποίησης εμποδίων, για αυτό και το LiDAR συνεργάζεται με άλλα συστήματα ανίχνευσης και δεν είναι αυτόνομο. Υπάρχουν δύο είδη LiDAR, τα μηχανικά και τα σταθερού τύπου. Τα μηχανικά περιέχουν κινούμενα μέλη, συνήθως περιστρεφόμενους εσωτερικούς καθρέπτες ανακατεύθυνσης ακτίνων, και έχουν την δυνατότητα για πλήρη σφαιρική εικόνα των 360 μοιρών και αναγκαστικά πρέπει να τοποθετηθούν στην οροφή των οχημάτων. Στην βιομηχανία αυτοκινούμενων οχημάτων προτιμάται η εγκατάσταση πολλαπλών ανιχνευτών σταθερού τύπου λόγω της διακριτικότητας τους και των εύκολων τεχνικών απόκρυψης τους από το γυμνό μάτι.

### 2.2.2 3D ανίχνευση αντικειμένων

Όπως οι κάμερες, οι ανιχνευτές LiDAR σταθερού τύπου έχουν ένα οπτικό πεδίο  $\varphi_{\max}$  στον οριζόντιο άξονα και έναν αριθμό ομάδων πομπών ακτινοβολίας σε διάφορες γωνίες  $\omega$  στον κάθετο άξονα. Σύμφωνα με το [44], γνωρίζοντας αυτές τις γωνίες, αν κάποια ακτίνα επιστρέψει, τότε το σύστημα καταγράφει το σημείο αντανάκλασης σε X, Y, Z συντεταγμένες.

$$x = d * \cos(\omega) * \cos(\varphi) \quad y = d * \cos(\omega) * \sin(\varphi) \quad z = d * \sin(\omega)$$

Όπου d η απόσταση,  $\omega$  η γωνία στον κάθετο άξονα και  $\varphi$  η γωνία στον οριζόντιο.



*Figure 2.12: Ακατέργαστα δεδομένα από σύστημα LiDAR Velodyne 16 [45].*

Με μια συλλογή σημείων, όπως φαίνεται στο fig 2.12, και την απεικόνιση τους σε ένα τρισδιάστατο επίπεδο, ένας παρατηρητής θα μπορούσε να ξεχωρίσει την μορφή ενός ανθρώπου με την μορφή ενός οχήματος ή ενός κτιρίου. Ένας αλγόριθμος ταυτοποίησης με χρήση σημείων, θα πρέπει πρώτα να κάνει μία ομαδοποίηση των σημείων, πριν προχωρήσει στην αναγνώριση του εμποδίου.

Οι μέθοδοι βασισμένες σε «σύννεφα» σημείων έχουν αποδειχθεί πιο ακριβείς και αποτελεσματικές από τις υπόλοιπες, όπως την 3-D εγχομετρική αναπαράσταση και την προβολή σε 2-D. Το νευρωνικό δίκτυο PointNet++ [47], του οποίου η αρχιτεκτονική φαίνεται στο fig 2.13, κάνει χωρική ανάλυση για κάθε σημείο, μέσω του πολυστρωματικού perceptron (MLP) του, και συγκεντρώνει τα χαρακτηριστικά του. Σε ένα παράλληλο νευρωνικό δίκτυο, γίνεται η εκπαίδευση και η ανάλυση για την ταυτοποίηση των αντικειμένων.

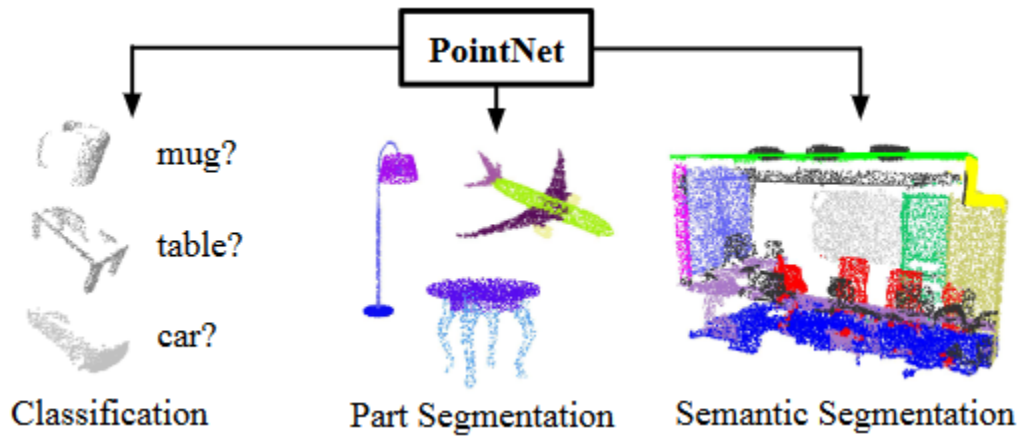


Figure 2.13: Αρχιτεκτονική δικτύου PointNet [46].

Αφού ολοκληρωθεί η ομαδοποίηση των αντικειμένων, η αναγνώριση και η ταυτοποίηση τους γίνεται με τις ίδιες τεχνικές που χρησιμοποιούνται από τα νευρωνικά δίκτυα αναγνώρισης εμποδίων με κάμερες.

## 2.3 RADAR (Radio Detection and Ranging)

Όπως οι κάμερες, έτσι και το LiDAR έχει αδύναμίες σε τομείς που είναι σημαντικοί για την αποτελεσματικότητα της διαδικασίας της αυτόνομης οδήγησης. Η επιστημονική και τεχνολογική κοινότητα έφερε στο προσκήνιο ένα όργανο που χρησιμοποιήθηκε στον Δεύτερο Παγκόσμιο Πόλεμο για την ανίχνευση αεροσκαφών, το RADAR[48]. Πλέον οι δυνατότητες του εκμεταλλεύονται από στρατιωτικές υπηρεσίες, αστρονομία και χαρτογραφικές τεχνικές.

### 2.3.1 Διαφορές LiDAR και RADAR

Το πάνω χέρι στην ακρίβεια σε μεγάλες αποστάσεις έχουν τα σύγχρονα RADAR αφού δεν επηρεάζονται από καιρικά φαινόμενα όπως ομίχλη και βροχή αφού γίνεται χρήση σημάτων πολύ μικρότερης συχνότητας. Έχουν την δυνατότητα ανίχνευσης αντικειμένων μέχρι και 70 μέτρα και γωνία 30 μοιρών από το όχημα, με μικρότερη όμως ακρίβεια όσο η απόσταση αυξάνεται [49]. Η αναφορά γίνεται σε οχήματα μαζικής παραγωγής οπότε το κόστος των αισθητήρων σε επίπεδο βιομηχανίας είναι κρίσιμο, κάτι που κάνει τους αισθητήρες RADAR νικητές, σε σύγκριση με τους LIDAR. Η βασική χρήση του RADAR είναι η εκτίμηση της ταχύτητας των γύρω αντικειμένων, βασισμένη στο φαινόμενο του Doppler, βασικά εργαλεία για συστήματα LCA (Lane Change Assistance) και AEB (Emergency Braking Systems) [50].

### 2.3.2 Τεχνικές εκτίμησης ταχύτητας και εμποδίων

Όταν ένα RADAR εκπέμπει ένα ηλεκτρομαγνητικό σήμα σε έναν στόχο, το σήμα αλληλεπιδρά με την επιφάνεια του στόχου και επιστρέφει στο ραντάρ. Οι αλλαγές στις ιδιότητες του σήματος που επιστρέφει, αντικατοπτρίζουν τα χαρακτηριστικά του στόχου προς ενδιαφέρον. Όταν ο

στόχος κινείται με σταθερή ταχύτητα, η συχνότητα του επιστρεφόμενου σήματος θα μετατοπιστεί. Αυτό είναι γνωστό ως το φαινόμενο Doppler [51].

Όταν η πηγή και στόχος κινούνται (fig 2.14), τότε ο υπολογισμός της ταχύτητας γίνεται ως εξής:

$$f' = \frac{1}{\gamma} \frac{1 \pm \frac{v_o \cos \theta_o}{c}}{1 \mp \frac{v_s \cos \theta_s}{c}} f$$

Όπου  $\gamma = 1/(1 - v^2/c^2)^{1/2}$ , ένας παράγοντας που αντιπροσωπεύει τη σχετικιστική χρονική διαστολή και  $v_o, \theta_o, v_s, \theta_s$  η ταχύτητες και γωνίες μεταξύ του στόχου και της πηγής αντίστοιχα.




Figure 2.14: Φαινόμενο Doppler όταν ο στόχος και η πηγή βρίσκονται εν κινήση [52].

Γίνεται αποδιαμόρφωση του επιστρεφόμενου σήματος και ανάλογα με την αλλαγή της φάσης υπολογίζεται η ταχύτητα του αντικειμένου.

$$v = \frac{c}{2f} \hat{f}_D$$

Με  $f_D$  το ληφθέν σήμα μετά από αποδιαμόρφωση,  $c$  η ταχύτητα του φωτός που ταξιδεύουν τα ηλεκτρομαγνητικά κύματα του ανιχνευτή και  $f$  η συχνότητα πομπού [52].

Πλέον χρησιμοποιείται μια πιο εξειδικευμένη μορφή του φαινομένου Doppler ονόματι Micro-Doppler Effect[52], που επικεντρώνεται στις μικρο-μετατοπίσεις αντικειμένων. Το ηλεκτρομαγνητικό κύμα που επιστρέφει το σώμα ενός ελικοπτέρου είναι διαφορετικό από αυτό που θα επιστρέψουν οι έλικες του. Το ίδιο ισχύει και για έναν πεζό που περνάει το δρόμο, άλλη ταχύτητα έχει το σώμα και άλλη ταχύτητα το πόδι του καθώς κάνει βήματα. Η αρθρωτή κίνηση των χεριών και των ποδιών προκαλεί κηλίδες κατά μήκος των γραμμών συχνοτήτων Doppler όπως απεικονίζεται στο figure 2.15.

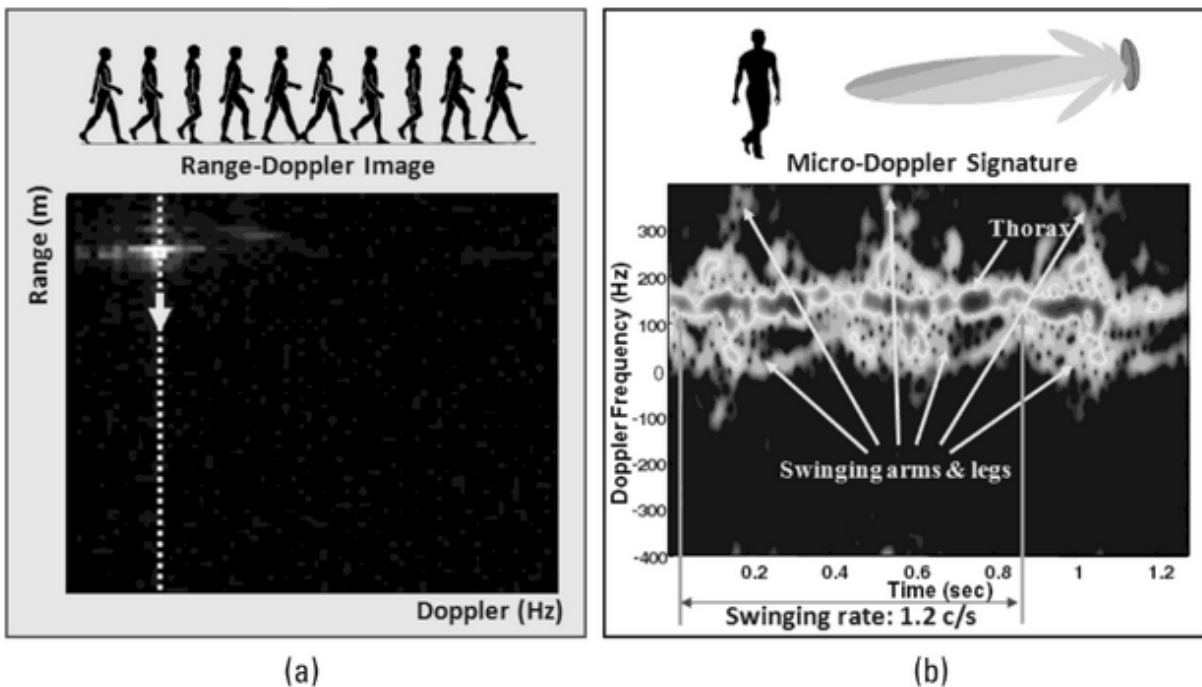


Figure 2.15: (a) Η συχνότητα Doppler ενός πεζού με την συμβατική μέθοδο. Διακρίνουμε ότι δεν μπορούμε να αναγνωρίσουμε το αντικείμενο. (b) Συχνότητα Doppler σε σχέση με τον χρόνο ενός

πεζού. Στο διάγραμμα μπορούμε να διακρίνουμε τα μέλη του σώματος που κινούνται με διαφορετικές ταχύτητες καθώς περπατάμε [52].

Η αναγνώριση αντικειμένων χρησιμοποιώντας την micro-Doppler μεθοδολογία, σε συνδυασμό με βαθέων συνελκτικών νευρωνικών δικτύων, έχει ευρεία εφαρμογή στην άμυνα, στην παρακολούθηση και στον ιδιωτικό τομέα, όπως στην αυτόνομη οδήγηση.

## 2.4 Sensor Fusion

Όλα τα όργανα ή ανιχνευτές που έχουν ειπωθεί μέχρι αυτό το σημείο (Κάμερες, LIDAR, RADAR) αποτελούν το υλικό που συλλέγουν τα δεδομένα για το περιβάλλον. Καθώς οι αισθητήρες είναι τα βασικά συστατικά των αυτοοδηγούμενων οχημάτων, η συγχώνευση των πληροφοριών από τους αισθητήρες και η σωστή ερμηνεία τους, ακολουθούμενη από τον έλεγχο του οχήματος, είναι το κεντρικό στοιχείο της αυτόνομης οδήγησης. Η “σύντηξη αισθητήρων” είναι μια προσέγγιση για το συνδυασμό δεδομένων που παραδίδονται από ανόμοιες πηγές ώστε να δημιουργηθούν ορθολογικές και επιθυμητές πληροφορίες [13]. Οι πληροφορίες που προκύπτουν είναι βέβαιο πως θα ήταν αδύνατες αν αυτές οι πηγές χρησιμοποιούνταν μεμονωμένα. Αυτό είναι ιδιαίτερα σημαντικό όταν διαφορετικά είδη πληροφοριών συνδυάζονται. Για παράδειγμα, στο αυτόνομο όχημα, είναι σημαντικό να υπάρχει μια κάμερα προκειμένου να κλωνοποιηθεί μια ανθρώπινη όραση, αλλά οι πληροφορίες για την απόσταση του εμποδίου θα είναι περισσότερο φερέγγυες μέσω των αισθητήρων LIDAR ή RADAR. Για αυτόν τον λόγο, η σύντηξη ετερογενών δεδομένων, δηλαδή δεδομένα της κάμερας με δεδομένα LIDAR ή RADAR, είναι πολύ σημαντική αφού ο σκοπός είναι η συμπληρωματικότητα μεταξύ τους. Αυτό το κεφάλαιο θα αναφερθεί στις τεχνικές συγχώνευσης δεδομένων και θα εισηγηθούν εργαλεία που χρησιμοποιούνται ευρέως για να πετύχουν την σύντηξη δεδομένων από διαφορετικές πηγές.



Πρακτικά υπάρχουν τρεις τρόποι που μπορεί μια εταιρία να συνδυάσει τα δεδομένα των αισθητήρων:

- Κάμερα με LIDAR
- Κάμερα με RADAR
- Camera, LIDAR και RADAR

### **2.4.1 Κάμερα με LIDAR**

Οι τρέχουσες τάσεις στην ανάπτυξη αυτόνομων οχημάτων έδειξαν αυξημένη χρήση του LIDAR. Η σύντηξη δεδομένων της κάμερας και του LIDAR δίνουν μια βέλτιστη λύση όσον αφορά την πολυπλοκότητα υλικού του συστήματος. Οι ενσωματωμένοι αισθητήρες είναι μόνο δύο τύποι, και η κάλυψη τους, κάμερα για την όραση και LIDAR για την ανίχνευση εμποδίων, συμπληρώνουν το ένα το άλλο. Μία από τις νέες λύσεις για αυτό το πρόβλημα είναι το δίκτυο PointFusion [53], το οποίο παράγει 3D πλαίσια οριοθέτησης από 2D φωτογραφίες και τα αντίστοιχα 3D “σύννεφα σημείων” που συνήθως παράγονται από αισθητήρες LIDAR (βλ. 2.2.2). Νέες προσεγγίσεις για την επίτευξη σύντηξης αισθητήρων χρησιμοποιώντας νευρωνικά δίκτυα τείνουν να αντιμετωπίζουν κάθε σήμα με διαφορετικό νευρωνικό δίκτυο, στη συνέχεια να ενσωματώνει το αποτέλεσμα σε ένα νέο νευρωνικό δίκτυο για να επιτευχθεί υψηλό επίπεδο σύντηξης, όπως φαίνεται στο fig. 2.16.

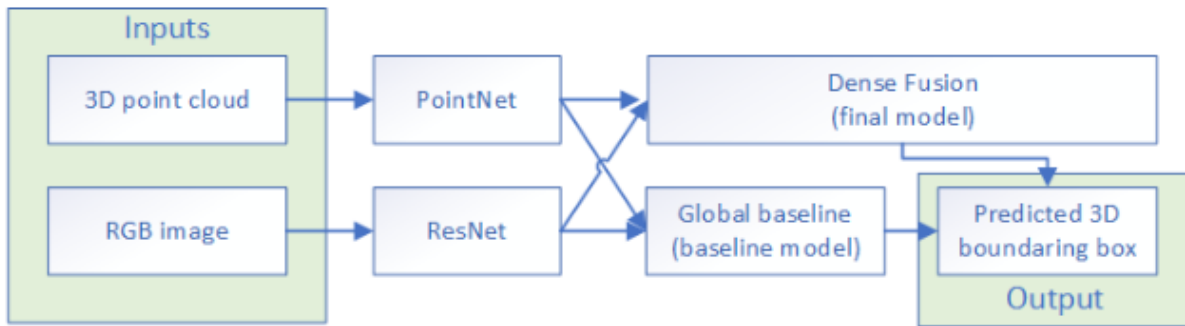


Figure 2.16: Διάγραμμα σύντηξης CNN από κάμερα και LIDAR [53].

Το Global baseline, ή αλλιώς **Global fusion network**, [54] επεξεργάζεται την εικόνα και το point-cloud και επιστρέφει άμεσα σαν αποτέλεσμα τις τρισδιάστατες θέσεις των οκτώ γωνιών του πλαισίου οριοθέτησης στόχου.

Η ιδέα πίσω από το **Dense fusion network** [54] είναι να χρησιμοποιούνται τα τρισδιάστατα σημεία εισόδου ως πυκνές χωρικές “άγκυρες”. Αντί να γίνεται άμεσος ορισμός θέσεων των 3D γωνιών του πλαισίου, για κάθε τρισδιάστατο σημείο εισόδου προβλέπουμε τις χωρικές μετατοπίσεις από εκείνο το σημείο από γωνιακές θέσεις ενός κοντινού πλαισίου. Ως αποτέλεσμα, το δίκτυο αποκτά μια εικόνα για την χωρική έκταση του περιβάλλοντος.

## 2.4.2 Κάμερα με RADAR


Οι αισθητήρες RADAR και οι κάμερες είναι κρίσιμο μέρος των σημερινών προηγμένων συστημάτων βοήθειας οδηγού (ADAS) και υψηλά αυτοματοποιημένα συστήματα οδήγησης. Απαιτείται αισθητήρας ικανός να διατηρεί την αποτελεσματικότητά του ακόμα και κάτω από διαφορετικά, συχνά δυσμενείς, συνθήκες του περιβάλλοντος. Για παράδειγμα, τα συστήματα κάμερας παράγουν ακριβείς εικόνες του περιβάλλοντος αλλά είναι πολύ ευαίσθητες κάτω από κακές συνθήκες φωτισμού και καιρού. Οι αισθητήρες ραντάρ, από την άλλη πλευρά, πληρούν

την απαίτηση ευρωστίας, αλλά έχουν σημαντικά χαμηλότερη ακρίβεια από τις κάμερες. Το ραντάρ χρησιμοποιείται στα σημερινά συστήματα υποβοήθησης οδηγού για τον προσδιορισμό εύρους, ταχύτητας, γωνίας αζιμουθίου και γωνία ανύψωσης αντικειμένων γύρω από το όχημα. Βασιζόμενοι στο φαινόμενο Doppler, ένα ραντάρ έχει εγγενή ικανότητα μέτρησης με ακρίβεια της σχετικής ταχύτητας των ανιχνευόμενων αντικειμένων και ως εκ τούτου να κάνει εύκολα διάκριση μεταξύ των δυναμικών και των στατικών αντικειμένων που ανιχνεύει [55]. Ο όγκος της πληροφορίας από ένα επιστρεφόμενο σήμα από ραντάρ είναι διαφορετικός από την πληροφορία ενός pixel. Η απόσταση ενός αντικειμένου από τον όχημα-πηγή, η οποία υπολογίζεται από το ραντάρ, μπορεί να θεωρηθεί πιο σχετική με την οδήγηση από μία απλή τιμή χρώματος pixel μιας κάμερας. Εάν οι δύο αισθητήρες συγχωνεύονται με μία πρόιμη σύντηξη, θα πρέπει να υποθέσουμε ότι τα διαφορετικά δεδομένα είναι σημασιολογικά παρόμοια.

Παρά την δημοτικότητα του ραντάρ στην αυτοκινητοβιομηχανία, λίγες μελέτες έχουν επικεντρωθεί στη σύντηξη δεδομένων από ραντάρ με άλλους αισθητήρες. Τα πιο γνωστά δίκτυα είναι το CRFnet [54], CenterFusion[56] και FusionNet. Διακρίνουμε στο figure 2.17 πως η χρήση πολλαπλών αισθητήρων και η σύντηξη τους μπορεί αποδειχθεί κρίσιμη αφού με ένα βασικό δίκτυο αναγνώρισης υπάρχει πιθανότητα να μην γίνει εντοπισμός σημαντικών εμποδίων, όπως ένας πεζός.



(a) Baseline network detection



(b) CRF-Net detection

*Figure 2.17: (a) Σύγκριση μεταξύ βασικού δικτύου αναγνώρισης και (b) το CRFnet δίκτυο με σύντηξη κάμερας και ραντάρ. Διακρίνουμε πως στο (a) το δίκτυο δεν ανιχνεύει τον πεζό στα αριστερά [54].*

Η αρχιτεκτονική δικτύου CRFnet ή Camera-and-Radar-Fusion Network βασίζεται στο RetinaNet με βάση VGG (Visual Geometry Group). Το δίκτυο επεκτείνεται για να ασχοληθεί με τα πρόσθετα κανάλια του ραντάρ. Η έξοδος του δικτύου είναι μια 2D απεικόνιση των συντεταγμένων οριοθέτησης και μια κατηγοριοποίηση για την οριοθέτηση (όχημα, άνθρωπος, εμπόδιο) [54].

### 2.4.3 Κάμερα, LIDAR και RADAR

Η ανίχνευση και η παρακολούθηση κινούμενων αντικειμένων είναι από τις πιο προκλητικές πτυχές του τομέα αυτόνομων οχημάτων. Η επίλυση αυτού του προβλήματος είναι ζωτικής σημασίας για την αυτόνομη οδήγηση, η καταλληλότητα και η αποτελεσματικότητα της λύσης είναι πολύ σημαντική. Ως εκ τούτου, είναι σύνηθες ότι όλοι οι υπάρχοντες αισθητήρες τοποθετημένοι στο όχημα χρησιμοποιούνται ταυτόχρονα. Η πιο συνηθισμένη συγχώνευση αισθητήρων είναι κάμερες, ραντάρ και LIDAR [57] όπως φαίνεται στο σχεδιαστικό διάγραμμα στο fig 2.18. Παλαιότερες προσεγγίσεις στην ανίχνευση κινούμενων αντικειμένων και η παρακολούθηση τους επικεντρώνεται στη σύντηξη δεδομένων αισθητήρα και παρακολούθηση τους γινόταν με χρήση αλγορίθμων ταυτόχρονου εντοπισμού και χαρτογράφησης (SLAM) [58]. Πρόσθετη συγχώνευση γίνεται στο επίπεδο της παρακολούθησης αντικειμένων για να υπάρχει μία συνολική αντίληψη του περιβάλλοντος.

Μια νέα προσέγγιση σε αυτό το πεδίο πραγματοποιεί ανίχνευση με ραντάρ και LIDAR, στέλνοντας στη συνέχεια περιοχές ενδιαφέροντος από το point-cloud στο δίκτυο ταυτοποίησης της κάμερας και στη συνέχεια συνδυάζει όλες αυτές τις πληροφορίες μαζί. Το αποτέλεσμα της σύντηξης τροφοδοτεί το πρόγραμμα παρακολούθησης με την λίστα κινούμενων αντικειμένων.

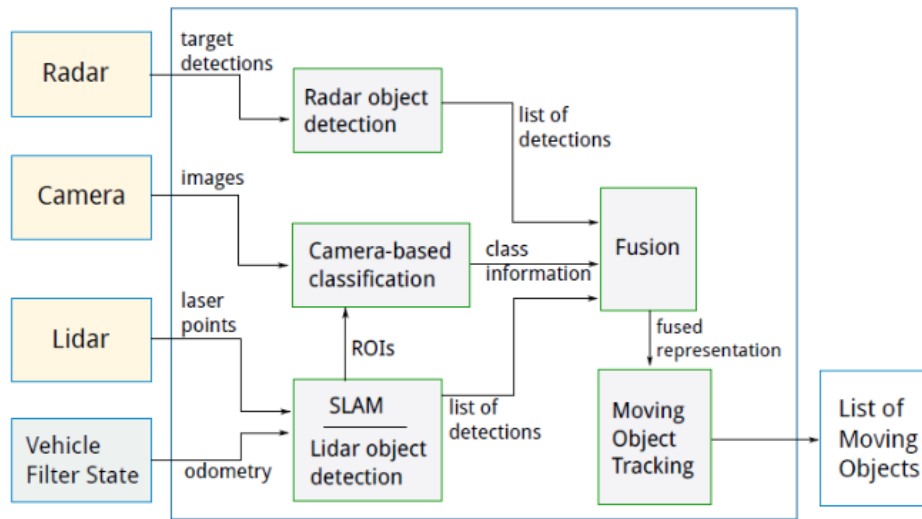


Figure 2.18: Σύστημα αισθητήρων διαφορετικού τύπου [57].

Είναι σύνηθες να γίνεται σύντηξη χαμηλού επιπέδου των προ-επεξεργασμένων δεδομένων από αισθητήρες ραντάρ και LIDAR, λύνοντας έως έναν βαθμό το πρόβλημα της τοπικοποίησης, δηλαδή ότι δεν υπάρχει κίνδυνος σύγκρουσης με οποιοδήποτε αντικείμενο. Αυτές οι συγχωνευμένες πληροφορίες γίνονται μέρος μιας υψηλότερου επιπέδου σύντηξη που λαμβάνει υπόψη και τις εισόδους της κάμερας. Σε αυτό το πλαίσιο, πετυχαίνεται η ανίχνευση και ταξινόμηση αντικειμένων.

# Κεφάλαιο 3

## Τοπικοποίηση

### 3.1 Ταυτόχρονο εντοπισμό και χαρτογράφηση (SLAM)

Ο ταυτόχρονος εντοπισμός και η χαρτογράφηση είναι ένα εξαιρετικά δημοφιλές θέμα στην κοινότητα της φορητής ρομποτικής για περισσότερα από 25 χρόνια τώρα. Η επιτυχία αυτού του τομέα είναι στενά συνδεδεμένη με το γεγονός ότι η «λύση» του προβλήματος SLAM [58], δηλαδή ο εντοπισμός ενός ρομπότ χάρη σε έναν χάρτη του περιβάλλοντος που κατασκευάζεται σταδιακά, έχει πολλές εφαρμογές που κυμαίνονται από την εξερεύνηση του χώρου έως την αυτόνομη οδήγηση. Τα πρόσφατα φώτα της δημοσιότητας στα αυτόνομα οχήματα ώθησαν περαιτέρω την ερευνητική προσπάθεια με τη συμβολή των κατασκευαστών αυτοκινήτων.

#### 3.1.1 Παγκόσμιο Δορυφορικό Σύστημα Πλοήγησης (GNSS)

Ο εντοπισμός ενός οχήματος, είτε σε τοπικό είτε σε παγκόσμιο πλαίσιο, αποτελεί βασική λειτουργία για την εκτέλεση οποιασδήποτε άλλης διεργασίας αντίληψης ή σχεδιασμού. Η πρόβλεψη των κινήσεων των αντικειμένων στο δρόμο και η επιλογή των ελιγμών είναι η πιο

κατάλληλη αφορμή για την ανάγκη ακριβής γνώσης της τοποθεσίας του οχήματος. Ο χάρτης έχει πρωταρχικό ενδιαφέρον όταν η αυτόνομη οδήγηση θεωρείται ως σύνολο, αφού προσφέρει ένα πρώτο επίπεδο αντίληψης που χρειάζεται για να γίνουν κατάλληλες αποφάσεις.

### **3.1.2 Το πρόβλημα με τα δορυφορικά συστήματα πλοήγησης**

Θα μπορούσε κανείς να σκεφτεί τα GNSS (Παγκόσμιο Δορυφορικό Σύστημα Πλοήγησης) ως λύση σε αυτό το πρόβλημα εντοπισμού αλλά αποδείχθηκε γρήγορα ότι δεν ήταν αρκετό από μόνο του. Αν και τα όρια ακρίβειας των κλασικών λύσεων GNSS είναι αυξημένα όταν χρησιμοποιούνται τοποθετημένοι σταθμοί στο έδαφος (Real-Time Kinematic GNSS) [59], η διαθεσιμότητα τους παραμένει ένα ζήτημα. Τα δορυφορικά σήματα επηρεάζονται από ατμοσφαιρικές συνθήκες που είναι δύσκολο να προβλεφθούν. Επιπλέον, η υποδομή των πόλεων μπορεί να εμποδίσει την άμεση λήψη σημάτων και να δημιουργήσει παρεμβολές πολλαπλών διαδρομών ή να είναι εκτός “οπτικής επαφής”, που έχει καταστροφικές συνέπειες στον παρεχόμενο εντοπισμό. Αυτό το είδος υποβάθμισης του σήματος είναι δύσκολο να εντοπιστεί και συνήθως προκαλεί απώλεια ακεραιότητας από την οποία η ανάκτηση μπορεί να είναι δύσκολη. Αυτά τα προβλήματα είναι πιο κοινά σε πυκνές αστικές περιοχές όπου τα ψηλά κτίρια μπορούν να καλύψουν τους δορυφόρους. Σε ανοιχτούς δρόμους, τα GNSS συνήθως αποδίδουν καλύτερα.

### **3.2 Αδρανειακή μονάδα μέτρησης**

Για την εκτίμηση της κίνησης ενός συστήματος που εκτίθεται σε υψηλό βαθμό ελευθερίας με υψηλή ακρίβεια, συχνά καθίσταται απαραίτητο να συγχωνεύονται πληροφορίες από διαφορετικούς αισθητήρες. Η σύντηξη αισθητήρων είναι μια πολύ γνωστή στρατηγική για τη μείωση των σφαλμάτων μέτρησης στην εκτίμηση κατάστασης και την εκτίμηση μη άμεσα



παρατηρήσιμων καταστάσεων του συστήματος όπως έχει προαναφερθεί. Σε πολλές εφαρμογές που απαιτείται ακρίβεια έχει εισαχθεί η χρήση μια μονάδα αδρανειακής μέτρησης (IMU - Inertial Measurement Unit). Το IMU αποτελείται από πολλούς αισθητήρες, όπως επιταχυνσιόμετρο, γυροσκόπιο και μαγνητόμετρο. Οι αισθητήρες παρέχουν πληροφορίες σχετικά με τους γωνιακούς ρυθμούς, γραμμική ταχύτητα και θέση σε σχέση με ένα παγκόσμιο πλαίσιο αναφοράς [59]. Η έξοδος αποστέλλεται σε αλγόριθμους πλοήγησης για να παρέχει τη θέση, την ταχύτητα και τη συμπεριφορά του οχήματος. Πολλές ερευνητικές εργασίες έχουν διεξαχθεί σχετικά με τη σύντηξη δεδομένων GPS/INS, ειδικά χρησιμοποιώντας το φίλτρο Kalman.

### **3.2.1 Φίλτρο Kalman**

Το φίλτρο Kalman [60] είναι ένα σύνολο μαθηματικών εξισώσεων που βασίζεται σε δυναμικό μοντέλο συστήματος. Αυτές οι εξισώσεις χρησιμοποιούνται για να γίνει μια εκτίμηση της τρέχουσας κατάστασης ενός συστήματος και να διορθωθεί η εκτίμηση χρησιμοποιώντας τυχόν διαθέσιμες μετρήσεις αισθητήρων. Η χρήση αυτού του φίλτρου που είναι πραγματικά ένας μηχανισμός “εκτιμητή-διορθωτή”, οδηγεί στη βέλτιστη εκτίμηση του γραμμικοποιημένου συστήματος και του μοντέλου συστήματος μέτρησης. Μια σύντομη εικονική περιγραφή του φίλτρου Kalman παρουσιάζεται στη συνέχεια στο fig 3.1.

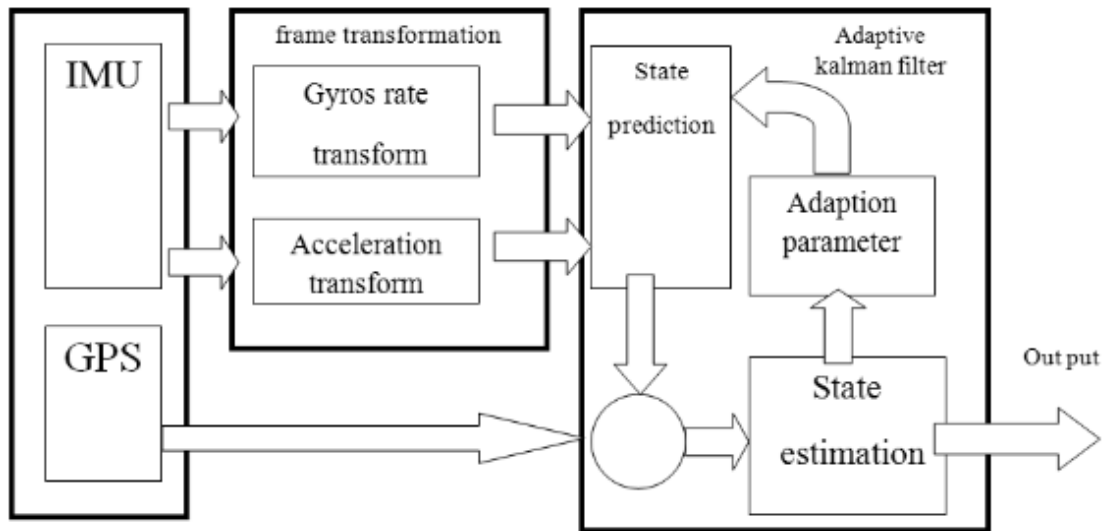


Figure 3.1: Διάγραμμα φίλτρου Kalman με GPS/IMU [59].

Για την εφαρμογή του προσαρμοστικού φίλτρου Kalman, δίνουμε προσοχή στην παράμετρο DOP (μείωση της ακρίβειας) και στη διάδοση σφαλμάτων των επιταχυνσιομέτρων και του γυροσκοπίου του IMU. Η παράμετρος DOP μας παρουσιάζει την επίδραση του καιρού και του περιβάλλοντος στην ακρίβεια του GPS. Μεγάλη τιμή της παραμέτρου DOP σημαίνει χαμηλή ακρίβεια στη θέση. Με αυτή την παράμετρο μπορούμε να αναγνωρίσουμε την ακρίβεια του GPS.

### 3.2.2 Visual - SLAM με χρήση IMU

Σε σενάρια με μην προσβάσιμο σήμα GPS, όπως καταστάσεις αποκατάστασης καταστροφών ή εφαρμογές σε πυκνόκτιστες περιοχές, αυτά τα συστήματα βασίζονται αποκλειστικά σε αδρανειακές μετρήσεις. Τα IMU υψηλής ποιότητας μπορούν να παρέχουν ακριβείς λύσεις πλοήγησης για μεγάλο χρονικό διάστημα. Αλλά τέτοιες συσκευές είναι δαπανηρές και μπορεί να είναι πολύ βαριές για οχήματα συμβατικής χρήσης. Ως εκ τούτου, φαίνεται πολλά υποσχόμενη η χρήση ενός χαμηλού κόστους IMU και η εκμετάλλευση εικόνων που λαμβάνονται από μια ενσωματωμένη κάμερα για την υποστήριξη πλοήγησης. Για το σκοπό αυτό επεκτείνουμε την

τυπική χρήση του φίλτρου Kalman για ενσωμάτωση GPS-INS [61], αυξάνοντας το διάλυμα της κατάστασης με τις συντεταγμένες των σημείων αναφοράς που αντιστοιχούν σε στοιχεία διακριτή υπόσταση στην παρατηρούμενη τοποθεσία και ενημερώνουμε το φίλτρο με τις συντεταγμένες εικόνας των παρατηρήσεων κάθε φορά που επεξεργάζεται ένα νέο πλαίσιο. Αυτό αποδίδει έναν οπτικό αλγόριθμο SLAM που ενσωματώνει άμεσα τις μετρήσεις IMU και μπορεί εύκολα να επεκταθεί ώστε να περιλαμβάνει μετρήσεις από πρόσθετους αισθητήρες.

Πολλές εξαιρετικές μελέτες έχουν χρησιμοποιήσει τεχνητή νοημοσύνη για να αντικαταστήσουν ορισμένες μη γεωμετρικές μονάδες σε παραδοσιακά συστήματα SLAM. Αυτές οι προσεγγίσεις ενισχύουν το συνολικό σύστημα SLAM βελτιώνοντας μόνο μέρος ενός τυπικού αγωγού, όπως στερεοφωνική αντιστοίχιση, επανατοποθέτηση και ούτω καθεξής. Ορισμένοι ερευνητές, όπως στο [62], προσπαθούν επίσης να χρησιμοποιήσουν χαρακτηριστικά υψηλότερου επιπέδου που αποκτήθηκαν μέσω μοντέλων μηχανικής μάθησης ως συμπλήρωμα στο SLAM. Αυτές οι μέθοδοι ξεπερνούν τους παραδοσιακούς αλγόριθμους SLAM υπό συγκεκριμένες συνθήκες και καταδεικνύουν τις δυνατότητες της βαθιάς μάθησης. Ωστόσο, ένας τέτοιος συνδυασμός Deep Learning και SLAM έχει σημαντικές ελλείψεις. Οι περισσότερες από τις μεθόδους Deep Learning βασίζονται σε μεγάλο βαθμό σε δεδομένα που χρησιμοποιούνται για εκπαίδευση, πράγμα που σημαίνει ότι δεν μπορούν να ταιριάζουν καλά σε άγνωστα περιβάλλοντα.

## **Κεφάλαιο 4**

# **Σχεδιασμός διαδρομής και προγραμματισμός συμπεριφοράς**

### **4.1 Σχεδιασμός και επιλογή διαδρομής**

Η ικανότητα ενός αυτόνομου αυτοκινήτου να βρίσκει μια διαδρομή μεταξύ δύο σημείων, δηλαδή μια θέση εκκίνησης και μια επιθυμητή τοποθεσία, αντιπροσωπεύει το σχεδιασμό διαδρομής. Σύμφωνα με τη διαδικασία σχεδιασμού διαδρομής, ένα αυτοοδηγούμενο αυτοκίνητο πρέπει να εξετάσει όλα τα πιθανά εμπόδια που υπάρχουν στο περιβάλλον και να υπολογίσει μια τροχιά κατά μήκος μιας διαδρομής χωρίς σύγκρουση. Η αυτόνομη οδήγηση είναι ένα περιβάλλον πολλαπλών πρακτόρων όπου το όχημα υποδοχής πρέπει να εφαρμόζει εξελιγμένες διαπραγματευτικές δεξιότητες με άλλους χρήστες του δρόμου κατά την προσπέραση, την υποχώρηση, τη συγχώνευση, στροφή αριστερά και δεξιά κατά πλοήγηση σε αδόμητους αστικούς δρόμους. Μια μη τετριμμένη πολιτική θα πρέπει να χειρίζεται την ασφάλεια στην οδήγηση. Αυτό το αναδυόμενο θέμα του βέλτιστου σχεδιασμού διαδρομής για αυτόνομα αυτοκίνητα θα πρέπει να λειτουργεί με υψηλές ταχύτητες υπολογισμού, ώστε να επιτυγχάνονται σύντομοι χρόνοι αντίδρασης, ενώ ικανοποιούνται συγκεκριμένα κριτήρια βελτιστοποίησης. Η εύρεση ενός

μονοπατιού σε ένα δεδομένο στατικό πλέγμα είναι ένα πολύ γνωστό και καλά μελετημένο πρόβλημα στις κοινότητες τεχνητής νοημοσύνης, σχεδιασμού και ρομποτικής με μια μεγάλη ποικιλία μεθόδων και αλγορίθμων που έχουν προταθεί μέχρι στιγμής. Οι περισσότεροι από αυτούς τους αλγορίθμους βασίζονται στην ευρετική αναζήτηση στον χώρο καταστάσεων που προκαλείται από τα κελιά του πλέγματος και βασίζονται στον γνωστό αλγόριθμο A\* που προτάθηκε το 1968 [67]. Στον τομέα της μηχανικής μάθησης, οι πρόσφατες εξελίξεις στη βαθιά μάθηση και στα συνελκτικά νευρωνικά δίκτυα (CNN) έχουν ξεπεράσει κάθε προσδοκία σε μια ευρεία ποικιλία εργασιών, όπως η ταξινόμηση και η τμηματοποίηση εικόνων, ο υπολογισμός οπτικής ροής, αναγνώριση αντικειμένων, όπως έχει πολυαναφερθεί στη τρέχουσα διπλωματική εργασία. Με αυτό, δεν είναι περίεργο που η βαθιά μάθηση έχει βρει τον δρόμο της και στον προγραμματισμό διαδρομών. Τα πιο αντιπροσωπευτικά παραδείγματα βαθιάς μάθησης για τον σχεδιασμό διαδρομής είναι τα Imitation Learning [63] και Deep Reinforcement Learning [67].

#### **4.1.1 Imitation Learning στον σχεδιασμό διαδρομής**

Αν και είναι δύσκολο να σχεδιαστεί ένα σύστημα αποφάσεων για ένα αυτόνομο όχημα, ένας έμπειρος οδηγός μπορεί να λύσει εύκολα το πρόβλημα οδήγησης, ακόμη και σε εξαιρετικά δύσκολα αστικά σενάρια. Επομένως, μια εναλλακτική είναι η εκμάθηση μιας πολιτικής οδήγησης από ειδικούς χρησιμοποιώντας τη μάθηση μίμησης. Η εφαρμογή της μάθησης μίμησης έχει πολλά οφέλη. Πρώτον, δεν χρειάζεται να σχεδιάσουμε χειροκίνητα το μοντέλο πολιτικής ή τη συνάρτηση κόστους που μπορεί να μην είναι βέλτιστη. Δεύτερον, χρειάζεται μόνο να παρέχουμε δεδομένα οδήγησης από ειδικούς, τα οποία δεν είναι δύσκολο να αποκτηθούν σε μεγάλη κλίμακα, και στη συνέχεια ο υπολογιστής θα μάθει αυτόματα μια πολιτική οδήγησης. Ένα πιο σοβαρό πρόβλημα για τις τρέχουσες προσεγγίσεις μάθησης μίμησης, ειδικά με την

προσέγγιση των συναρτήσεων νευρωνικά δίκτυα, είναι η ασφάλεια. Η ασφάλεια είναι το πιο κρίσιμο ζήτημα για την αυτόνομη οδήγηση και πρέπει να λαμβάνεται σοβαρά υπόψη.

Ο πρώτος αλγόριθμος μίμησης εκμάθησης που εφαρμόστηκε στην αυτόνομη οδήγηση ήταν πριν από 30 χρόνια, όταν το σύστημα ALVINN χρησιμοποίησε ένα νευρωνικό δίκτυο 3 επιπέδων [69] για να εκτελέσει παρακολούθηση δρόμου με βάση τις εικόνες της μπροστινής κάμερας. Βοηθούμενη από την πρόσφατη πρόοδο στη βαθιά εκμάθηση, η NVIDIA ανέπτυξε ένα σύστημα οδήγησης χρησιμοποιώντας βαθιά συνελκτικά νευρωνικά δίκτυα [66], τα οποία μπορούν να αποδώσουν καλές συμπεριφορές ακολουθώντας τη λωρίδα ακόμη και σε δύσκολα περιβάλλοντα όπου δεν μπορούν να αναγνωριστούν σήμανση λωρίδας. Επιπλέον Ο προσομοιωτής CARLA αναπτύχθηκε πρόσφατα και είναι ανοιχτού κώδικα. Επιτρέπει την εκπαίδευση και τη δοκιμή συστημάτων αυτόνομης οδήγησης σε ένα ρεαλιστικό τρισδιάστατο περιβάλλον προσομοίωσης αστικής οδήγησης. Η Uber χρησιμοποιεί ως είσοδο μια εικόνα που περιλαμβάνει πληροφορίες για τον χάρτη και αντικείμενα, και εκπαίδευσε ένα συνελκτικό νευρωνικό δίκτυο για να προβλέψει τη μελλοντική τροχιά του οχήματος. Η Waymo χρησιμοποίησε μια παρόμοια αναπαράσταση, όπου απεικονίζεται στο fig 4.1, και εκπαίδευσε ένα μοντέλο που, σε συνδυασμό με μονάδες αντίληψης και ελέγχου, θα μπορούσε να οδηγηθεί ένα όχημα σε διάφορα αστικά σενάρια [66].

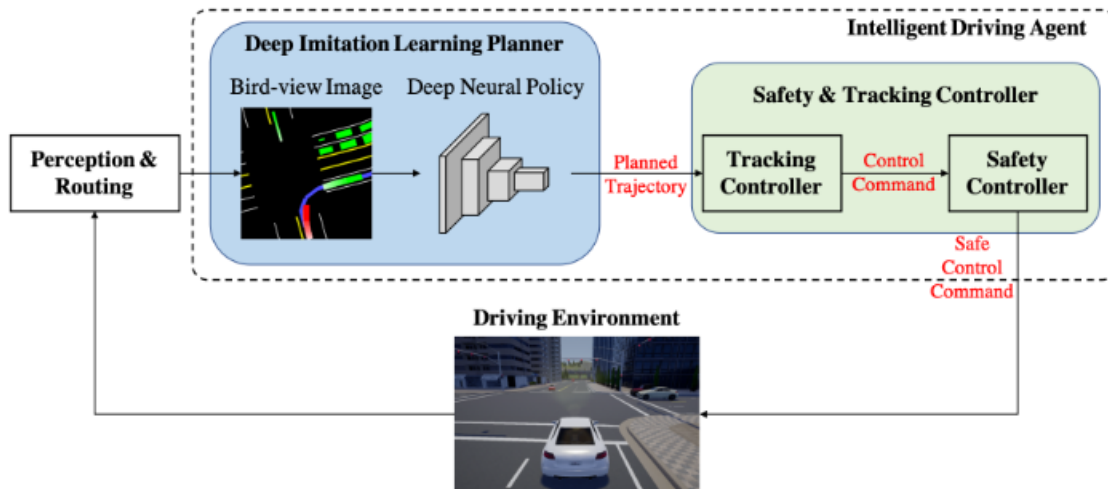


Figure 4.1: Διάγραμμα λήψης αποφάσεων αυτόνομου οχήματος [66].

Ο στόχος του Imitation Learning είναι να μάθει έναν ελεγκτή που μιμείται τη συμπεριφορά ενός ειδικού. Στη φάση της συλλογής δεδομένων, ένας εμπειρογνώμονας (είτε άνθρωπος οδηγός είτε ελεγκτής) λαμβάνει μια παρατήρηση  $o_t$  και μια ενέργεια εξόδου  $a_t$  σε χρόνο  $t$ . Τα ζεύγη παρατήρησης-δράσεων  $D = \{(o_t, a_t)\}_{t=1}^N$  αποθηκεύονται στη συνέχεια ως σύνολο δεδομένων.

Έστω η συνάρτηση πολιτικής  $f(o, \theta)$ , όπου  $\theta$  είναι η παράμετρος της. Το  $f$  μπορεί να είναι οποιαδήποτε προσέγγιση συνάρτησης, συμπεριλαμβανομένου ενός νευρωνικού δικτύου όπως χρησιμοποιείται σε αυτό το άρθρο. Το πρόβλημα μάθησης μίμησης διαμορφώνεται στη συνέχεια ως ένα εποπτευόμενο μαθησιακό (supervised learning) πρόβλημα, όπου ο στόχος είναι η βελτιστοποίηση της παραμέτρου  $\theta$  της συνάρτησης πολιτικής για την ελαχιστοποίηση της συνάρτησης απώλειας  $L$ :

$$\min_{(o_t, a_t) \in D} \sum L(f(o_t, \theta), a_t)$$

Ο σκοπός είναι ο βέλτιστος σχεδιασμός των παρατηρήσεων  $o$  (observation), ενεργειών  $a$  (action), της συνάρτησης πολιτικής  $f$  και της συνάρτησης απωλειών  $L$  [66].

#### 4.1.2 Deep Reinforced Learning για την επιλογή διαδρομής

Οι αλγόριθμοι Μηχανικής Μάθησης ταξινομούνται συχνά σε μία από τις τρεις ευρείες κατηγορίες: εποπτευόμενη (supervised) μάθηση, μάθηση χωρίς επίβλεψη (unsupervised) και ενισχυτική μάθηση (reinforced - RL) [68]. Στην ενισχυτική μάθηση ένας αυτόνομος πράκτορας μαθαίνει να βελτιώνει την απόδοσή του σε μια εργασία που του έχει ανατεθεί αλληλεπιδρώντας με το περιβάλλον του. Οι πράκτορες της RL δεν ενημερώνονται ρητά πώς να ενεργούν από έναν ειδικό αλλά η απόδοση ενός πράκτορα αξιολογείται από μια συνάρτηση ανταμοιβής  $R$  (reward function). Για κάθε κατάσταση που βιώνεται, ο πράκτορας επιλέγει μια ενέργεια και λαμβάνει μια περιστασιακή ανταμοιβή από το περιβάλλον του με βάση τη αποτελεσματικότητα της απόφασής του. Ο στόχος για τον πράκτορα είναι να μεγιστοποιήσει τις σωρευμένες ανταμοιβές που λαμβάνει κατά τη διάρκεια της ζωής του. Σταδιακά, ο πράκτορας μπορεί να αυξήσει τη μακροπρόθεσμη ανταμοιβή του, εκμεταλλευόμενος τη γνώση που έχει μάθει σχετικά με την αναμενόμενη αποτελεσματικότητα (δηλαδή το μειωμένο άθροισμα των αναμενόμενων μελλοντικών ανταμοιβών) διαφορετικών ζευγών κατάστασης-δράσης. Μία από τις κύριες προκλήσεις στην ενισχυτική μάθηση είναι η διαχείριση της αντιστάθμισης μεταξύ εξερεύνησης και εκμετάλλευσης. Για να μεγιστοποιήσει τις ανταμοιβές που λαμβάνει, ένας πράκτορας πρέπει να εκμεταλλευτεί τις γνώσεις του επιλέγοντας ενέργειες που είναι γνωστό ότι οδηγούν σε υψηλές ανταμοιβές.

Οι διαδικασίες απόφασης Markov (MDPs) [69] θεωρούνται το de facto πρότυπο όταν επισημοποιούνται διαδοχικά προβλήματα λήψης αποφάσεων που περιλαμβάνουν έναν μόνο πράκτορα RL. Ένα MDP αποτελείται από ένα σύνολο καταστάσεων  $S$ , ένα σύνολο ενεργειών  $A$ ,



μια συνάρτηση μετάβασης  $T$  και μια συνάρτηση ανταμοιβής  $R$ , δηλαδή μια πλειάδα  $\langle S, A, T, R \rangle$ . Όταν σε οποιαδήποτε κατάσταση  $s \in S$ , επιλέγοντας μια ενέργεια  $a \in A$  θα έχει ως αποτέλεσμα το περιβάλλον να εισέλθει σε μια νέα κατάσταση  $s' \in S$  με πιθανότητα μετάβασης  $T(s, a, s') \in (0, 1)$  και να δώσει μια ανταμοιβή  $R(s, a)$ . Η στοχαστική πολιτική  $\pi : S \rightarrow D$  είναι μια αντιστοίχιση από το χώρο κατάστασης σε μια πιθανότητα πάνω από το σύνολο των ενεργειών, και το  $\pi(a|s)$  αντιπροσωπεύει την πιθανότητα επιλογής της ενέργειας  $a$  στην κατάσταση  $s$ . Ο στόχος είναι να βρεθεί η βέλτιστη πολιτική  $\pi^*$ , η οποία έχει ως αποτέλεσμα το υψηλότερο αναμενόμενο άθροισμα ανταμοιβών [67].

$$\pi^* = \operatorname{argmax}\{V_\pi(s)\} \text{ με}$$

$$V_\pi(s) = \mathbb{E}_\pi \left\{ \sum_{k=0}^{H-1} \gamma^k r_{k+1} \mid s_0 = s \right\},$$

για όλες τις καταστάσεις  $s \in S$ , όπου  $r_k = R(s_k, a_k)$  είναι η ανταμοιβή τη στιγμή  $k$  και  $V_\pi(s)$  η συνάρτηση τιμής στην κατάσταση  $s$  που ακολουθεί μια πολιτική  $\pi$ .

## 4.2 Προγραμματισμος συμπεριφοράς - Vehicle Controls

Για αυτόνομη οδήγηση, το όχημα πρέπει να μπορεί να ελέγχει ταυτόχρονα το τιμόνι και την επιτάχυνση. Οι προσεγγίσεις της Αντίστροφης Ενισχυτικής Μάθησης (IRL) [67] έχουν επίσης διερευνηθεί στο πλαίσιο των συστημάτων ελέγχου ως ένας τρόπος για να ξεπεραστεί η δυσκολία καθορισμού μιας βέλτιστης συνάρτησης ανταμοιβής. Το IRL είναι ένα υποσύνολο της ενισχυτικής μάθησης, στο οποίο η συνάρτηση ανταμοιβής δεν καθορίζεται, αλλά ο πράκτορας προσπαθεί να τη μάθει από τις επιδείξεις ενός ειδικού. Στο IRL, ο πράκτορας υποθέτει ότι ο ειδικός ολοκληρώνει την εργασία ακολουθώντας μια άγνωστη συνάρτηση ανταμοιβής. Στη συνέχεια, υπολογίζει μια συνάρτηση ανταμοιβής στην οποία η τροχιά του ειδικού είναι η πιο

πιθανή. Αυτό έχει το πλεονέκτημα ότι αντί να απαιτείται από τον προγραμματιστή να ορίσει ρητά μια συνάρτηση ανταμοιβής, πρέπει απλώς να επιδείξει την επιδιωκόμενη συμπεριφορά. Αυτό μπορεί να είναι επωφελές καθώς σε μεγάλες και πολύπλοκες εργασίες, ο καθορισμός μιας κατάλληλης συνάρτησης ανταμοιβής για την παροχή βέλτιστης συμπεριφοράς του πράκτορα μπορεί να είναι δύσκολος και χρονοβόρος. Οι προσεγγίσεις IRL έχουν αποδειχθεί ότι όχι μόνο μειώνουν το χρόνο που απαιτείται για το σχεδιασμό και τη βελτιστοποίηση, αλλά βελτιώνουν επίσης την απόδοση του συστήματος δημιουργώντας πιο ισχυρές λειτουργίες ανταμοιβής.

## Κεφάλαιο 5 - Συμπεράσματα

Η τεχνολογία των αυτόνομων οχημάτων έχει σημειώσει ταχεία πρόοδο την τελευταία δεκαετία, ειδικά λόγω της ανάπτυξης στον τομέα της τεχνητής νοημοσύνης και της μηχανικής μάθησης. Οι τρέχουσες μεθοδολογίες τεχνητής νοημοσύνης στις μέρες μας είτε χρησιμοποιούνται, είτε λαμβάνονται υπόψη κατά το σχεδιασμό διαφορετικών εξαρτημάτων για ένα αυτοοδηγούμενο αυτοκίνητο. Τα αυτοκίνητα χωρίς οδηγό είναι πολύπλοκα συστήματα που πρέπει να μετακινούν με ασφάλεια επιβάτες ή φορτίο από την εκκίνηση στον προορισμό. Αρκετές προκλήσεις αντιμετωπίζονται με την εμφάνιση των αυτόνομων οχημάτων που βασίζονται σε ΑΙ σε δημόσιους δρόμους. Μια σημαντική πρόκληση είναι η δυσκολία απόδειξης της λειτουργικής ασφάλειας αυτών των οχημάτων, δεδομένης της τρέχουσας επεξηγησιμότητας των νευρωνικών δικτύων. Επιπλέον, τα συστήματα μηχανικής μάθησης βασίζονται σε μεγάλες βάσεις δεδομένων εκπαίδευσης και απαιτούν εκτεταμένο υπολογιστικό υλικό. Προτού μπορέσει να αναπτυχθεί η μηχανική εκμάθηση στο δρόμο, θα χρειαστεί να βρεθούν ορισμένες τεχνικές επικύρωσης της ασφάλειας για την αντιμετώπιση της αδιαφάνειάς τους. Η διασφάλιση της ασφάλειας αυτών των βαθιών νευρωνικών δικτύων είναι ένα σημαντικό εμπόδιο για την εμπορική χρήση τους.

# Βιβλιογραφία

1. Deep learning / Ian Goodfellow, Yoshua Bengio, Aaron Courville, Cambridge, Massachesetts: The MIT Press 2016
2. Applied Deep Learning and Computer Vision for Self-Driving Cars / By Sumit Ranjan , Dr. S. Senthamilarasu / Publisher: Packt
3. Sensor Fusion and its Applications, Ciza Thomas, Republished by InTech  
<https://www.intechopen.com/books/2971> για όλο το βιβλίο.
4. The Growth of the Automobile Industry: Toyota’s Dominance in United States, October 2014, Journal of Research in Marketing Vol 3(No2): 265-268/ Assoc. Prof. Dr. Rashad Yazdanifard/ DOI: 10.17722/JORM.V3I2.86
5. ACEA: Position Paper – Artificial Intelligence in the automotive industry / 24 November 2020
6. Sumari, A. D. W., & Ahmad, A. S. (2017). Knowledge-growing system The origin of the cognitive artificial intelligence. 2017 6th International Conference on Electrical Engineering and Informatics (ICEEI). doi10.1109/iceei.2017.83
7. Luckow, A., Cook, M., Ashcraft, N., Weill, E., Djerekarov, E., & Vorster, B. (2016). Deep learning in the automotive industry Applications and tools. 2016 IEEE International

8. Petrović, Đ., Mijailović, R., & Pešić, D. (2020). Traffic Accidents with Autonomous Vehicles: Type of Collisions, Manoeuvres and Errors of Conventional Vehicles' Drivers. *Transportation Research Procedia*, 45, 161–168. doi:10.1016/j.trpro.2020.03.0
9. Cars, planes, trains: where do CO2 emissions from transport come from? By Hannah Ritchie, October 06, 2020 <https://ourworldindata.org/co2-emissions-from-transport>
10. Alcantarilla, P. F., Yebes, J. J., Almazan, J., & Bergasa, L. M. (2012). On combining visual SLAM and dense scene flow to increase the robustness of localization and mapping in dynamic environments. 2012 IEEE International Conference on Robotics and Automation. doi:10.1109/icra.2012.6224690
11. Computer Vision for Autonomous Vehicles: Problems, Datasets and State-of-the-Art / J. Janai, F. Güney, Andreas Geiger, 2020, *Computer Science* / DOI:10.1561/06000000079
12. Lv, D., Ying, X., Cui, Y., Song, J., Qian, K., & Li, M. (2017). Research on the technology of LIDAR data processing. 2017 First International Conference on Electronics Instrumentation & Information Systems (EIIS). doi:10.1109/eiis.2017.8298694
13. Kocic, J., Jovicic, N., & Drndarevic, V. (2018). Sensors and Sensor Fusion in Autonomous Vehicles. 2018 26th Telecommunications Forum (TELFOR). doi:10.1109/telfor.2018.8612054
14. KAMIJO, S., GU, Y., & HSU, L.-T. (2015). Autonomous Vehicle Technologies Localization and Mapping. *IEICE ESS Fundamentals Review*, 9(2), 131–141. doi10.1587/essfr.9.2\_131
15. E.Javanmardi, et al., Autonomous vehicle self-localization based on abstract map and multi-channel LiDAR in urban area, *IATSS Research* (2017),

<https://doi.org/10.1016/j.iatssr.2018.05.001>

16. J.-M. Zogg, GPS: Essentials of Satellite Navigation: Compendium: Theorie and Principles of Satellite Navigation, Overview of GPS/GNSS Systems and Applications. Thalwil, Switzerland: U-Blox, 2009, U-Blox (Firma)
17. Yozevitch, R., Ben-Moshe, B., & Dvir, A. (2014). GNSS Accuracy Improvement Using Rapid Shadow Transitions. IEEE Transactions on Intelligent Transportation Systems, 15(3), 1113–1122. doi:10.1109/tits.2013.2294537
18. Javanmardi, E., Gu, Y., Javanmardi, M., & Kamijo, S. (2018). Autonomous vehicle self-localization based on abstract map and multi-channel LiDAR in urban area. IATSS Research. doi:10.1016/j.iatssr.2018.05.001
19. Inertial Navigation — Theory and Applications, Gade, Kenneth , Publisher: NTNU, Series: Doctoral theses at NTNU;2018:38
20. A Brief Survey on SLAM Methods in Autonomous Vehicle, Talha Takleh Omar Takleh1\*, Nordin Abu Bakar, Shuzlina Abdul Rahman, Raseeda Hamzah, Zalilah Abd Aziz, Faculty of Computer and Mathematical Sciences, Universiti Teknologi MARA (UiTM), Shah Alam, Malaysia
21. Nardi, L., & Stachniss, C. (2019). Uncertainty-Aware Path Planning for Navigation on Road Networks Using Augmented MDPs. 2019 International Conference on Robotics and Automation (ICRA). doi:10.1109/icra.2019.8794121
22. Pratik Kanani, May 2019, Google Maps, International Journal of Computer Applications 178(8): 41-46, DOI:10.5120/IJCA2019918791

23. Wei, J., Snider, J. M., Gu, T., Dolan, J. M., & Litkouhi, B. (2014). A behavioral planning framework for autonomous driving. 2014 IEEE Intelligent Vehicles Symposium Proceedings. doi:10.1109/ivs.2014.6856582
24. Zeyu Zhu, Huijing Zhao, 6 Jan 2021, A survey of Deep RL and IL for Autonomous Driving Policy Learning, arXiv:2101.01993v1 [cs.RO]
25. Heng, L., Choi, B., Cui, Z., Geppert, M., Hu, S., Kuan, B., ... Sattler, T. (2019). Project AutoVision: Localization and 3D Scene Perception for an Autonomous Vehicle with a Multi-Camera System. 2019 International Conference on Robotics and Automation (ICRA). doi:10.1109/icra.2019.8793949
26. Tesla Autopilot : Semi Autonomous Driving, an Uptick for Future Autonomy, Nathanael Bassett, IRJET Volume 03 Issue 09 Sep 2016, IRJET Journal, e-ISSN: 2395 -0056
27. Dannheim, C., Icking, C., Mader, M., & Sallis, P. (2014). Weather Detection in Vehicles by Means of Camera and LIDAR Systems. 2014 Sixth International Conference on Computational Intelligence, Communication Systems and Networks. doi:10.1109/cicsyn.2014.47
28. Google AI Blog, EfficientDet: Towards Scalable and Efficient Object Detection, 15/APR/2020, Mingxing Tan, Software Engineer and Adams Yu, Research Scientist, Google Research <https://ai.googleblog.com/2020/04/efficientdet-towards-scalable-and.html>
29. YOLOv4 Optimal Speed and Accuracy of Object Detection Alexey Bochkovskiy, Chien-Yao Wang, Hong-Yuan Mark Liao

30. Gu, Y., Chi, J., Liu, J., Yang, L., Zhang, B., Yu, D., ... Lu, X. (2021). A survey of computer-aided diagnosis of lung nodules from CT scans using deep learning. *Computers in Biology and Medicine*, 137, 104806. doi.org/10.1016/j.combiomed.2021.104806
31. Carranza-García M, Torres-Mateo J, Lara-Benítez P, García-Gutiérrez J. On the Performance of One-Stage and Two-Stage Object Detectors in Autonomous Vehicles Using Camera Data. *Remote Sensing*. 2021; 13(1):89. <https://doi.org/10.3390/rs13010089>
32. Lan, W., Dang, J., Wang, Y., & Wang, S. (2018). Pedestrian Detection Based on YOLO Network Model. 2018 IEEE International Conference on Mechatronics and Automation (ICMA). doi10.1109/icma.2018.8484698
33. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once Unified, Real-Time Object Detection. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). doi10.1109/cvpr.2016.91
34. Muthalagu, R., Bolimera, A., & Kalaichelvi, V. (2020). Lane detection technique based on perspective transformation and histogram analysis for self-driving cars. *Computers & Electrical Engineering*, 85, 106653. doi:10.1016/j.compeleceng .2020.106653
35. Neven, D., Brabandere, B. D., Georgoulis, S., Proesmans, M., & Gool, L. V. (2018). Towards End-to-End Lane Detection: an Instance Segmentation Approach. 2018 IEEE Intelligent Vehicles Symposium (IV). doi:10.1109/ivs.2018.8500547
36. Fast lane detection based on bird's eye view and improved random sample consensus algorithm - Ding2017\_Article\_FastLaneDetectionBasedOnBirdSE 25 November 2016 Springer Science and Business Media DOI 10.1007/s11042-016-4184-6



37. Abbas, Syed & Zisserman, Andrew. (2019). A Geometric Approach to Obtain a Bird's Eye View From an Image. 4095-4104. 10.1109/ICCVW.2019.00504.
38. Mukhopadhyay, P., & Chaudhuri, B. B. (2015). A survey of Hough Transform. Pattern Recognition, 48(3), 993–1010. doi10.1016j.patcog.2014.08.27
39. Jiaxu Zhang, Shaolin Hu and Haoqiang Shi, “Deep Learning based Object Distance Measurement Method for Binocular Stereo Vision Blind Area” International Journal of Advanced Computer Science and Applications(IJACSA), 9(9), 2018. <http://dx.doi.org/10.14569/IJACSA.2018.090977>
40. Zivingy, Manaf. (2013). Object distance measurement by stereo vision. International Journal of Science and Applied Information Technology (IJSAIT). 2. 05-08.
41. NVIDIA DRIVE lab series, “To Go the Distance, We Built Systems That Could Better Perceive It”, <https://blogs.nvidia.com/blog/2019/06/19/drive-labs-distance-to-object-detection/>
42. Badino, H., Huber, D., & Kanade, T. (2011). Integrating LIDAR into Stereo for Fast and Improved Disparity Computation. 2011 International Conference on 3D Imaging, Modeling, Processing, Visualization and Transmission. doi:10.1109/3dimpvt.2011.58
43. Royo, S., & Ballesta-Garcia, M. (2019). An Overview of Lidar Imaging Systems for Autonomous Vehicles. Applied Sciences, 9(19), 4093. doi:10.3390/app9194093
44. Zamanakos, G., Tsochatzidis, L., Amanatiadis, A., & Pratikakis, I. A comprehensive survey of LIDAR-based 3D object detection methods with deep learning for autonomous driving. doi10.1016j.cag.2021.07.003

45. Wang, H., Wang, B., Liu, B., Meng, X., & Yang, G. (2017). Pedestrian recognition and tracking using 3D LiDAR for autonomous vehicle. *Robotics and Autonomous Systems*, 88, 71–78. doi:10.1016/j.robot.2016.11.014
46. C. R. Qi, H. Su, K. Mo, and L. J. Guibas. Pointnet Deep learning on point sets for 3d classification and segmentation. arXiv preprint arXiv:1612.00593, 2016
47. Qi CR , Yi L , Su H , Guibas LJ . Pointnet++: deep hierarchical feature learning on point sets in a metric space. arXiv preprint arXiv:1706.02413 2017b
48. CHO, Keun-Yeong; LEE, Keun-Dong; OH, Tae-Keun. Characteristics of Radio Detection and Ranging System.
49. RASSHOFER, R. H.; GRESSER, K. Automotive Radar and Lidar Systems for Next Generation Driver Assistance Functions. *Advances in Radio Science*, 2005, 3: 205-209.
50. Schubert, E., Meinl, F., Kunert, M., & Menzel, W. (2015). High resolution automotive radar measurements of vulnerable road users – pedestrians & cyclists. 2015 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM). doi:10.1109/icmim.2015.711794
51. Chen, V. C., Fayin Li, Shen-Shyang Ho, & Wechsler, H. (2006). Micro-doppler effect in radar: phenomenon, model, and simulation study. *IEEE Transactions on Aerospace and Electronic Systems*, 42(1), 2–21. doi:10.1109/taes.2006.1603402
52. CHEN, Victor C. The micro-Doppler effect in radar. Artech House, 2019
53. D. Xu, A. Jain, and D. Anguelov, “PointFusion: Deep Sensor Fusion for 3D Bounding Box Estimation, Proc. of CVPR, 2018

54. Nobis, F., Geisslinger, M., Weber, M., Betz, J., & Lienkamp, M. (2019). A Deep Learning-based Radar and Camera Sensor Fusion Architecture for Object Detection. 2019 Sensor Data Fusion Trends, Solutions, Applications (SDF). doi10.1109s
55. Lekic, V., & Babic, Z. (2019). Automotive radar and camera fusion using generative adversarial networks. Computer Vision and Image Understanding. doi10.1016j.cviu.2019.04.002
56. CenterFusion Center based Radar and Camera Fusion for 3D Object Detection, Ramin Nabati, Hairong Qi
57. R. O. Chavez-Garcia and O. Aycard, "Multiple Sensor Fusion and Classification for Moving Object Detection and Tracking," in IEEE Transactions on Intelligent Transportation Systems, vol. 17, no. 2, pp. 525-534, Feb. 2016
58. Bresson, G., Alsayed, Z., Yu, L., & Glaser, S. (2017). Simultaneous Localization and Mapping A Survey of Current Trends in Autonomous Driving. IEEE Transactions on Intelligent Vehicles, 2(3), 194–220. doi10.1109tiv.2017.2749181
59. Wahyudi, Listiyana, M. S., Sudjadi, & Ngatelan. (2018). Tracking Object based on GPS and IMU Sensor. 2018 5th International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE). doi10.1109icitacee.2018
60. Girrbaach, F., Hol, J., Bellusci, G., & Diehl, M. (2017). Optimization-Based Sensor Fusion of GNSS and IMU Using a Moving Horizon Approach. Sensors, 17(5), 1159. doi10.3390s17051159

61. Kleinert, M., & Schleith, S. (2010). Inertial aided monocular SLAM for GPS-denied navigation. 2010 IEEE Conference on Multisensor Fusion and Integration. doi:10.1109/mfi.2010.5604453
62. Rong Kang, Jieqi Shi, Xueming Li, Yang Liu, Xiao Liu, DF-SLAM: A Deep-Learning Enhanced Visual SLAM System based on Deep Local Features, arXiv:1901.07223
63. Rehder, E., Quehl, J., & Stiller, C. (2017). Driving like a human Imitation learning for path planning using convolutional neural networks. I International Conference on Robotics and Automation Workshops
64. D. A. Pomerleau. Alvin: An autonomous land vehicle in a neural network. In Advances in neural information processing systems, pages 305–313, 1989.
65. M. Bojarski et al. End to end learning for self-driving cars. arXiv preprint arXiv:1604.07316, 2016
66. Chen, J., Yuan, B., & Tomizuka, M. (2019). Deep Imitation Learning for Autonomous Driving in Generic Urban Scenarios with Enhanced Safety. 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). doi10.1109/iros4
67. B. R. Kiran et al., "Deep Reinforcement Learning for Autonomous Driving: A Survey," in IEEE Transactions on Intelligent Transportation Systems, doi: 10.1109/TITS.2021.3054625.
68. Wiering, M., & van Otterlo, M. (Eds.). (2012). Reinforcement Learning. Adaptation, Learning, and Optimization. doi:10.1007/978-3-642-27645-3

69. Kuutti, S., Bowden, R., Jin, Y., Barber, P., & Fallah, S. (2020). A Survey of Deep Learning Applications to Autonomous Vehicle Control. *IEEE Transactions on Intelligent Transportation Systems*, 1–22. doi10.1109/tits.2019.2962338