



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ & ΗΛΕΚΤΡΟΝΙΚΩΝ ΜΗΧΑΝΙΚΩΝ

Διπλωματική Εργασία

**Καταμέτρηση Αριθμού Ατόμων μέσω Ανίχνευσης Wi-Fi και Χρήση
Μηχανικής Μάθησης**



Φοιτητής: Ιωάννης Σπανακάς

AM: 48346963

Επιβλέπων Καθηγητής

Χαράλαμπος Πατρικάκης

Καθηγητής

ΑΘΗΝΑ-ΑΙΓΑΛΕΩ, ΙΟΥΛΙΟΣ 2024



UNIVERSITY OF WEST ATTICA
FACULTY OF ENGINEERING
DEPARTMENT OF ELECTRICAL & ELECTRONICS ENGINEERING

Diploma Thesis

Indoor People Counting with Wi-Fi Sensing Using Machine Learning



Student: Ioannis Spanakas
Registration Number: 48346963

Supervisor

Charalampos Patrikakis
Professor

ATHENS-EGALEO, July 2024

Η Διπλωματική Εργασία έγινε αποδεκτή και βαθμολογήθηκε από την εξής τριμελή επιτροπή:

Χαράλαμπος Πατρικάκης, Καθηγητής	Νικόλαος – Αλέξανδρος Τάτλας, Καθηγητής	Περικλής Παπαδόπουλος, Καθηγητής
(Υπογραφή)	(Υπογραφή)	(Υπογραφή)

Copyright © Με επιφύλαξη παντός δικαιώματος. All rights reserved.

**ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ και Ιωάννης Σπανακάς,
Μήνας, Έτος**

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τους συγγραφείς.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον/την συγγραφέα του και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις θέσεις του επιβλέποντος, της επιτροπής εξέτασης ή τις επίσημες θέσεις του Τμήματος και του Ιδρύματος.

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Ο κάτωθι υπογεγραμμένος Ιωάννης Σπανακάς του Ελευθερίου, με αριθμό μητρώου 48346963 φοιτητής του Πανεπιστημίου Δυτικής Αττικής της Σχολής ΜΗΧΑΝΙΚΩΝ του Τμήματος ΗΛΕΚΤΡΟΛΟΓΩΝ ΚΑΙ ΗΛΕΚΤΡΟΝΙΚΩΝ ΜΗΧΑΝΙΚΩΝ,

δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της διπλωματικής εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του διπλώματός μου.»

Ο Δηλών
(Ονοματεπώνυμο φοιτητή)
Ιωάννης Σπανακάς

Ι. Σπανακάς

(Υπογραφή φοιτητή)

*Στον πατέρα μου Λευτέρη και
στον μικρό μου αδερφό Δημήτρη.*

Ευχαριστώ τους καθηγητές αυτούς, που μέσα από τα μάτια τους διδάχθηκα παιδεία.

Περίληψη

Στην εκπονηθείσα διπλωματική εργασία παρουσιάζεται ένα σύστημα ανίχνευσης αριθμού ατόμων σε εσωτερικό χώρο με χρήση της τεχνολογίας WiFi Sensing και εφαρμογή αλγορίθμων μηχανικής και βαθιάς μάθησης. Συγκεκριμένα, διερευνήθηκε η προαναφερθείσα τεχνολογία, μελετήθηκαν αλγόριθμοι μηχανικής μάθησης που επιλύουν τέτοιου είδους προβλήματα και υλοποιήθηκε το σύστημα ανίχνευσης αριθμού ατόμων σε εσωτερικό χώρο. Κατά την υλοποίηση του συστήματος αναπτύχθηκαν και εφαρμόστηκαν δύο υπό – συστήματα, ένα για την καταμέτρηση του πραγματικού αριθμού ατόμων και ένα για την καταγραφή των πληροφοριών του καναλιού επικοινωνίας. Στη συνέχεια, θεσπίστηκε το σετ δεδομένων εκπαίδευσης για αριθμό πέντε ατόμων και αφού επεξεργάστηκε και τιτλοφορήθηκε, τροφοδοτήθηκε σε τέσσερις αλγορίθμους μηχανικής μάθησης για τρία σενάρια. Το πρώτο σενάριο αφορά την ανίχνευση παρουσίας, το δεύτερο την ανίχνευση πληρότητας και το τρίτο την ανίχνευση του ακριβούς αριθμού ατόμων στο χώρο. Έπειτα, επιλέχθηκε ο αλγόριθμος με την καλύτερη απόδοση, και οι προβλέψεις του, για τα τρία σενάρια, τροφοδοτήθηκαν σε ένα μετά μοντέλο μηχανικής μάθησης, ώστε να επιτευχθούν υψηλότερα ποσοστά πρόβλεψης για το σενάριο ανίχνευσης του αριθμού ατόμων. Τέλος, η εκπαίδευση του καλύτερου αλγορίθμου, για τα μοντέλα των τριών σεναρίων, και του μετά-μοντέλου, αξιολογήθηκε εξάγοντας προβλέψεις σε δύο άλλους εσωτερικούς χώρους. Τα αποτελέσματα των μοντέλων έδειξαν ότι η παραμετροποίηση των συστημάτων διαφέρει ανά χώρο μελέτης και η καταμέτρηση αριθμού ατόμων με την προσέγγιση που εκπονήθηκε, μπορεί να επιτευχθεί ξεχωριστά για κάθε προφίλ χώρου και όχι γενικά για όλους τους εσωτερικούς χώρους.

Λέξεις – κλειδιά

Ανίχνευση WiFi Σημάτων, Μηχανική Μάθηση, Αισθητήρες, Πρωτόκολλο 802.11ax, Αλγόριθμοι, Ασύρματα Επικοινωνιακά Συστήματα.

Abstract

In this thesis, a system for detecting the number of people in an indoor environment, using WiFi Sensing technology and machine and deep learning algorithms, is presented. In particular, a research was set upon the aforementioned technology and the machine learning algorithms that solve classification problems, and the system for the detection of the number of people in an indoor environment was implemented. During the implementation of the system, two sub systems were developed, one for counting the actual number of people and one for recording the channel state information. Next, the training dataset was established, for a number of five people and after being processed and labeled, it was fed into for machine learning algorithms for three scenarios. The first scenario was for presence detection, the second was for occupancy detection and the third was for detecting the exact number of people in a room. Then, the best performing algorithm was selected, and its predictions, for the three scenarios, were fed into a deep learning meta-model, in order to achieve higher prediction scores for the scenario of the number of people detection. Finally, the training of the best algorithm, for the models of the three scenarios, and the meta-model, was evaluated by extracting predictions into two other indoor environments. The results of the models showed that the configuration of the systems differs per study case, and that counting the number of people, with the approach developed, can be achieved separately for each indoor space profile and not generally for all interiors.

Keywords

WiFi Sensing, Machine Learning, Deep Learning, Sensors, Protocol 802.11ax, Algorithms, Wireless Communication Systems.

Περιεχόμενα

Κατάλογος Πινάκων.....	12
Κατάλογος Εικόνων.....	13
Αλφαβητικό Ευρετήριο.....	15
ΕΙΣΑΓΩΓΗ.....	17
Αντικείμενο της διπλωματικής εργασίας.....	17
Σκοπός και στόχοι.....	18
Μεθοδολογία.....	18
Δομή.....	19
1 ΚΕΦΑΛΑΙΟ 1^ο : Βασικές Έννοιες και Πρωτόκολλο Wi-Fi.....	21
1.1 Ραδιοσυχνотικά Σήματα (RF Signals).....	21
1.1.1 Πόλωση Ηλεκτρομαγνητικού Κύματος.....	21
1.1.2 Δείγματα IQ.....	23
1.1.3 Διαμόρφωση Πλάτους Τετραγωνικής Διάταξης (QAM: Quadrature Amplitude Modulation).....	24
1.1.4 FFT & IFFT (Fast Fourier Transform & Inverse Fast Fourier Transform).....	25
1.1.5 Πολυπλεξία Ορθογωνικής Διαίρεσης Συχνότητας (OFDM: Orthogonal Frequency Division Multiplexing).....	27
1.2 Πομπός, Δέκτης και Διάυλος Επικοινωνίας σε RF Συστήματα.....	28
1.2.1 Αρχιτεκτονική στον Πομπό.....	28
1.2.2 Αρχιτεκτονική στον Δέκτη.....	29
1.2.3 Πληροφορία Κατάστασης Καναλιού Επικοινωνίας (CSI: Channel State Information).....	31
1.2.4 Διαφορά Φάσης Φέροντος Σήματος (CFO: Carrier Frequency Offset).....	31
1.2.5 Προφίλ Καθυστέρησης Ισχύος Σήματος (PDP: Power Delay Profile).....	32
1.3 Πρωτόκολλο 802.11 (Wi-Fi).....	32
1.3.1 Ιστορική Αναδρομή.....	32
1.3.2 Δομή.....	32
1.4 Το Πρωτόκολλο 802.11ax.....	34
1.4.1 Τεχνολογίες Κλειδιά του 802.11ax.....	34
1.4.2 Αποδοτικότητα.....	35
2 ΚΕΦΑΛΑΙΟ 2^ο : Υπολογιστική Νοημοσύνη και Μηχανική Μάθηση.....	36
2.1 Σύντομη Ιστορική Αναδρομή.....	36
2.2 Εισαγωγή στην Υπολογιστική Νοημοσύνη.....	36
2.3 Είδη Μηχανικής Μάθησης.....	37
2.3.1 Επιβλεπόμενη Μάθηση (Supervised Learning).....	37
2.3.2 Μάθηση Διόρθωσης Σφάλματος (Error Correction Learning).....	38
2.3.3 Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning).....	40
2.3.4 Ενισχυτική Μάθηση (Reinforcement Learning).....	40
2.4 Αλγόριθμοι Μηχανικής Μάθησης.....	41
2.4.1 Perceptron.....	41
2.4.2 Perceptrons Πολλαπλών Στοιβάδων (MLP: Multilayer Perceptrons).....	42
2.4.3 Νευρωνικά Δίκτυα Εμπρόσθιας Τροφοδότησης (FNN: Feedforward Neural Network).....	43
2.4.4 Συσταδοποίηση μέσω Bayes (Naive Bayes).....	45
2.4.5 Αλγόριθμος Ακραίας Ενίσχυσης Κλίσης (XGBoost: eXtreme Gradient Boosting).....	47
2.4.6 Μηχανή Ελαφράς Ενίσχυσης Κλίσης (LightGBM: Light Gradient Boosting Machine).....	47
2.5 Μέθοδοι Βελτιστοποίησης Εκπαίδευσης Μηχανικής Μάθησης.....	48
2.5.1 Διασταυρωμένη Επικύρωση (Cross Validation).....	48
2.5.2 Διασταυρωμένη Επικύρωση K-Επιπέδων (K-Folds Cross Validation).....	49
2.5.3 Ισοκατανεμημένα Δεδομένα σε K-Επίπεδα (Stratified K-Folds).....	49
2.5.4 Διερευνητική Ανάλυση Δεδομένων (EDA: Exploratory Data Analysis).....	50
2.5.5 Αλγόριθμος Βελτιστοποίησης Μηχανικής Μάθησης ADAM.....	51
2.5.6 Μετρητικές Ποσοτικοποιήσεις Αξιολόγησης Απόδοσης.....	51

3	ΚΕΦΑΛΑΙΟ 3° : Ασύρματη Ανίχνευση (Wireless Sensing).....	53
3.1	Εισαγωγή στην Ασύρματη Ανίχνευση.....	53
3.2	Εφαρμογές.....	54
3.2.1	Καταμέτρηση Αριθμού Ατόμων σε Εσωτερικό Χώρο.....	54
3.3	Ανίχνευση μέσω WiFi και Βαθιάς Μάθησης.....	55
4	ΚΕΦΑΛΑΙΟ 4° : Τεχνικό μέρος.....	56
4.1	Προσέγγιση Υλοποίησης.....	56
4.1.1	Περιγραφή.....	56
4.1.2	Σχέδιο-Αρχιτεκτονική Υλοποίησης.....	57
4.2	Πειραματική Διαδικασία.....	57
4.2.1	Εισαγωγή στη Διεξαγωγή Πειραμάτων.....	57
4.3	Λογισμικά Προγράμματα.....	58
4.3.1	Arduino IDE.....	58
4.3.2	Matlab.....	58
4.3.3	Putty.....	59
4.3.4	Visual Studio Code.....	59
4.4	Αισθητήριο Σύστημα Ανίχνευσης Πραγματικού Αριθμού Ατόμων.....	59
4.4.1	Εξοπλισμός.....	60
4.4.2	Κατασκευή, Προγραμματισμός και Εγκατάσταση Συστήματος.....	61
4.4.3	Αρχιτεκτονική Συστήματος.....	63
4.4.4	Τρόπος Χρήσης και Λειτουργίας.....	64
4.4.5	Εξαγωγή Δεδομένων.....	64
4.5	Σύστημα καταγραφής CSI Δεδομένων.....	66
4.5.1	Εξοπλισμός.....	66
4.5.2	Τρόπος Λειτουργίας και Εξαγωγή Δεδομένων.....	67
4.6	Κάτοψη Χώρου Διεξαγωγής.....	70
4.7	Καταγραφή, Επεξεργασία και Τιτλοφόρηση Δεδομένων.....	71
4.7.1	Διαδικασία Καταγραφής Δεδομένων.....	71
4.7.2	Επεξεργασία JSON αρχείων.....	72
4.7.3	Τιτλοφόρηση Δεδομένων (Labeling).....	72
4.7.4	Προεπεξεργασία και Οριστικοποίηση Τελικού Σειτ Δεδομένων.....	73
4.8	Εκπαίδευση Αλγορίθμων Μηχανικής Μάθησης.....	74
4.8.1	GNB (Gaussian Naive Bayes).....	74
4.8.2	XGBoost.....	74
4.8.3	LightGBM.....	74
4.8.4	Feed-forward Neural Network.....	75
4.8.5	Μετα-μοντέλο FNN.....	76
5	ΚΕΦΑΛΑΙΟ 5° : Αποτελέσματα και Αξιολόγηση.....	78
5.1	Αποτελέσματα.....	78
5.1.1	Gaussian Naive Bayes.....	78
5.1.2	XGBoost.....	79
5.1.3	LightGBM.....	79
5.1.4	Feed-forward Neural Network.....	80
5.2	Αξιολόγηση.....	88
5.2.1	Αξιολόγηση Αποτελεσμάτων Πειραματικής Διαδικασίας.....	88
5.3	Προβλήματα και Προβληματισμοί κατά την Υλοποίηση.....	93
6	Συμπεράσματα και Παρατηρήσεις.....	95
6.1.1	Παρατηρήσεις.....	95
6.1.2	Συμπεράσματα.....	95
	Βιβλιογραφία – Αναφορές - Διαδικτυακές Πηγές.....	97
	Παράρτημα Α: Κώδικας.....	100
	Παράρτημα Β: Πίνακες.....	110

Κατάλογος Πινάκων

Πίνακας 1.1 Ζώνες Συχνοτήτων κατά IEEE [1].....	[111]
Πίνακας 1.2 Ζώνες Συχνοτήτων κατά ITU [1].....	[111]
Πίνακας 2.1 Παράδειγμα Πίνακα Σύγκυσης Δύο Κλάσεων.....	[42]
Πίνακας 5.1 Πίνακας Σύγκυσης FNN Δύο Κλάσεων	[80]
Πίνακας 5.2 Πίνακας Σύγκυσης FNN Τριών Κλάσεων.....	[81]
Πίνακας 5.3 Πίνακας Σύγκυσης FNN Πέντε Κλάσεων.....	[83]
Πίνακας 5.4 Πίνακας Σύγκυσης FNN Πέντε Κλάσεων.....	[86]
Πίνακας 5.5 Πίνακας Σύγκυσης FNN Δύο Κλάσεων Χώρου Α.....	[87]
Πίνακας 5.6 Πίνακας Σύγκυσης FNN Τριών Κλάσεων Χώρου Α.....	[87]
Πίνακας 5.7 Πίνακας Σύγκυσης FNN Τριών Κλάσεων Χώρου Α.....	[88]
Πίνακας 5.8 Πίνακας Σύγκυσης Μετά Μοντέλου FNN Πέντε Κλάσεων Χώρου Α.....	[89]
Πίνακας 5.9 Πίνακας Σύγκυσης FNN Δύο Κλάσεων Χώρου Β.....	[89]
Πίνακας 5.10 Πίνακας Σύγκυσης FNN Τριών Κλάσεων Χώρου Β.....	[90]
Πίνακας 5.11 Πίνακας Σύγκυσης FNN Πέντε Κλάσεων Χώρου Β.....	[90]
Πίνακας 5.12 Πίνακας Σύγκυσης Μετά Μοντέλου FNN Πέντε Κλάσεων Χώρου Β.....	[91]

Κατάλογος Σχημάτων

Σχήμα 2.1: Σχηματικό Διάγραμμα Επιβλεπομένης Μάθησης.....	[36]
Σχήμα 2.2: Σχηματικό Διάγραμμα Μάθησης Διόρθωσης Σφάλματος.....	[37]
Σχήμα 2.3: Σχηματικό Διάγραμμα Μη Επιβλεπομένης Μάθησης.....	[38]
Σχήμα 2.4: Σχηματικό Διάγραμμα Ενισχυμένης Μάθησης.....	[39]
Σχήμα 2.5: Perceptron.....	[40]
Σχήμα 2.6: Αρχιτεκτονική δομή Perceptron πολλαπλών επιπέδων με δύο κρυφά επίπεδα.....	[41]
Σχήμα 2.7: Συναρτήσεις Ενεργοποίησης Νευρωνικών Δικτύων Εμπρόσθιας Τροφοδότησης..	[42]
Σχήμα 2.8: Τεχνική Διασταυρωμένης Επικύρωσης.....	[46]
Σχήμα 2.9: Πολλαπλά Επίπεδα Διασταυρωμένης Επικύρωσης και η μέθοδος Πολλαπλής Διασταύρωσης.....	[47]
Σχήμα 2.10. Σχηματική αναπαράσταση μεθόδου Ισοκατανεμημένων Πολλαπλών Επιπέδων..	[48]
Σχήμα 4.1 Διάγραμμα Διαδικασιών Υλοποίησης Συστήματος.....	[55]

Καταμέτρηση Αριθμού Ατόμων σε Εσωτερικό Χώρο Μέσω Ανίχνευσης Wi-Fi και Χρήσης Μηχανικής Μάθησης	
Σχήμα 4.2 Συνδεσμολογική Διάταξη Συστήματος Ανίχνευσης Πραγματικού Αριθμού Ατόμων	[61]
Σχήμα 4.3 Κάτοψη Χώρου Διεξαγωγής Καταγραφής Δεδομένων Εκπαίδευσης	[69]
Σχήμα 4.4 Κάτοψη Χώρου Α Διεξαγωγής Καταγραφής Δεδομένων Αξιολόγησης	[70]

Κατάλογος Εικόνων

Εικόνα 1.1: Ηλεκτρομαγνητικό φάσμα [34]	[19]
Εικόνα 1.2: Γραμμική Πόλωση Ηλεκτρικού Πεδίου [2]	[20]
Εικόνα 1.3: Κυκλική Πόλωση Ηλεκτρικού Πεδίου [2]	[20]
Εικόνα 1.4: Ελλειπτική Πόλωση Ηλεκτρικού Πεδίου [2]	[21]
Εικόνα 1.5: Τετραγωνική Διάταξη Ημιτονοειδών Σημάτων [4]	[22]
Εικόνα 1.6: Ψηφιακή Διαμόρφωση IQ Σημάτων [4]	[23]
Εικόνα 1.7: Φασικό Διάγραμμα Διαμόρφωσης RF Σημάτων [4]	[23]
Εικόνα 1.8: Παράδειγμα Φασικού Διαγράμματος OFDM με ισαπέχοντες φακέλους κέρδους συχνοτήτων [13]	[26]
Εικόνα 1.9: Μπλοκ διάγραμμα απλής αρχιτεκτονικής πομπού [5]	[27]
Εικόνα 1.10: Μπλοκ διάγραμμα αρχιτεκτονικής πομπού με χρήση OFDM τεχνολογίας [13]	[27]
Εικόνα 1.11: Μπλοκ διάγραμμα απλής αρχιτεκτονικής δέκτη [5]	[28]
Εικόνα 1.12: Μπλοκ διάγραμμα αρχιτεκτονικής δέκτη απευθείας μετατροπή και διαχωρισμό RF σήματος σε δείγματα IQ [6]	[28]
Εικόνα 1.13: Μπλοκ διάγραμμα αρχιτεκτονικής δέκτη με χρήση OFDM τεχνολογίας [13]	[29]
Εικόνα 1.14: Μοντέλο αναφοράς TCP/IP πέντε επιπέδων [14]	[31]
Εικόνα 1.15: Διάγραμμα εξυπηρέτησης πελατών με OFDMA [16]	[33]
Εικόνα 1.16: Διαμόρφωση σε 1024 μιγαδικά δείγματα [22]	[33]
Εικόνα 2.1: Κανονική Κατανομή Πιθανοφάνειας μίας Παραμέτρου [18]	[44]
Εικόνα 2.2: Ανάπτυξη δενδρικών δομών βάσει επιπέδου (Level-wise) και βάσει κόμβου (Leaf-wise) [19]	[45]
Εικόνα 2.3: Παράδειγμα Λειτουργικής Καμπύλης Δέκτη [15]	[50]
Εικόνα 3.1 Πλαίσιο Ασύρματης Ανίχνευσης [24]	[51]
Εικόνα 4.1: Πυροηλεκτρικός Υπέρυθρος Αισθητήρας Κίνησης [35]	[58]
Εικόνα 4.2: Arduino UNO R3 [36]	[58]

Εικόνα 4.3: Generic UNO Proto Shield Prototype Expansion [37]	[59]
Εικόνα 4.4 Εξωτερική Εμφάνιση Κουτιού.....	[60]
Εικόνα 4.5 Εσωτερική Τοπολογία Κουτιού.....	[60]
Εικόνα 4.6 Τριγωνικές Ξύλινες Κατασκευές.....	[60]
Εικόνα 4.7 Τελειοποιημένη πλακέτα RTC.....	[61]
Εικόνα 4.8 Τοπολογία RTC.....	[61]
Εικόνα 4.9 Χαρακτηριστικά Επικοινωνίας για Καταγραφή Δεδομένων.....	[63]
Εικόνα 4.10 Καταγραφή Δεδομένων και Δημιουργία JSON Αρχείου.....	[63]
Εικόνα 4.11 Εμφάνιση Καταγραφών Συστήματος.....	[64]
Εικόνα 4.12 (α) BK7235.....	[64]
Εικόνα 4.12 (β) BK7235.....	[64]
Εικόνα 4.13 ADALM PLUTO SDR.....	[65]
Εικόνα 4.14 Ρύθμιση Παραμέτρων Πομπού και Έλεγχος Επικοινωνίας.....	[66]
Εικόνα 4.15 Ρύθμιση Παραμέτρων Δέκτη και Έλεγχος Επικοινωνίας.....	[66]
Εικόνα 4.16 Περιβάλλον Καταγραφής και Παρουσίασης Καλύτερων Πακέτων.....	[67]
Εικόνα 4.17 Ιστόγραμμα Κατανομής Συνολικών Δεδομένων.....	[71]
Εικόνα 5.1 Αποτελέσματα GNB Δύο Κλάσεων.....	[76]
Εικόνα 5.2 Αποτελέσματα GNB Τριών Κλάσεων.....	[76]
Εικόνα 5.3 Αποτελέσματα GNB Πέντε Κλάσεων.....	[76]
Εικόνα 5.4 Αποτελέσματα XGBoost Δύο Κλάσεων.....	[77]
Εικόνα 5.5 Αποτελέσματα XGBoost Τριών Κλάσεων.....	[77]
Εικόνα 5.6 Αποτελέσματα XGBoost Πέντε Κλάσεων.....	[77]
Εικόνα 5.7 Αποτελέσματα LightGBM Δύο Κλάσεων.....	[77]
Εικόνα 5.8 Αποτελέσματα LightGBM Τριών Κλάσεων.....	[78]
Εικόνα 5.9 Αποτελέσματα LightGBM Πέντε Κλάσεων.....	[78]
Εικόνα 5.10 Ακρίβειες FNN Δύο Κλάσεων.....	[78]
Εικόνα 5.11 Καμπύλες Ακρίβειας Εκπαίδευσης και Αξιολόγησης FNN Δύο Κλάσεων.....	[79]
Εικόνα 5.12 Καμπύλες Απωλειών Εκπαίδευσης και Αξιολόγησης FNN Δύο Κλάσεων.....	[79]

Καταμέτρηση Αριθμού Ατόμων σε Εσωτερικό Χώρο Μέσω Ανίχνευσης Wi-Fi και Χρήσης Μηχανικής Μάθησης	
Εικόνα 5.13 Ακρίβειες FNN Τριών Κλάσεων.....	[80]
Εικόνα 5.15 Καμπύλες Ακρίβειας Εκπαίδευσης και Αξιολόγησης FNN Τριών Κλάσεων.....	[81]
Εικόνα 5.16 Ακρίβειες FNN Πέντε Κλάσεων.....	[81]
Εικόνα 5.17 Καμπύλες Απωλειών Εκπαίδευσης και Αξιολόγησης FNN Πέντε Κλάσεων.....	[82]
Εικόνα 5.18 Καμπύλες Ακρίβειας Εκπαίδευσης και Αξιολόγησης FNN Πέντε Κλάσεων.....	[82]
Εικόνα 5.19 Ιστόγραμμα FNN 18 Χαρακτηριστικών Εκπαίδευσης.....	[83]
Εικόνα 5.20 Συνοπτικό Ιστόγραμμα FNN Δύο Κλάσεων.....	[84]
Εικόνα 5.21 Συνοπτικό Ιστόγραμμα FNN Τριών Κλάσεων.....	[84]
Εικόνα 5.22 Συνοπτικό Ιστόγραμμα FNN Πέντε Κλάσεων.....	[85]
Εικόνα 5.23 Ακρίβειες Μέτα-Μοντέλου FNN Πέντε Κλάσεων.....	[85]
Εικόνα 5.24 Ακρίβειες Μέτα-Μοντέλου FNN Πέντε Κλάσεων Χώρου Α.....	[88]
Εικόνα 5.25 Ακρίβειες Μέτα-Μοντέλου FNN Πέντε Κλάσεων Χώρου Β.....	[91]

Αλφαβητικό Ευρετήριο

AP: Access Point

BPF: Band Pass Filter

BPSK: Binary Phase Shift Key

CFO: Carrier Frequency Offset

CSI: Channel State Information

DAC: Digital to Analog Converter

DSP: Digital Signal Processor

FNN: Feed-forward Neural Network

GNB: Gaussian Naive Bayes

IEEE : The Institute for Electrical and Electronics Engineers

IF: Intermediate Frequency signal

ISO: International Organization for Standardization

ITU: International Telecommunication Unit

LHCP: Left Hand Circular Polarization

LightGBM: Light Gradient Boosting Machine

LO: Local Oscillator signal

LoS: Line-of-Sight

LPF: Low Pass Filter

MAC: Medium Access Control

MCS: Modulation and Coding Schemes

MU-OFDMA: Multi-User Orthogonal Frequency Division Multiple Access

PHY Layer: Physical Layer

PIR: Pyroelectric InfraRed

PLCP: Physical Layer Convergence Procedure

ΠΑΔΑ Τμήμα Η&ΗΜ, Διπλωματική Εργασία, Ιωάννης Σπανακάς

PMD: Physical Medium Dependent

QAM: Quadrature Amplitude Modulation

QPSK: Quadrature Phase Shift Key

RF: Radio Frequency signal

RHCP : Right Hand Circular Polarization

SMOTE: Synthetic Minority Over-sampling Technique

SNR: Sound to Noise Ratio

TCP/IP: Transmition Control Protocol/ Internet Protocol

TWT: Target Wake Time

XGBoost: eXtreme Gradient Boosting

ΕΙΣΑΓΩΓΗ

Στη σύγχρονη κοινωνία του ανθρώπου, όπου οι ανάγκες και τα επερχόμενα προβλήματα πλήττουν μεγάλο μέρος της παγκόσμιας επικράτειας, γίνεται όλο και περισσότερο αναγκαία, η εφαρμογή καινούργιων τεχνολογιών και μεθόδων ώστε να διατηρηθεί ή και να εξελιχθεί ο τρόπος διαβίωσης του. Για αυτόν τον λόγο χιλιάδες μηχανικοί και εταιρείες ανά τον κόσμο έχουν κληθεί να φέρουν την νέα γενιά τεχνολογιών που θα επιτελούν αυτό το έργο.

Μία τεχνολογία εξ αυτών, είναι η τεχνητή νοημοσύνη, η οποία έχει αρχίσει και κατακλύζει το μεγαλύτερο κομμάτι της αγοράς και της καθημερινότητας. Εφαρμόζεται σε πολλούς τομείς της κοινωνίας μας, βοηθώντας τη βελτίωση της καθημερινής μας ζωής αλλά είναι και ένα πολύ χρήσιμο εργαλείο των μηχανικών αλλά και άλλων επαγγελματιών. Χάρη στη τεχνητή νοημοσύνη έχει μειωθεί το ανθρώπινο σφάλμα σε πολλούς τομείς.

Η εξέλιξη του πρωτοκόλλου Wi-Fi, η οποία ήρθε, καθώς η ανάγκη για εξυπηρέτηση περισσότερων τερματικών αυξανόταν και αυξάνεται. Με το πρωτόκολλο 802.11ax, οι ταχύτητες ξεπερνούν τις προηγούμενες, υπάρχει μεγαλύτερη και καλύτερη εξυπηρέτηση τερματικών καθώς και μπορεί να χρησιμοποιηθεί στην εξέλιξη τεχνολογιών όπως το Wi-Fi Sensing. Το Wi-Fi Sensing είναι μία σχετικά ανερχόμενη τεχνολογία η οποία χρησιμοποιείται σε διάφορες εφαρμογές, κυρίως στους τομείς της υγείας και αποτελεί ένα νέο αισθητήριο σύστημα.

Όλες οι προαναφερθείσες τεχνολογίες μπορούν να συνδυαστούν και να εφαρμοστούν στον τομέα του εντοπισμού αριθμού ατόμων σε εσωτερικό χώρο. Χρησιμοποιώντας τις δυνατότητες που προσφέρει το πρωτόκολλο 802.11ax, όσον αφορά την επικοινωνία ενός πομπού και ενός δέκτη, και αξιοποιώντας τις δυνατότητες πρόβλεψης της μηχανικής μάθησης, μπορεί να παραχθεί ένα ικανοποιητικό αποτέλεσμα όσον αφορά τον εντοπισμό αριθμού ατόμων και τον εντοπισμό θέσης. Οι εφαρμογές της συγκεκριμένης τεχνολογίας βοηθούν σε πολλές περιπτώσεις που απαιτείται επίβλεψη του εσωτερικού χώρου, για λόγους ασφάλειας των ατόμων που τον χρησιμοποιούν.

Αντικείμενο της διπλωματικής εργασίας

Η συγκεκριμένη διπλωματική πραγματεύεται την καταμέτρηση του αριθμού ατόμων σε εσωτερικό χώρο, αξιοποιώντας τεχνολογίες ασύρματων αισθητήριων συστημάτων και αλγόριθμους μηχανικής μάθησης.

Όπως φάνηκε την προηγούμενη τετραετία, ήταν δύσκολο να εξασφαλιστεί η ορθή τήρηση των υγειονομικών μέτρων, με αποτέλεσμα την αύξηση των κρουσμάτων από τον ιό SarsCovId-19 και κατά επέκταση την αύξηση των θανάτων. Είναι σημαντικό, λοιπόν, να μπορεί να σημειωθεί ο αριθμός των ατόμων σε έναν εσωτερικό χώρο, ώστε να τηρούνται, με μεγαλύτερη αποτελεσματικότητα, τα υγειονομικά μέτρα σε περιπτώσεις πανδημίας. Επιπροσθέτως, έχει παρατηρηθεί αύξηση των θανόντων ζώων και μικρών παιδιών από ασφυξία στον εσωτερικό χώρο αυτοκινήτων από αμέλεια.

Με την εγκατάσταση ενός συστήματος σε εσωτερικό χώρο, το οποίο μέσω ηλεκτρομαγνητικών κυμάτων και την εφαρμογή τεχνητής νοημοσύνης, ανιχνεύει τον αριθμό ατόμων που βρίσκονται σε αυτόν και με την ανάλογη επενέργεια, ανάλογα την περίπτωση χρήσης του συστήματος, μπορεί να σώσει ανθρώπινες ζωές είτε έμμεσα είτε άμεσα.

Σε αυτήν την εργασία παρουσιάζεται ο τρόπος με τον οποίο οι τεχνολογίες αυτές μπορούν να συντελέσουν στην δημιουργία ενός συστήματος που μπορεί να συμβάλει σημαντικά στην ασφάλεια των χρηστών ενός εσωτερικού χώρου.

Σκοπός και στόχοι

Βασικός σκοπός της εργασίας είναι η θέσπιση ενός εύρωστου συστήματος εντοπισμού αριθμού ατόμων σε εσωτερικό χώρο, ώστε να μπορέσει να χρησιμοποιηθεί αργότερα για το καλό της ανθρώπινης ασφάλειας.

Βασικοί στόχοι είναι:

- Γνωριμία με τη τεχνολογία Wi-Fi Sensing,
- Έρευνα σχετική με RF σήματα και με νεότερες εκδόσεις του πρωτοκόλλου 802.11ax
- Εξοικείωση με την ανάλυση και επεξεργασία RF σημάτων,
- Έρευνα σχετική με αλγόριθμους μηχανικής μάθησης και με τρόπους διαχείρισης δεδομένων,
- Εύρεση κατάλληλου αλγόριθμου μηχανικής μάθησης πρόβλεψης αριθμού ατόμων,
- Δημιουργία αξιόπιστου συστήματος αναπαράστασης πραγματικού αριθμού ατόμων ώστε να γίνει όσον το δυνατό μικρότερο σφάλμα στην κατηγοριοποίηση των σημάτων στον δέκτη,
- Δημιουργία αξιόπιστου σετ δεδομένων,
- Εξασφάλιση καλής επικοινωνίας μεταξύ πομπού δέκτη,
- Ελαχιστοποίηση εσφαλμένης πρόβλεψης αλγόριθμου.

Μεθοδολογία

Όσον αφορά τη μεθοδολογία που ακολουθήθηκε, αρχικά, έγινε σχετική έρευνα με το θέμα της διπλωματικής. Συγκεκριμένα, γνωρίζοντας ότι η διπλωματική εργασία χρησιμοποιεί δύο κύριες τεχνολογίες, την επικοινωνία μέσω Wi-Fi και την υπολογιστική νοημοσύνη, ερευνήθηκαν βασικές ορολογίες σχετικά με την διάδοση και συμπεριφορά των ραδιοσυχνοτικών σημάτων. Έπειτα, μελετήθηκε βιβλιογραφία για την αρχιτεκτονική του πρωτοκόλλου Wi-Fi [12 – 16], [20] και διερευνήθηκε περαιτέρω η επιρροή του στο Wi-Fi Sensing [21 - 25]. Στη συνέχεια, μελετήθηκαν κάποιοι αλγόριθμοι και έννοιες στη μηχανική μάθηση [17 - 19], εκτός αυτών που διδάχθηκαν στη σχολή, ώστε να εφαρμοστούν αργότερα στην εκπαίδευση του συστήματος ανίχνευσης αριθμού ατόμων και πραγματοποιήθηκε επανάληψη ορολογιών και μεθόδων που αφορούν τη μηχανική μάθηση.

Παράλληλα με τη έρευνα του θέματος, βελτιστοποιήθηκε το, ήδη υπάρχον, σύστημα επικοινωνίας πομπού δέκτη. Συγκεκριμένα, ο πομπός και ο δέκτης, που χρησιμοποιείται για την εξαγωγή των δεδομένων προς εκπαίδευση, είναι εξοπλισμός που προμηθεύτηκε από εταιρεία που ασχολείται με το συγκεκριμένο ζήτημα.

Στη συνέχεια, δημιουργήθηκε ένα αισθητήριο σύστημα που αναπαριστά τον πραγματικό αριθμό ατόμων που βρίσκονται στον χώρο (Ground Truth), του οποίου τα δεδομένα συγκρίνονται με τα δεδομένα που εξάγονται από το σύστημα επικοινωνίας πομπού δέκτη και κατηγοριοποιούνται (Classification), ώστε να θεσπιστεί το τελικό, προς εκπαίδευση και αξιολόγηση σετ δεδομένων.

Σε επόμενο στάδιο, εγκαταστάθηκε ο εξοπλισμός στον χώρο που υποδείχθηκε από τον επιβλέποντα καθηγητή και δοκιμάστηκε, ώστε να εξακριβωθεί η ορθή λειτουργία και των δύο συστημάτων.

Αφού “χτίστηκε” ένα ικανοποιητικό, σε είδη και αριθμό δεδομένων, σετ, εκπαιδεύτηκαν οι αλγόριθμοι και εν τέλει επιλέχθηκε ο κατάλληλος αλγόριθμος που εξάγει καλό ποσοστό επιτυχίας στις προβλέψεις του. Έπειτα δοκιμάστηκε η απόδοσή του σε άλλους δύο χώρους και εξάχθηκαν κάποια σημαντικά συμπεράσματα αναφορικά με την ικανότητα γενίκευσής του.

Ποιο συνοπτικά η μεθοδολογία που ακολουθήθηκε μπορεί να αποδοθεί με τα παρακάτω βήματα.

Βήμα 1° : Έρευνα και μελέτη θεματικών κατηγοριών

Βήμα 2° : Βελτιστοποίηση, δημιουργία και οριστικοποίηση συστημάτων εξαγωγής δεδομένων.

Βήμα 3° : Εγκατάσταση συστημάτων στο χώρο διεξαγωγής

Βήμα 4° : Εξαγωγή και επεξεργασία δεδομένων

Βήμα 5° : Εκπαίδευση αλγορίθμων μηχανικής μάθησης

Βήμα 6° : Αξιολόγηση αποτελέσματος σε άλλους χώρους.

Δομή

Η εκπονηθείσα διπλωματική εργασία, θεωρήθηκε θεμιτό να οργανωθεί με γνώμονα την κατανόηση, σε πρώτο επίπεδο, των τεχνολογιών που αξιοποιήθηκαν κατά την υλοποίηση των συστημάτων και έπειτα την αξιολόγηση της αποδοτικότητας του συγκεκριμένου συστήματος ανίχνευσης και πρόβλεψης αριθμού ατόμων που εφαρμόστηκε.

Πιο συγκεκριμένα, η διπλωματική εργασία αποτελείται από δύο βασικές δομικές κατηγορίες. Η πρώτη αφορά την ανάλυση και την έρευνα που πραγματοποιήθηκε για τις τεχνολογίες που χρησιμοποιήθηκαν και αποτελείται, με τη σειρά της, από τρεις θεματικές ενότητες.

Η πρώτη θεματική ενότητα (Κεφάλαιο 1), της πρώτης δομικής κατηγορίας, αφορά την εισαγωγή του αναγνώστη σε κάποιες βασικές έννοιες σχετικά με τα ραδιοσυχνотικά σήματα και τη συμπεριφορά τους, όπως και κάποιες τεχνικές αξιοποίησής τους για μεγαλύτερη αποτελεσματικότητα στα προς μελέτη συστήματα. Στη συνέχεια, της ενότητας αυτής, επεξηγείται η λειτουργία και δομή του Wi-Fi πρωτοκόλλου, με έμφαση στο πρωτόκολλο 802.11ax, το οποίο χρησιμοποιείται.

Έπειτα, στην δεύτερη θεματική ενότητα (Κεφάλαιο 2), ο αναγνώστης ξεναγείται στον κόσμο της τεχνητής νοημοσύνης. Συγκεκριμένα, αναλύεται η υπολογιστική νοημοσύνη εμβαθύνοντας στα είδη μηχανικής μάθησης, σε βασικές δομές αλγορίθμων μηχανικής μάθησης και σε τεχνικές βελτιστοποίησης και εκπαίδευσης που μπορούν να εφαρμοστούν και εφαρμόζονται στην συγκεκριμένη διπλωματική εργασία.

Τέλος, στην τρίτη θεματική ενότητα (Κεφαλαίο 3), δίνεται η δυνατότητα στον αναγνώστη να γνωρίσει την χρησιμότητα και την απήχηση που έχει στην κοινωνία μας η τεχνολογία του Wi-Fi Sensing καθώς και κάποια επιτεύγματα που έχουν πραγματοποιηθεί τα προηγούμενα χρόνια σχετικά με αυτήν την τεχνολογία.

Έπειτα από την ανάγνωση και επεξήγηση των τεχνολογιών που χρησιμοποιήθηκαν, ο αναγνώστης είναι πλέον έτοιμος να κατανοήσει την δεύτερη βασική δομική κατηγορία στην οποία παρατίθεται το τεχνικό μέρος της διπλωματικής εργασίας (Κεφαλαίο 4). Σε αυτό, παρουσιάζεται ο σχεδιασμός και οι στόχοι της υλοποίησης, καθώς επίσης και όλη η υλικοτεχνική υποδομή που συνετέλεσε

στην δόμηση του συστήματος ανίχνευσης και αρίθμησης ατόμων σε εσωτερικό χώρο, καθώς επίσης προβλήματα και προβληματισμοί που προέκυψαν κατά τη διαδικασία. Ακολουθεί η αξιολόγηση όσον αφορά την λειτουργικότητα των συστημάτων, την αποδοτικότητα και το τελικό αποτέλεσμα. Επίσης, αξιολογείται το κατά πόσο επιτεύχθηκαν οι στόχοι της διπλωματικής εργασίας (Κεφάλαιο 5).


Τέλος, στην τελευταία ενότητα (Κεφάλαιο 6) αποδίδονται τα συμπεράσματα όσον αφορά τη χρήση των προαναφερθέντων τεχνολογιών και της υλοποίησης, καθώς επίσης στα παραρτήματα που ακολουθούν παρατίθενται κάποια ζωτικής σημασίας τμήματα κώδικα, ώστε ο αναγνώστης να μπορεί να εμβαθύνει και να κατανοήσει καλύτερα τις διαδικασίες που δομούν τα συστήματα και τους τρόπους αξιοποίησης των αλγορίθμων μηχανικής μάθησης.

1 ΚΕΦΑΛΑΙΟ 1^ο : Βασικές Έννοιες και Πρωτόκολλο Wi-Fi

Σε αυτό το κεφάλαιο αναλύονται και εξηγούνται κάποιες βασικές έννοιες σχετικά με τις συμπεριφορικές αρχές των ηλεκτρομαγνητικών κυμάτων, καθώς επίσης και κάποιες τεχνικές επεξεργασίας αυτών για τη αξιοποίηση της επιθυμητής, προς εξαγωγή, πληροφορίας. Είναι σημαντικό να κατανοηθούν οι συγκεκριμένες εισαγωγικές έννοιες, ώστε να διευκολυνθεί ο αναγνώστης ως προς την κατανόηση των μετέπειτα εφαρμογών και να μπορέσει να αντιληφθεί την φυσική υπόσταση των φαινομένων που διέπουν αυτήν τη διπλωματική εργασία.

1.1 Ραδιοσυχνοτικά Σήματα (RF Signals)

Τα ραδιοσυχνοτικά σήματα ή ραδιοκύματα είναι ηλεκτρομαγνητικά κύματα των οποίων η συχνότητα κυμαίνεται από 3Hz έως 300GHz και καταλαμβάνουν μεγάλο τμήμα της ηλεκτρομαγνητικής ακτινοβολίας. Σε αυτό το μεγάλο εύρος συχνοτήτων εμπεριέχονται τα μικροκύματα με εύρος συχνοτήτων 300MHz με 300GHz όπως φαίνεται και στην *Εικόνα 1.1*.



Εικόνα 1.1: Ηλεκτρομαγνητικό φάσμα [34]


Το συχνοτικό φάσμα των ραδιοκυμάτων χωρίζεται σε ζώνες στις οποίες υλοποιούνται τηλεπικοινωνιακές εφαρμογές. Οι ζώνες συχνοτήτων σύμφωνα με τη Διεθνή Ένωση Τηλεπικοινωνιών (ITU) παρατίθενται στο Παράρτημα Α και σύμφωνα με το Ινστιτούτο Ηλεκτρολόγων και Ηλεκτρονικών Μηχανικών (IEEE) καθορίζονται βάσει του *Πίνακα 1.1* [1]. Οι συμπεριφορικές αρχές των ραδιοκυμάτων είναι ίδιες με όλων των υπολοίπων ηλεκτρομαγνητικών κυμάτων του φάσματος και κάποιες από αυτές αναλύονται στη συνέχεια του κεφαλαίου.

1.1.1 Πόλωση Ηλεκτρομαγνητικού Κύματος

Γενικά, ένα ηλεκτρομαγνητικό κύμα, που ταξιδεύει στο κανάλι επικοινωνίας δύο κεραιών, μπορεί να πολωθεί με τρεις διαφορετικούς τρόπους και ανάλογα την περίπτωση της εφαρμογής να αξιοποιηθεί καταλλήλως. Οι τρεις αυτές πολώσεις είναι η *γραμμική πόλωση*, η *κυκλική* και η *ελλειπτική πόλωση*.


Η *γραμμική πόλωση* διακρίνεται σε τρεις κατηγορίες οι οποίες δημιουργούνται βάσει της ταλάντωσης του ηλεκτρικού πεδίου. Η πρώτη εξ αυτών είναι η κάθετη πόλωση, κατά την οποία το

ηλεκτρικό πεδίο ταλαντώνεται στον κάθετο άξονα, η δεύτερη ονομάζεται οριζόντια πόλωση, με το ηλεκτρικό πεδίο να ταλαντώνεται στον οριζόντιο άξονα και η τρίτη είναι η διαγώνια πόλωση στην οποία το ηλεκτρικό πεδίο ταλαντώνεται υπό γωνία 45 μοιρών.



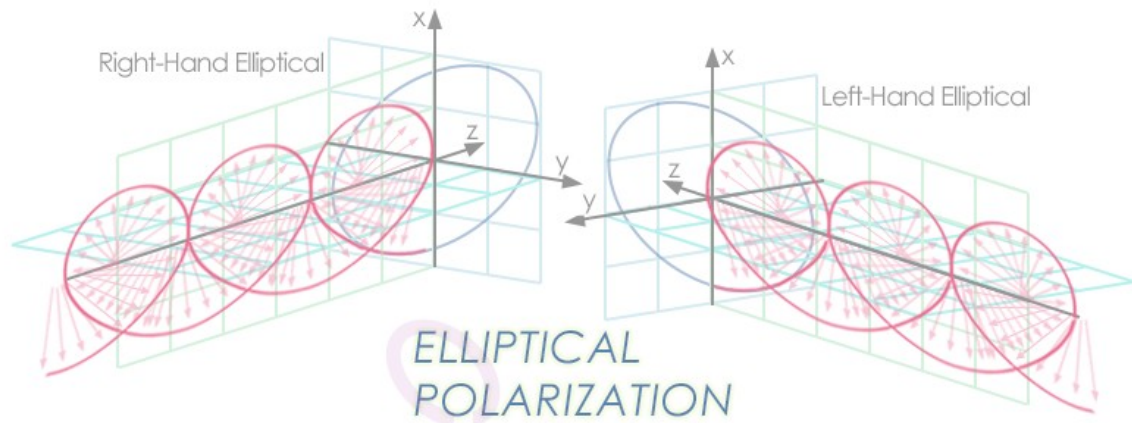
Εικόνα 1.2: Γραμμική Πόλωση Ηλεκτρικού Πεδίου [2]

Η κυκλική πόλωση αναφέρεται στην περιστροφική κίνηση του ραδιοκύματος που πραγματοποιείται κατά την μετάδοση. Αν η περιστροφή είναι δεξιόστροφη τότε η πόλωση ονομάζεται Δεξιά Κυκλική Πόλωση (RHCP), ενώ αν είναι αριστερόστροφη, Αριστερή Κυκλική Πόλωση (LHCP).



Εικόνα 1.3: Κυκλική Πόλωση Ηλεκτρικού Πεδίου [2]

Η ελλειπτική πόλωση συμβαίνει όταν το ηλεκτρομαγνητικό κύμα στρέφεται ελλειπτικά κατά τη μετάδοση του. Όμοια με την κυκλική πόλωση, η ελλειπτική διακρίνεται σε δεξιά και αριστερή ελλειπτική πόλωση, όπως φαίνεται και στην Εικόνα 1.4.



Εικόνα 1.4: Ελλειπτική Πόλωση Ηλεκτρικού Πεδίου [2]

Η πόλωση του ηλεκτρομαγνητικού κύματος, σε ένα τηλεπικοινωνιακό σύστημα, παίζει σημαντικό ρόλο, καθώς ανάλογα το είδος της, αλλά και την αρχιτεκτονική τοπολογία πομπού και δέκτη, μπορεί να συμβάλει στην ποιότητα, της τελικής προς επεξεργασία, πληροφορίας.

Η κυκλική πόλωση παρουσιάζει κάποια σημαντικά πλεονεκτήματα έναντι των άλλων δύο πολώσεων. Τα πλεονεκτήματα αυτά, αφορούν κάποιες ιδιότητες της συγκεκριμένης πόλωσης. [3]

Αρχικά, όσον αφορά την ανακλαστικότητα του κύματος, όταν ένα ηλεκτρομαγνητικό κύμα έρχεται σε επαφή με την ύλη, ανάλογα το υλικό, ένα ποσοστό του κύματος θα απορροφηθεί και ένα άλλο θα ανακλαστεί. Όταν η πόλωση είναι γραμμική τότε το προσπίπτον κύμα ταξιδεύει σε ένα πεδίο, φτάνει στην προσπίπτουσα επιφάνεια, και αν μεγάλο μέρος του απορροφηθεί, κατά την επιστροφή του μπορεί να είναι τόσο αδύναμο που να χαθεί. Στην κυκλική πόλωση, όμως, δυσκολότερα χάνεται η πληροφορία, καθώς το κύμα ταξιδεύει σε πολλαπλά πεδία κατά την μετάδοσή του, δίνοντας μεγαλύτερη πιθανότητα επιτυχούς σύνδεσης.

Έπειτα, τα συστήματα επικοινωνίας που λειτουργούν με κυκλική πόλωση στις κεραίες τους, μπορούν να αποφύγουν προβλήματα που δημιουργούνται στον δέκτη λόγω των πολλαπλών διαδρομών του σήματος (Multi-path). Οι πολλαπλές διαδρομές δημιουργούνται από τις ανακλάσεις του σήματος στον χώρο μετάδοσης, απαιτώντας πόρους από τον δέκτη για την αποσαφήνιση και επεξεργασία της πληροφορίας. Ένα γραμμικά πολωμένο κύμα είναι περισσότερο επιρρεπές στο φαινόμενο του Multi-path, δημιουργώντας προβλήματα στην επεξεργασία του σήματος στον δέκτη, όπως μείωση του throughput, μείωση απόδοσης σε συστήματα που επικοινωνούν στα 2.4 GHz κα.


Τέλος, η κυκλική πόλωση μπορεί να διατηρεί, πιο αποδοτικά, συνδέσεις όταν υπάρχουν εμπόδια στο Line-of-Sight, από ότι η γραμμική πόλωση.

1.1.2 Δείγματα IQ

Τα δείγματα IQ ή σήματα χρησιμοποιούνται σε εφαρμογές που επεξεργάζονται ραδιοσυχνотικά σήματα και αποτελούν τη βάση για διαμόρφωση και απο-διαμόρφωση ραδιοσυχνотικών σημάτων. Σε αυτήν την ενότητα αναλύεται η χρήση και η ποιότητα των σημάτων αυτών.

Τα σήματα IQ είναι μιγαδικά σήματα, δηλαδή έχουν μέτρο και φάση. Είναι σήματα βασικής ζώνης και μπορούν να είναι είτε ψηφιακά είτε αναλογικά. Όταν ένα ζεύγος περιοδικών σημάτων έχουν διαφορά φάσης 90 μοίρες, τότε λέγεται ότι βρίσκονται σε τετραγωνική διάταξη (in Quadrature). Το σήμα αναφοράς (in-phase signal) είναι αυτό που συμβολίζεται με I και το σήμα με διαφορά φάσης 90 μοιρών με Q.

Ένα παράδειγμα δύο ημιτονοειδών σημάτων, που βρίσκονται σε τετραγωνική διάταξη είναι το ημίτονο και το συνημίτονο, όπως φαίνεται και στην παρακάτω εικόνα.



Εικόνα 1.5: Τετραγωνική Διάταξη Ημιτονοειδών Σημάτων [4]

Στο συγκεκριμένο παράδειγμα το σήμα αναφοράς είναι το ημίτονο και με I συμβολίζεται το πλάτος του, ενώ το 90 μοίρες μετατοπισμένο σήμα είναι το συνημίτονο και το πλάτος του συμβολίζεται με Q . Στον οριζόντιο άξονα μετράται ο χρόνος και στον κάθετο το πλάτος.

Αν προστεθούν τα δύο αυτά ημιτονικά σήματα το αποτέλεσμα θα είναι ένα αντίστοιχο ημιτονικό σήμα μετατοπισμένο κατά 45 μοίρες. Αυξομειώνοντας, λοιπόν, τα πλάτη των δύο σημάτων αυτών, μπορούν να παραχθούν διαμορφωμένα ραδιοκύματα. [4]

1.1.3 Διαμόρφωση Πλάτους Τετραγωνικής Διάταξης (QAM: Quadrature Amplitude Modulation)


Όπως αναφέρθηκε στην προηγούμενη ενότητα, τα δείγματα IQ είναι η βάση της διαμόρφωσης των ραδιοσυχνοτικών σημάτων. Πιο συγκεκριμένα, όταν εναλλάσσονται οι τιμές των I και Q , δημιουργούνται διαφορετικά, διαμορφωμένα κατά πλάτος, ραδιοκύματα.

Για παράδειγμα, αν το $Q = 0$, το I κυμαίνεται από -1 έως 1 και το I μπορεί να ελεγχθεί, τότε δημιουργείται ένα Κλειδί Δυαδικής Μετατόπισης Φάσης (Binary Phase Shift Key).

Αν τώρα, και το I και το Q κυμαίνονται από -1 έως 1 , και για τον έλεγχο τους χρησιμοποιούνται απλοί τετραγωνικοί παλμοί, τότε το αποτέλεσμα της πρόσθεσης των σημάτων, θα έδινε σήματα σε τέσσερις διακριτές φάσεις.


Συγκεκριμένα:

- ◆ $I = 1$ & $Q = 1$, έχει ως αποτέλεσμα τις 45 μοίρες φάση
- ◆ $I = -1$ & $Q = 1$, έχει ως αποτέλεσμα τις 135 μοίρες φάση
- ◆ $I = -1$ & $Q = -1$, έχει ως αποτέλεσμα τις 225 μοίρες φάση
- ◆ $I = 1$ & $Q = -1$, έχει ως αποτέλεσμα τις 315 μοίρες φάση



Εικόνα 1.6: Ψηφιακή Διαμόρφωση IQ Σημάτων [4]

Οι συγκεκριμένες τιμές των I, Q και των μοιρών στην κάθε περίπτωση μπορούν να αποδοθούν γραφικά σε ένα φασικό διάγραμμα, το οποίο απεικονίζει το πλάτος και τη φάση της εκάστοτε περίπτωσης. Όπως φαίνεται στην παρακάτω εικόνα.



Εικόνα 1.7: Φασικό Διάγραμμα Διαμόρφωσης RF Σημάτων [4]

Στο παραπάνω φασικό διάγραμμα το μήκος του διανύσματος εκφράζει το πλάτος του κύματος και η γωνία που σχηματίζει με τον οριζόντιο άξονα τη φάση του.

Στο παράδειγμα αυτό δημιουργείται ένα Κλειδί Τετραγωνικής Μετατόπισης Φάσης (Quadrature Phase Shift Key ή QPSK) τεσσάρων σημείων. Υπάρχει 16 σημείων 64 και γενικά 4^n σημείων. [4]

Τα δύο παραπάνω παραδείγματα αποτελούν δύο περιπτώσεις ψηφιακής Διαμόρφωσης Πλάτους Τετραγωνικής Διάταξης RF σημάτων (QAM). Η διαμόρφωση πλάτους μπορεί να είναι και αναλογική καθώς στην πραγματικότητα τα σήματα αυτά είναι αναλογικά και αντίστοιχα μπορεί να γίνει απο-διαμόρφωση. Με την κατάλληλη δειγματοληψία, κβάντιση και κωδικοποίηση των αναλογικών ραδιοσυχνοτικών σημάτων, πραγματοποιείται η ψηφιακή επεξεργασία (συνήθως από την πλευρά του δέκτη σε τηλεπικοινωνιακά συστήματα) των σημάτων αυτών.

1.1.4 FFT & IFFT (Fast Fourier Transform & Inverse Fast Fourier Transform)

Ο μετασχηματισμός Fourier, αποτελεί ένα σημαντικό εργαλείο των μηχανικών για την ανάλυση και επεξεργασία σημάτων. Πιο συγκεκριμένα, ο μετασχηματισμός Fourier χρησιμοποιείται, όταν

κρίνεται αναγκαίο να μετασχηματιστεί ένα ή πολλά σήματα από το πεδίο του χρόνου στο πεδίο της συχνότητας και αντίστροφα, για την επίλυση του εκάστοτε προβλήματος.

Χάρι σε αυτό το εργαλείο μπορούν να μετασχηματιστούν συνεχή (αναλογικά) και διακριτά (ψηφιακά) σήματα. Στη συγκεκριμένη ενότητα θα δοθεί έμφαση στο μετασχηματισμό και την επεξεργασία ψηφιακών σημάτων.

Προτού γίνει αναφορά στον Ταχύ Μετασχηματισμό Fourier (FFT) και στον αντίστροφό του (Inverse FFT), πρέπει πρώτα να γίνει κατανοητός ο Διακριτός Μετασχηματισμός Fourier (DFT) και ο αντίστροφος του (Inverse DFT), καθώς ο πρώτος μετασχηματισμός αποτελεί τέχνασμα, για γρηγορότερη επεξεργασία, του δεύτερου.

Ο Διακριτός Μετασχηματισμός Fourier (DFT) εκφράζεται από την παρακάτω εξίσωση :

$$X(k) = \text{DFT}[x(n)] = \sum_{n=0}^{N-1} x(n) \cdot W_N^{nk}, \quad 0 \leq k \leq N-1 \quad (1.1)$$

Και ο αντίστροφός του:

$$x(n) = \text{IDFT}[X(k)] = \frac{1}{N} \sum_{k=0}^{N-1} X(k) \cdot W_N^{-nk}, \quad 0 \leq n \leq N-1 \quad (1.2)$$

Όπου:

$X(k)$: Διακριτό σήμα στο πεδίο της συχνότητας με k δείγματα,

$x(n)$: Διακριτό σήμα στο πεδίο του χρόνου με n δείγματα,

N : Μήκος ή συνολικός αριθμός διακριτών δειγμάτων,

$W_N = e^{-j\frac{2\pi}{N}}$ και ονομάζεται παράγοντας αναστροφής. [16]

Ο παράγοντας αναστροφής είναι το βασικό στοιχείο που συντελείται ο μετασχηματισμός, καθώς αν αναλυθεί, προκύπτει ότι αποτελείται από δύο (συν)ημιτονικά σήματα, διότι:

$$e^{jn} = \cos(n) - j \sin(n) \quad (1.3)$$

Από την Σχέση 1.3 μπορεί κανείς να αντιληφθεί ότι κάθε φορά το δειγματοληπτημένο σήμα, για κάθε k ή n δείγμα (εξαρτάται αν είναι αντίστροφος ή μη), πολλαπλασιάζεται με τις εκάστοτε συνιστώσες των (συν)ημιτονικών σημάτων, και το άθροισμα αυτών προσδίδει ως αποτέλεσμα το μετασχηματισμένο διακριτό σήμα στο εκάστοτε πεδίο (χρόνου ή συχνότητας).

Ο Ταχύς Μετασχηματισμός Fourier (FFT) είναι ένας αλγόριθμος που επιλύει προβλήματα που προκύπτουν κατά τη χρήση του Διακριτού Μετασχηματισμού Fourier (DFT). Συγκεκριμένα, για μεγάλο αριθμό N οι πράξεις που πρέπει να πραγματοποιηθούν είναι υπέρογκες, απαιτώντας μεγάλη υπολογιστική ισχύ από τα συστήματα. Ο αλγόριθμος FFT υλοποιεί τον DFT σε δύο βήματα όπως φαίνεται στο παρακάτω παράδειγμα.

Παράδειγμα 1.1

Έστω ότι χρειάζεται να υπολογιστεί ο DFT για 4 σημεία:

$$X(k) = \sum_{n=0}^3 x(n) \cdot W_4^{nk}, \quad 0 \leq k \leq 3, \quad W_4 = -j$$

Υπολογισμός με χρήση πινάκων:

$$\begin{bmatrix} X(0) \\ X(1) \\ X(2) \\ X(3) \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & W_4 & W_4^2 & W_4^3 \\ 1 & W_4^2 & W_4^4 & W_4^6 \\ 1 & W_4^3 & W_4^6 & W_4^9 \end{bmatrix} \cdot \begin{bmatrix} x(0) \\ x(1) \\ x(2) \\ x(3) \end{bmatrix} \Rightarrow \begin{bmatrix} X(0) \\ X(1) \\ X(2) \\ X(3) \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & -j & -1 & j \\ 1 & -1 & 1 & -1 \\ 1 & j & -1 & -j \end{bmatrix} \cdot \begin{bmatrix} x(0) \\ x(1) \\ x(2) \\ x(3) \end{bmatrix}$$

Παρατηρείται ότι πραγματοποιούνται 16 πολλαπλασιασμοί.

Αν αναπτυχθεί ως εξής:

$$\begin{aligned} X(0) &= x(0) + x(1) + x(2) + x(3) = [x(0) + x(2)] + [x(1) + x(3)] \\ X(1) &= x(0) - jx(1) - x(2) + jx(3) = [x(0) - x(2)] - j[x(1) - x(3)] \\ X(2) &= x(0) - x(1) + x(2) - x(3) = [x(0) + x(2)] - [x(1) + x(3)] \\ X(3) &= x(0) + jx(1) - x(2) + jx(3) = [x(0) - x(2)] + j[x(1) + x(3)] \end{aligned}$$

Με εφαρμογή του FFT, αντί να υλοποιηθεί DFT 4 σημείων, υλοποιούνται δύο DFT 2 σημείων.

Συγκεκριμένα θέτεται:

$$\begin{array}{ll} g_1 = x(0) + x(2) & X(0) = g_1 + g_2 \\ g_2 = x(1) + x(3) & X(1) = h_1 - jh_2 \\ h_1 = x(0) + x(2) & X(2) = g_1 - g_2 \\ h_2 = x(1) - x(3) & X(3) = h_1 + jh_2 \end{array} \quad \begin{array}{l} \text{Βήμα 1}^\circ \\ \text{Βήμα 2}^\circ \end{array}$$

Με αυτήν τη μέθοδο μειώνονται οι πράξεις από $4^2=16$ σε $2^2+2^2=8$. [16]


Η μέθοδος αυτή εφαρμόζεται αντίστοιχα και για τον αντίστροφο διακριτό μετασχηματισμό Fourier και ονομάζεται IFFT (Inverse Fast Fourier Transform).

1.1.5 Πολυπλεξία Ορθογωνικής Διαίρεσης Συχνότητας (OFDM: Orthogonal Frequency Division Multiplexing)

Η τεχνική Πολυπλεξίας Ορθογωνικών Διαιρεμένων Συχνοτήτων χρησιμοποιείται ευρέως, στις μέρες μας, κυρίως σε τηλεπικοινωνίες που χρησιμοποιούν πρωτόκολλο Wi-Fi και 5G, για την ψηφιακή επεξεργασία των σημάτων μετάδοσης.

Όπως αναφέρει ο H.Rohlin [17], η τεχνική Πολυπλεξίας Ορθογωνικών Διαιρεμένων Συχνοτήτων (OFDM), γενικά, διαιρεί το συνολικό εύρος ζώνης (Bandwidth) της συχνότητας σε στενότερα εύρη ή αλλιώς μικρότερα κανάλια τα οποία ισαπέχουν συχνοτικά μεταξύ τους. Τα υπο-κανάλια αυτά, συμπέφτουν το ένα πάνω στο άλλο, δηλαδή κάποιες συχνότητες, του φάκελου κέρδους της συχνότητας των καναλιών αυτών, είναι ίδιες. Παρά ταύτα, τα υπο-φέροντα σήματα παραμένουν ορθογωνικά μεταξύ τους. Η υψηλού ρυθμού ροή δεδομένων διαιρείται σε πολλές μικρές ροές δεδομένων χαμηλού ρυθμού, ώστε να μπορέσουν να συνδεθούν με τα εκάστοτε υπο-κανάλια.

Στην *Εικόνα 1.8* διαφαίνονται τα υπο-κανάλια που δημιουργούνται με την τεχνική OFDM, τα οποία είναι Δειγματικές Συναρτήσεις (sinc-functions) και παρατηρείται ότι έχουν κοινές συχνότητες, όπως προαναφέρθηκε.



Εικόνα 1.8: Παράδειγμα Φασικού Διαγράμματος OFDM με ισαπέχοντες φακέλους κέρδους συχνοτήτων [17]

Κάθε υπο-κανάλι διαμορφώνεται ξεχωριστά και θα εκπεμφθεί ταυτόχρονα, με επικαλυπτόμενο και παράλληλο τρόπο. Το γεγονός ότι κάθε δειγματική συνάρτηση είναι ορθογωνική με την προηγούμενη και την επόμενη της, σημαίνει ότι στο κέντρο των συναρτήσεων αυτών δεν υπάρχει διαταραχή στην συχνότητά τους από τα διπλανά υπο-φέροντα σήματα.


Με τη χρήση της τεχνικής αυτής μπορεί να μεταδοθεί μεγάλος όγκος δεδομένων σε μικρό εύρος συχνοτήτων. Επίσης το OFDM είναι μία καλή πρακτική για να αποφευχθεί το πρόβλημα απόσβεσης ισχύος του σήματος λόγω Multi-path και έχει μεγάλη ευελιξिमότητα όσον αφορά τη δημιουργία νέων σημάτων, καθώς μπορεί κανείς να ρυθμίσει την πυκνότητα των υπο-καναλιών σε ένα συγκεκριμένο εύρος συχνοτήτων. Τέλος, είναι κατάλληλο για εφαρμογές σε MIMO (Multiple Input Multiple Output) συστήματα, σε συστήματα δηλαδή όπου ο πομπός και ο δέκτης έχουν πολλές κεραίες. Στην ενότητα που ακολουθεί δεικνύονται κάποιες αρχιτεκτονικές σε πομπό και δέκτη που χρησιμοποιούν την OFDM τεχνολογία.

1.2 Πομπός, Δέκτης και Δίαυλος Επικοινωνίας σε RF Συστήματα

Στην ενότητα αυτή πραγματοποιείται μία επιφανειακή επεξήγηση, κάποιων βασικών διατάξεων και εννοιών που χρησιμοποιούνται ευρέως στα σύγχρονα τηλεπικοινωνιακά συστήματα που μεταδίδουν και επεξεργάζονται RF σήματα. Είναι σημαντικό κανείς να μπορεί να κατανοήσει τις βασικές έννοιες και τοπολογίες που ακολουθούν, ώστε να αποκτήσει καλύτερη αντίληψη όσον αφορά τα σύγχρονα τηλεπικοινωνιακά συστήματα που διέπουν την πραγματικότητά μας.

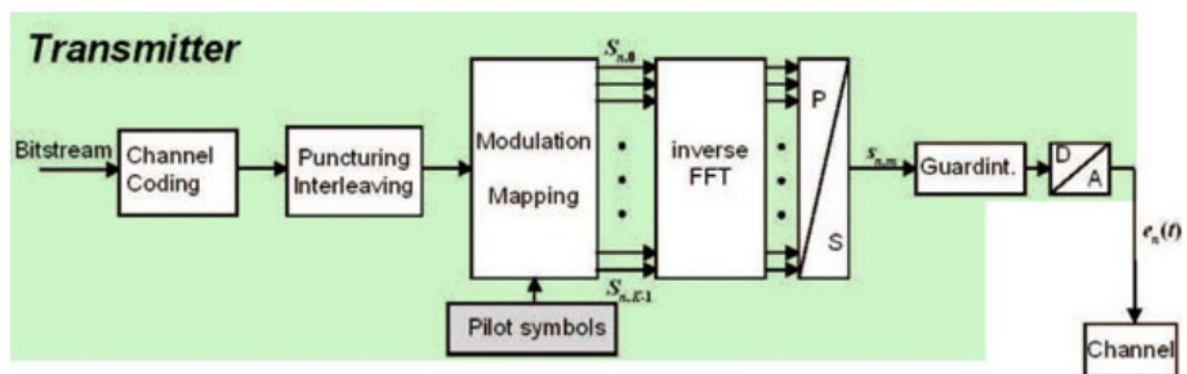
1.2.1 Αρχιτεκτονική στον Πομπό

Σύμφωνα με τον M. Steer [5], η κύρια λειτουργία ενός πομπού, που εκπέμπει σε ραδιοσυχνότητες, είναι να επεξεργάζεται ένα σήμα βασικής ζώνης και να το μεταδίδει μέσω του καναλιού επικοινωνίας σε πολύ υψηλότερες συχνότητες. Αυτό το καταφέρνει υπερθέτοντας το σήμα βασικής ζώνης με ένα φέρων σήμα πολύ υψηλής συχνότητας. Πιο συγκεκριμένα, ο πομπός, διαμορφώνοντας κατά πλάτος, συχνότητα ή φάση το φέρων σήμα, παράγει διαμορφωμένα φέροντα σήματα για την επιτυχή μετάδοση της πληροφορίας στον δέκτη.



Εικόνα 1.9: Μπλοκ διάγραμμα απλής αρχιτεκτονικής πομπού [5]

Στην *Εικόνα 1.9* παρουσιάζεται μία βασική αρχιτεκτονική πομπού, κατά την οποία ο πομπός μετατρέπει ένα χαμηλής συχνότητας σήμα, σε συχνότητα την οποία θα μπορέσει να εκπέμψει εύκολα. Η πληροφορία που εμπεριέχεται στο συγκεκριμένο σήμα βασικής ζώνης παράγεται στον Ψηφιακό Επεξεργαστή Σήματος (DSP). Έπειτα, το σήμα που εξέρχεται από τον DSP, μετατρέπεται σε αναλογικό μέσω του Ψηφιακού σε Αναλογικό Μετατροπέα (DAC). Το αναλογικό πλέον σήμα, φιλτράρεται από ένα χαμηλοπερατό φίλτρο (LPF) για να αφαιρεθούν οι αρμονικές που δημιουργούνται κατά την μετατροπή του από ψηφιακό σε αναλογικό σήμα. Στη συνέχεια ενισχύεται και πολλαπλασιάζεται με το φέρον σήμα που παράγεται από τον εσωτερικό ταλαντωτή. Το τελικό διαμορφωμένο σήμα φιλτράρεται από ένα ζωνοπερατό φίλτρο, ώστε να παραμείνει ή επιθυμητή ζώνη συχνοτήτων και τέλος ενισχύεται και εκπέμπεται μέσω της κεραίας.



Εικόνα 1.10: Μπλοκ διάγραμμα αρχιτεκτονικής πομπού με χρήση OFDM τεχνολογίας [17]


Όπως αναλύθηκε και στην *Ενότητα 1.1.5 Πολυπλεξία Ορθογωνικής Διαιρεμένης Συχνότητας*, η τεχνική OFDM διαιρεί το κανάλι σε υποκανάλια για μετάδοση μεγάλου όγκου πληροφοριών. Η ενέργεια αυτή συμβαίνει στην πλευρά του πομπού, ο οποίος παράγει με ψηφιακό τρόπο πολλά υπο-φέροντα σήματα, τα οποία τίθενται υπό πολυπλεξία με τη χρήση IFFT, προσδίδοντας έτσι έναν πιο αποδοτικό και απλοποιημένο τρόπο, παραγωγής ραδιοσυχνοτικών σημάτων και διαχείρισης του διαθέσιμου εύρους ζώνης (bandwidth). [17]

1.2.2 Αρχιτεκτονική στον Δέκτη

Υπάρχουν πολλές αρχιτεκτονικές δέκτη για επεξεργασία ραδιοσυχνοτικών σημάτων οι οποίες διαφέρουν μεταξύ τους λόγω διαφορετικών απαιτήσεων ανά σύστημα αλλά και λόγω εξέλιξης μεθόδων επεξεργασίας του σήματος. Στην συγκεκριμένη ενότητα παρουσιάζονται τρεις βασικές τοπολογίες δέκτη.

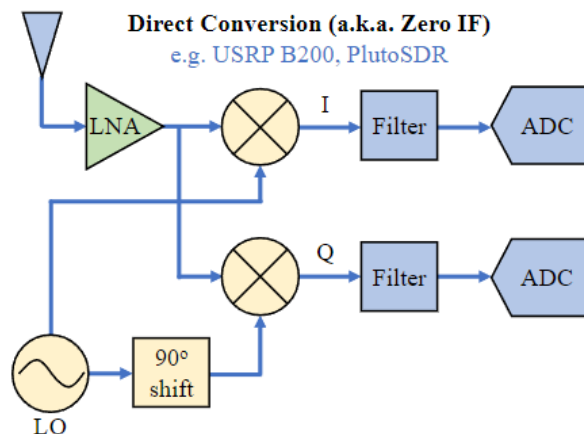
Η κύρια λειτουργία του δέκτη σε ένα τηλεπικοινωνιακό σύστημα RF σημάτων, είναι να δέχεται το αναλογικό σήμα του πομπού, να το ψηφιοποιεί και να το επεξεργάζεται. Συγκεκριμένα και σύμφωνα με το μπλοκ διάγραμμα της *Εικόνας 1.11*, μέσω της κεραίας του δέχεται το διαμορφωμένο αναλογικό σήμα, υψηλής συχνότητας, του πομπού και το φιλτράρει με ένα

ζωνοπερατό φίλτρο ώστε να το μετατοπίσει στην ζώνη συχνοτήτων που μπορεί να επεξεργαστεί την πληροφορία.



Εικόνα 1.11: Μπλοκ διάγραμμα απλής αρχιτεκτονικής δέκτη [5]

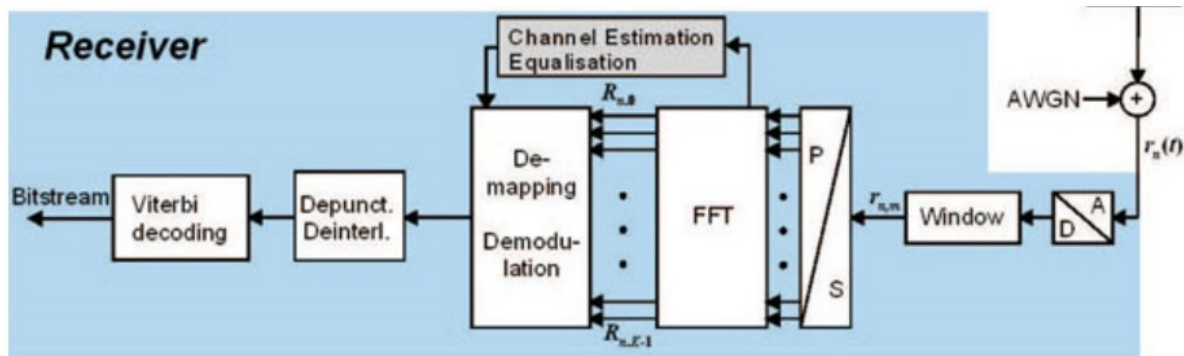
Έπειτα, ενισχύει το μετατοπισμένο ραδιοσυχνοτικό σήμα και το αποδιαμορφώνει πολλαπλασιάζοντάς το με το φέρον σήμα που παράγεται εσωτερικά στον δέκτη από τον τοπικό ταλαντωτή (LO). Στη συνέχεια, το σήμα φιλτράρεται με ένα χαμηλοπερατό φίλτρο (LPF), ώστε να απομακρυνθεί ο πιθανός θόρυβος και τέλος μετατρέπεται σε ψηφιακό μέσω του αναλογικού σε ψηφιακό μετατροπέα (ADC) και στέλνεται ως ψηφιακό σήμα, πλέον, στον ψηφιακό επεξεργαστή για επεξεργασία της πληροφορίας που στάλθηκε από τον πομπό.



Εικόνα 1.12: Μπλοκ διάγραμμα αρχιτεκτονικής δέκτη απευθείας μετατροπή και διαχωρισμό RF σήματος σε δείγματα IQ [6]

Μία δεύτερη τοπολογία δέκτη φαίνεται στην *Εικόνα 1.12*, κατά την οποία το αναλογικό σήμα που λαμβάνεται, μέσω της κεραίας, ενισχύεται με τη χρήση ενός Ενισχυτή Χαμηλού Θορύβου (LNA: Low Noise Amplifier). Το ενισχυμένο σήμα πολλαπλασιάζεται με δύο εσωτερικά παραγόμενα φέροντα σήματα, το ένα εκ των οποίων είναι μετατοπισμένο κατά 90 μοίρες, ώστε να μπορέσουν να εξαχθούν τα σήματα IQ του RF σήματος. Τέλος, τα I και Q σήματα ψηφιοποιούνται και επεξεργάζονται με χρήση Αναλογικού σε Ψηφιακό Μετατροπέα.

Τέλος, μία επίσης σημαντική τοπολογία είναι αυτή του δέκτη που επεξεργάζεται πολλά υποκανάλια με χρήση της τεχνολογίας OFDM.



Εικόνα 1.13: Μπλοκ διάγραμμα αρχιτεκτονικής δέκτη με χρήση OFDM τεχνολογίας [17]

Στην συγκεκριμένη αρχιτεκτονική, αφού ψηφιοποιηθεί το σήμα, διαιρείται και με χρήση FFT, υπολογίζονται και μετατοπίζονται στο πεδίο της συχνότητας τα διαιρεμένα σήματα. Έπειτα αποδιαμορφώνονται και ομαδοποιούνται με σκοπό την απόσπαση της συνολικής πληροφορίας και τέλος μετατρέπονται σε μία μεγάλη ροή δεδομένων και αποστέλλονται προς επεξεργασία.

1.2.3 Πληροφορία Κατάστασης Καναλιού Επικοινωνίας (CSI: Channel State Information)

Όσον αφορά τον δίαυλο επικοινωνίας, στην περίπτωση των RF συστημάτων συνηθίζεται να είναι ο αέρας. Η Πληροφορία Κατάστασης Καναλιού (CSI), είναι μία μέθοδος για μελέτη της παραμόρφωσης της αποστέλλουσας πληροφορίας, από πομπό σε δέκτη. Η μελέτη αυτή αφορά το κατά πόσο ο δίαυλος επικοινωνίας σε ένα RF τηλεπικοινωνιακό σύστημα, παραμορφώνει το RF σήμα. Από αυτήν τη μελέτη, μπορεί να αποσπαστεί πληροφορία σχετικά με αντικείμενα ή ανθρώπους, που βρίσκονται ανάμεσα σε πομπό και δέκτη και κατά πόσο επηρεάζουν την επικοινωνία τους.

Το CSI βοηθά στην προσαρμογή μεταδόσεων πληροφορίας υπό συγκεκριμένες συνθήκες καναλιού επικοινωνίας. Το CSI συνήθως εκτιμάται και αναλύεται από την πλευρά του δέκτη και κβαντίζεται και ανατροφοδοτείται στην πλευρά του πομπού. Για τον λόγο αυτό μπορεί σε ένα σύστημα επικοινωνίας το CSI του πομπού να διαφέρει από το CSI του δέκτη και κάποιο χρονικό διάστημα. Τα δύο CSI αυτά συμβολίζονται CSIT για την πλευρά του πομπού και CSIR για την πλευρά του δέκτη. [7]

1.2.4 Διαφορά Φάσης Φέροντος Σήματος (CFO: Carrier Frequency Offset)

Η Διαφορά Φάσης Φέροντος Σήματος συμβαίνει όταν ο δέκτης και ο πομπός σε ένα σύστημα, δεν έχουν συγχρονισμένα εσωτερικά ρολόγια ή από το φαινόμενο Doppler κατά τη μετάδοση του κύματος στο μέσο διάδοσης. Αυτό έχει ως αποτέλεσμα να δημιουργείται σφάλμα μετάδοσης και να μην μεταδίδεται ολόκληρη η πληροφορία. Πιο συγκεκριμένα, είναι το φαινόμενο κατά το οποίο το φέρον σήμα, που περιέχεται στο σήμα της πληροφορίας, δεν είναι συγχρονισμένο με το φέρον σήμα που χρησιμοποιεί ο δέκτης για να κάνει αποδιαμόρφωση του σήματος.

Να σημειωθεί επίσης ότι σε συστήματα που χρησιμοποιούν OFDM, η ορθογωνικότητα των διαιρεμένων σημάτων διατηρείται μόνο όταν ο εσωτερικός ταλαντωτής του δέκτη, που παράγει τα φέροντα σήματα, είναι συγχρονισμένος με τον αντίστοιχο ταλαντωτή του πομπού. Είναι γνωστό ότι δεν μπορεί να επιτευχθεί ιδανικός συγχρονισμός ανάμεσα σε δύο ή περισσότερους ταλαντωτές, γι' αυτό και το πρωτόκολλο IEEE 802.11 WLAN θεσπίζει την ανοχή των εσωτερικών ταλαντωτών να βρίσκεται ανάμεσα σε +20ppm (parts per million) και -20 ppm, ώστε η διαφορά

φάσης των φερόντων σημάτων να μην ξεπερνάει τα +40ppm και να μην πέφτει κάτω από -40ppm. [\[9\]](#)

1.2.5 Προφίλ Καθυστέρησης Ισχύος Σήματος (PDP: Power Delay Profile)

Το προφίλ καθυστέρησης ισχύος (PDP) είναι μία γραφική παράσταση που παρουσιάζει την ισχύ ενός σήματος που εκπέμπεται σε ένα κανάλι με πολλαπλές διαδρομές συναρτήσεως του χρόνου. Μέσω της απόστασης των κορυφών που διαφαίνονται στην συγκεκριμένη γραφική παράσταση, μπορεί κανείς να διακρίνει την χρονική καθυστέρηση των ανακλάσεων του σήματος, που διαδίδονται λόγω των πολλαπλών διαδρομών. Η ισχύς του σήματος εκφράζεται σε db και από το γράφημα μπορεί να εξαχθεί η διασπορά καθυστέρησης του σήματος. [\[13\]](#)

1.3 Πρωτόκολλο 802.11 (Wi-Fi)

Στη συγκεκριμένη ενότητα γίνεται αναφορά στην έως τώρα εξέλιξη του πρωτοκόλλου 802.11, καθώς επίσης αναλύεται επιδερμικά η δομή του.

Το πρωτόκολλο 802.11 (Wi-Fi) αποτελεί επανάσταση στο πεδίο των τηλεπικοινωνιών, καθώς κατά τη θέσπισή του, άλλαξε την καθημερινότητα του σύγχρονου ανθρώπου και της κοινωνίας του. Οι εφαρμογές του, έχουν διεισδύσει, πλέον, στον τρόπο με τον οποίο επικοινωνούν οι άνθρωποι, στις μέρες μας, αλλά και χάρη σε αυτό, κατάφερε να εδραιωθεί ο κόσμος του διαδικτύου στις ζωές μας, δίνοντάς μας πρόσβαση σε τεράστιο όγκο πληροφοριών και γεγονότων που συμβαίνουν ανά τον κόσμο.

1.3.1 Ιστορική Αναδρομή

Η ιστορία του πρωτοκόλλου 802.11 στις ασύρματες τηλεπικοινωνίες, ξεκινά από το 1999, όπου θεσπίστηκαν τα 802.11a και 802.11b. Το 802.11b ήταν το πιο σύνηθες στη χρήση, με ταχύτητες των 11 Mbps (πολύ χαμηλότερες από αυτές των ενσύρματων ταχυτήτων με Ethernet), αλλά το γεγονός ότι δεν υπήρχαν φορητοί υπολογιστές (laptops, κινητά), έκανε τις συγκεκριμένες ταχύτητες ικανοποιητικές.

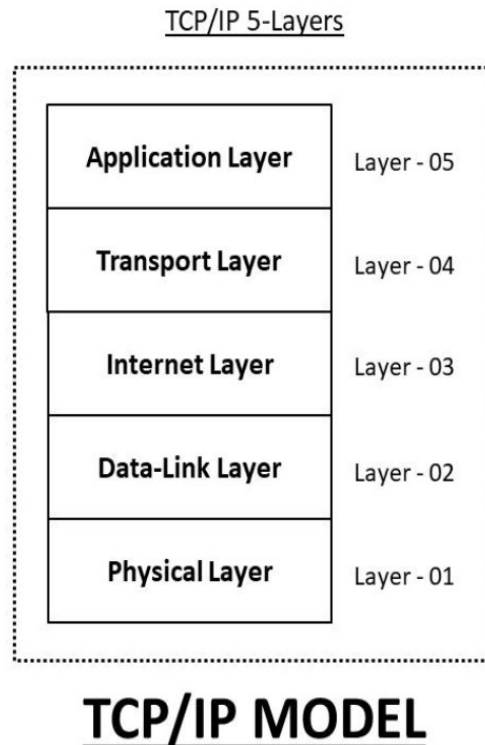
Το 2003, με την άνοδο σε ζήτηση και χρήση, επαγγελματική και οικιακή, των κινητών και των φορητών υπολογιστών, που χρησιμοποιούν Wi-Fi, εδραιώθηκε το 802.11g, το οποίο πρόσφερε ταχύτητες έως και 54 Mbps.

Το 2007 η Apple εισήγαγε στην αγορά το πρώτο iPhone και τα έξυπνα κινητά τηλέφωνα εισήχθησαν στην καθημερινή ζωή του ανθρώπου. Το 2009 θεσπίστηκε το 802.11n με ταχύτητες που έφταναν τα 100 Mbps. Το πρότυπο 802.11n έφερε και ταχύτερους ρυθμούς δεδομένων με ταχύτητες μέχρι 600 Mbps και μπορούσε να υποστηρίξει συσκευές που επικοινωνούσαν στα 2.4GHz και στα 5GHz. Έπειτα, το 2013 ορίστηκε το πρότυπο 802.11ac το οποίο φτάνει σε ταχύτητες ρυθμού δεδομένων 433 και 2167 Mbps.

Σήμερα, αναπτύσσεται το πρότυπο 802.11ax, το οποίο υπόσχεται ταχύτητες των 10 Gbps αλλά επίσης, η αποδοτικότητα είναι πλέον ένα ζήτημα στο οποίο δίνεται έμφαση. Το συγκεκριμένο πρότυπο αναλύεται στην *Ενότητα 1.4*. [\[18\]](#)

1.3.2 Δομή

Σύμφωνα με το μοντέλο αναφοράς Διαδικτυακού Πρωτοκόλου (TCP/IP), το οποίο θεσπίστηκε από την Υπηρεσία Έρευνας Αμυντικών Έργων (DARPA), η αρχιτεκτονική των συστημάτων ορίζεται σε πέντε επίπεδα. Συγκεκριμένα, αποτελεί μία οδηγία ως προς το πως θα πρέπει να δομούνται τα συστήματα για την επιτυχή τους σύνδεση και επικοινωνία. Τα πέντε αυτά επίπεδα παρουσιάζονται στην *Εικόνα 1.14*. [\[14\]](#)



Εικόνα 1.14: Μοντέλο αναφοράς TCP/IP πέντε επιπέδων [14]

Τα πρότυπα του πρωτοκόλλου 802.11 (802.11a, 802.11b, 802.11g, 802.11n, 802.11ac) δίνουν έμφαση στα τελευταία δύο επίπεδα, της προτεινόμενης αρχιτεκτονικής του TCP/IP, δηλαδή αυτά του φυσικού και του ζεύξης δεδομένων, επιπέδων. Ο λόγος για τον οποίο όλα τα προηγούμενα επίπεδα είναι κοινά σε όλα τα πρότυπα, είναι για να μπορούν να επικοινωνούν συσκευές, που υπακούν σε διαφορετικά πρότυπα, μεταξύ τους. Ο έλεγχος αυτός πραγματοποιείται στο επίπεδο Ζεύξης Δεδομένων (MAC Layer). Επομένως, σε αυτήν την ενότητα θα δοθεί έμφαση στο επίπεδο MAC και στο Φυσικό επίπεδο (PHY).

Το MAC επίπεδο ή αλλιώς Επίπεδο ζεύξης δεδομένων (Data Link Layer), είναι υπεύθυνο για τη συνδεσιμότητα μεταξύ συσκευών, καθώς επίσης και για τη διόρθωση τυχόντων σφαλμάτων που προέκυψαν στο Φυσικό επίπεδο. [14]

Στο Φυσικό επίπεδο (PHY) ορίζονται τα τεχνικά χαρακτηριστικά για τις συσκευές. Συγκεκριμένα, σε αυτό το επίπεδο ορίζεται η σχέση μεταξύ συσκευής και μέσου μετάδοσης. Το επίπεδο αυτό είναι υπεύθυνο για τη δημιουργία και τον τερματισμό επικοινωνίας της συσκευής με μία άλλη, καθώς επίσης και για τη διαμόρφωση και ψηφιακή επεξεργασία των σημάτων που εκπέμπονται σε ένα κανάλι επικοινωνίας. [14]

1.4 Το Πρωτόκολλο 802.11ax


Το πρότυπο 802.11ax ή Wi-Fi 6, στοχεύει όχι μόνο σε μεγαλύτερες ταχύτητες αλλά και σε μεγαλύτερη αποδοτικότητα επικοινωνίας. Το πρότυπο αυτό θεσπίστηκε από το IEEE το 2019 με συχνότητες επικοινωνίας τα 2.4GHz και 5GHz, και το 2020 δημοσιεύτηκε μια ενισχυμένη έκδοσή του, η Wi-Fi 6E, η οποία μπορεί να λειτουργεί και στα 6 GHz, αυξάνοντας τους ρυθμούς διακίνησης δεδομένων. Στη συγκεκριμένη υποενότητα, παρουσιάζονται οι τεχνολογίες που εξέλιξαν το 802.11ac σε 802.11ax και πως αυτές συνέβαλλαν σε καλύτερες αποδόσεις σε επεξεργασία και επικοινωνία συσκευών που χρησιμοποιούν το πρότυπο αυτό.

1.4.1 Τεχνολογίες Κλειδιά του 802.11ax

Οι βασικότερες τεχνολογίες που ορίζουν το πρότυπο 802.11ax είναι η χρήση MU-OFDMA, η διαμόρφωση 1024QAM, μακράς διάρκειας OFDM σύμβολα, επαναχρησιμοποίηση χώρου (SR), Στοχευμένη ώρα αφύπνισης (TWT). Οι υπόλοιπες αναφέρονται αναλυτικά στις πηγές [18] και [26].


Η Πολλαπλή Πρόσβαση Πολλαπλών Χρηστών με Ορθογώνια Διαίρεση Συχνότητας (MU-OFDMA), αποτελεί την πιο σημαντική τεχνολογία στο πρότυπο 802.11ax, καθώς επιτρέπει σε πολλαπλούς χρήστες με διαφορετικές ανάγκες σε εύρος ζώνης (Bandwidth), να εξυπηρετούνται παράλληλα.

Όπως αναφέρθηκε και στην Ενότητα 1.1.5 Πολυπλεξία Ορθογωνικής Διαίρεσης Συχνότητας (OFDM), το OFDMA είναι και αυτό αντίστοιχα μία τεχνική διαίρεσης του εύρους ζώνης σε υπο-κανάλια με κύρια διαφορά ότι το OFDMA έχει επιπλέον ένα σημείο πρόσβασης (AP), το οποίο ορίζει την ταυτόχρονη επικοινωνία με πολλαπλούς πελάτες (τερματικά). Το AP μπορεί να προσδώσει ένα ολόκληρο κανάλι ή κομμάτια αυτού σε μία συσκευή-πελάτη. [24]



Εικόνα 1.15: Διάγραμμα εξυπηρέτησης πελατών με OFDMA [24]

Η διαμόρφωση 1024-QAM πραγματοποιείται χάρη στον υψηλό ρυθμό διαμόρφωσης και κωδικοποίησης των 10 Mbit/s και 11 Mbit/s ή αλλιώς MCS10 και MCS1. Να σημειωθεί ότι όταν χρησιμοποιείται διαμόρφωση μεγάλης τάξης πρέπει να αυξάνεται και ο λόγος ήχου προς θόρυβο (SNR), ώστε να εξισορροπούνται τα σφάλματα BER (Bit Error Rate) και FER (Frame Error Rate). [26]



Εικόνα 1.16: Διαμόρφωση σε 1024 μιγαδικά δείγματα [26]

1.4.2 Αποδοτικότητα

Χάρη στις τεχνολογίες κλειδιά που αναφέρονται στην *Ενότητα 1.4.1 Τεχνολογίες Κλειδιά του 802.11ax*, αλλά και στις αναλυτικότερες αναφορές των παραπομπών [19] και [26], το πρότυπο 802.11ax θεωρείται κατάλληλο για IoT εφαρμογές, όπου απαιτείται παράλληλη επικοινωνία και μεταφορά δεδομένων με πολλούς και διαφορετικούς κόμβους, και γενικότερα σε εφαρμογές όπου απαιτείται η παράλληλη επικοινωνία με πολλά τερματικά για μετάδοση μεγάλου όγκου δεδομένων.

Το πρότυπο 802.11ax είναι συμβατό και με τις προηγούμενες εκδόσεις προτύπων για τους λόγους που αναφέρονται στην *Ενότητα 1.3.2 Δομή*, κάνοντάς το προσαρμόσιμο σε ήδη υπάρχοντα δίκτυα. Η ικανότητα επικοινωνίας στα 6 GHz αλλά και η αρχιτεκτονική της ψηφιακής διαμόρφωσης των σημάτων, καθιστά την διακίνηση δεδομένων πιο αποδοτική και αποκρίσιμη σε μεγαλύτερες ταχύτητες.

2 ΚΕΦΑΛΑΙΟ 2^ο : Υπολογιστική Νοημοσύνη και Μηχανική Μάθηση

Η τεχνητή νοημοσύνη αποτελεί μία ευρέως χρησιμοποιούμενη τεχνολογία, στις μέρες μας, και έχει συμβάλει σε διάφορες τεχνολογικές εξελίξεις. Η τεχνητή νοημοσύνη είναι η προσπάθεια του ανθρώπου να εξομοιώσει την λειτουργικότητα του ανθρώπινου εγκεφάλου, καθώς ο ανθρώπινος εγκέφαλος είναι ένα "εργαλείο" το οποίο, στην πάροδο του χρόνου, εξελίχθηκε με τέτοιο τρόπο, ώστε να μπορεί να πραγματοποιεί λειτουργίες και υπολογισμούς σε πολύ μεγάλες ταχύτητες για τον συντονισμό απαραίτητων διαδικασιών για την εξασφάλιση της ανθρώπινης ζωής. Η τεχνητή Νοημοσύνη έχει δημιουργήσει μία καλή προσέγγιση του ανθρώπινου εγκεφάλου όσον αφορά το υπολογιστικό κομμάτι και τη διαδικασία μάθησης. Ωστόσο, δεν έχει προοδεύσει στην δημιουργία αντίληψης και συνείδησης σε μία μηχανή.

Η τεχνητή νοημοσύνη χωρίζεται σε Συμβατική Τεχνητή Νοημοσύνη και σε Υπολογιστική Τεχνητή Νοημοσύνη. Η πρώτη αφορά μεθόδους μάθησης που χρησιμοποιούν στατιστικές και μαθηματικά πιθανοτήτων. Η δεύτερη αφορά αλγόριθμους που χρησιμοποιούν εμπειρικές γνώσεις, βάσει των δεδομένων που συλλέγονται από το περιβάλλον για την επίτευξη της μηχανικής μάθησης.

Σε αυτό το Κεφάλαιο εμβαθύνεται και αναλύεται η Υπολογιστική Νοημοσύνη καθώς επίσης αναφέρονται και κάποιοι αλγόριθμοι που ανήκουν στον τομέα της Συμβατικής Νοημοσύνης.

2.1 Σύντομη Ιστορική Αναδρομή

Πραγματοποιήθηκαν πολλές προσπάθειες αποτύπωσης αλγοριθμικών σκέψεων, δηλαδή δομών εκτέλεσης διαδικασιών, για την επίλυση μη γραμμικών προβλημάτων στο παρελθόν. Μία από τις πρώτες προσπάθειες προσέγγισης των νευρωνικών δικτύων ως μεθόδου λύσης μη γραμμικών προβλημάτων, ήταν αυτή των McCulloch και Pitts (1943) κατά την οποία έγινε μία πρώτη εισήγηση των νευρωνικών δικτύων ως υπολογιστικές μηχανές. [21]

Έπειτα, το 1949 ο Hebb δημοσίευσε ένα βιβλίο με τίτλο "The organization of behavior" στο οποίο παρουσιάζεται ο πρώτος κανόνας αυτο-οργανούμενης μάθησης, κατά τον οποίον <<όταν ένα νευρωνικό δίκτυο χρησιμοποιεί τις νευρωνικές του συνδέσεις αυτές ενισχύονται και το δίκτυο πλησιάζει περισσότερο στο να μάθει το πρότυπο που του παρουσιάζεται>> [10].

Το 1958 αναπτύχθηκε το πρώτο μοντέλο μάθησης Perceptron από τον Rosenblatt το οποίο προτείνει τη μάθηση με εκπαιδευτή και αναλύεται στην ενότητα 2.4.1 Perceptron.

Στα μέσα της δεκαετίας του '80 έγινε η πρώτη αναφορά του όρου <<back propagation>>, έπειτα από τη δημοσίευση του βιβλίου " Parallel Distributed Processing" από τους Rumelhart και McClelland.

Με τη συγκεκριμένη δημοσίευση έγινε εφικτή η εξέλιξη των νευρωνικών δικτύων παρέχοντας μία υπολογιστικά αποτελεσματική μέθοδο για την εκπαίδευση των perceptrons πολλαπλών επιπέδων. [17]

Στην σύγχρονη εποχή έχουν αναπτυχθεί διάφορα μοντέλα νευρωνικών δικτύων και χρησιμοποιούνται σε κάθε παράδειγμα περίπτωσης επίλυσης μη γραμμικών προβλημάτων (π.χ. αναγνώριση προτύπων, clustering, κα).

2.2 Εισαγωγή στην Υπολογιστική Νοημοσύνη

Η υπολογιστική νοημοσύνη αποτελεί τη "σχολή σκέψης" που αναπτύχθηκε ραγδαία με την τεχνολογική ανάπτυξη του ηλεκτρονικού υπολογιστή, καθώς με την αύξηση της υπολογιστικής ισχύος ενός Η/Υ μπορούσαν να υποστηριχθούν οι υπολογιστικές πολυπλοκότητες που διέπουν τα

προβλήματα υπολογιστικής νοημοσύνης. Η υπολογιστική νοημοσύνη δίνει έμφαση σε εξελικτικούς αλγόριθμους που χρησιμοποιούν διάφορους αναδρομικούς τρόπους, για να συσχετίζουν τα δεδομένα που επεξεργάζονται. Στην πάροδο του χρόνου έχουν διαμορφωθεί κάποια είδη μηχανικής μάθησης, τα οποία αποτελούν την καθοδηγήτρια γραμμή σε μεθόδους διαχείρισης των δεδομένων, που πρέπει να τεθούν υπό επεξεργασία, σε ένα σύστημα όπου επιθυμείται η χρήση μηχανικής μάθησης.

Τα συστήματα που διαχειρίζονται δεδομένα, στην περίπτωση της Υπολογιστικής Νοημοσύνης, είναι τα νευρωνικά δίκτυα, τα οποία αποτελούν μία προσέγγιση της λειτουργίας των νευρώνων του ανθρώπινου εγκεφάλου. Οι νευρώνες είναι τα δομικά στοιχεία των νευρωνικών δικτύων, και όπως και στον εγκέφαλο, επεξεργάζονται τη πληροφορία και ανάλογα πυροδοτούν ή όχι ένα σήμα. Τα νευρωνικά δίκτυα αποτελούνται από στοιβάδες, οι οποίες περιέχουν έναν αριθμό νευρώνων και είναι συνδεδεμένες μεταξύ τους. Ένα νευρωνικό δίκτυο μπορεί να αποτελείται από μία (Απλή Μάθηση) ή περισσότερες στοιβάδες (Βαθιά Μάθηση). Στην είσοδό του δέχεται, τα προς επεξεργασία, δεδομένα και στην έξοδό του παρέχει τις προβλέψεις. Η συσχέτιση των δεδομένων συμβαίνει στα συναπτικά βάρη (βλ. *Ενότητα 2.4 Αλγόριθμοι Μηχανικής Μάθησης*)

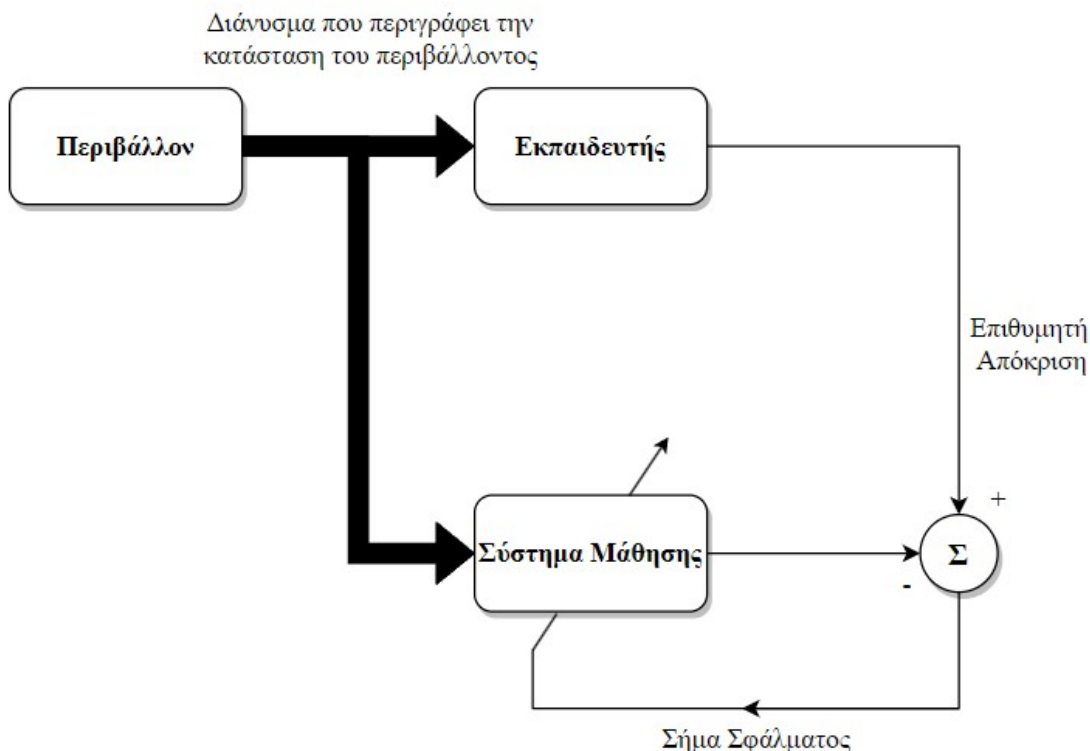
Στις παρακάτω ενότητες παρουσιάζονται τα βασικά είδη μηχανικής μάθησης και κάποιοι επίσης βασικοί αλγόριθμοι μηχανικής μάθησης νευρωνικών δικτύων.

2.3 Είδη Μηχανικής Μάθησης

Τα είδη μηχανικής μάθησης διακρίνονται σε τέσσερις υπο-κατηγορίες την Επιβλεπόμενη Μάθηση (Supervised Learning), τη Μάθηση Διόρθωσης Σφάλματος (Error Correction Learning), τη Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning) και την Ενισχυτική Μάθηση (Reinforcement Learning). Τα συγκεκριμένα είδη αποτελούν τα τέσσερα βασικά μοντέλα στα οποία στηρίζονται οι αλγόριθμοι μηχανικής μάθησης.

2.3.1 Επιβλεπόμενη Μάθηση (Supervised Learning)

Σύμφωνα με S.Haykin [21], εννοιολογικά, η επιβλεπόμενη μάθηση ή αλλιώς μάθηση με εκπαιδευτή, είναι η μάθηση που εξαρτάται από τον εκπαιδευτή. Συγκεκριμένα, ο εκπαιδευτής έχει γνώση του περιβάλλοντος, ενώ το νευρωνικό δίκτυο όχι. Σύμφωνα με το *Σχήμα 2.1*, όταν λαμβάνεται από το ίδιο περιβάλλον ένα διάνυμα εκπαίδευσης, στον εκπαιδευτή και στο σύστημα μάθησης, ο εκπαιδευτής, λόγω της επίγνωσης του περιβάλλοντος, δίνει ένα σήμα επιθυμητής απόκρισης στην έξοδό του.

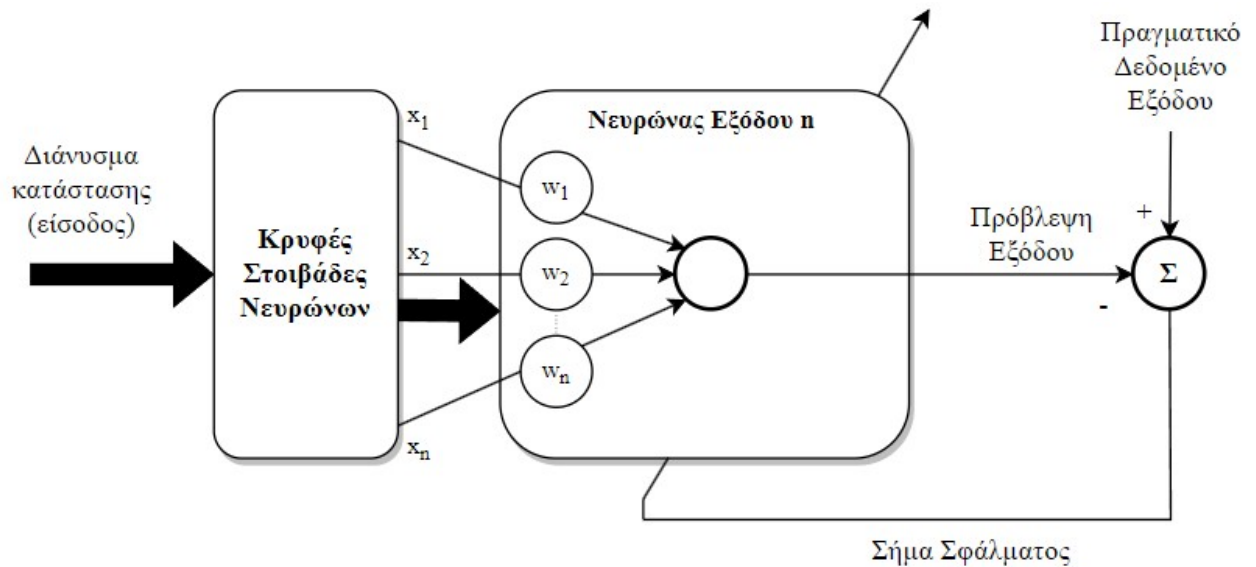


Σχήμα 2.1: Σχηματικό Διάγραμμα Επιβλεπομένης Μάθησης

Το νευρωνικό δίκτυο, με τη σειρά του, δίνει και αυτό την απόκρισή του και στη συνέχεια το νευρωνικό λαμβάνει το σήμα σφάλματος ως είσοδο, το οποίο εκφράζει την απόκλιση της απόκρισης του νευρωνικού δικτύου από την επιθυμητή απόκριση του εκπαιδευτή. Πραγματοποιώντας επαναληπτικές διαδικασίες, το νευρωνικό δίκτυο, αποκρίνει σήματα τα οποία κάθε φορά, προσπαθεί να προσεγγίζουν όλο και περισσότερο την επιθυμητή απόκριση που έχει προσδώσει ο εκπαιδευτής.

2.3.2 Μάθηση Διόρθωσης Σφάλματος (Error Correction Learning)

Μία από τις πιο συνηθισμένες περιπτώσεις μάθησης με εκπαιδευτή, είναι η Μάθηση Διόρθωσης Σφάλματος. Στο Σχήμα 2.2 απεικονίζεται, ένα παράδειγμα νευρωνικού δικτύου με εμπρόσθια τροφοδότηση (βλ. Ενότητα 2.4.3 Νευρωνικά Δίκτυα Εμπρόσθιας Τροφοδότησης), στο οποίο δίνεται έμφαση στο τι συμβαίνει στον τελευταίο νευρώνα του δικτύου.



Σχήμα 2.2: Σχηματικό Διάγραμμα Μάθησης Διόρθωσης Σφάλματος

Συγκεκριμένα, εισάγεται ένα διάνυσμα εισόδου (δεδομένο), επεξεργάζεται στις κρυφές στοιβάδες και το αποτέλεσμα εισάγεται σαν είσοδος στον τελευταίο νευρώνα του νευρωνικού δικτύου. Εκεί κάθε μεταβλητή του διανύσματος εισόδου του νευρώνα, πολλαπλασιάζεται με τα συναπτικά βάρη (w_{nj}) και προκύπτει μία πρόβλεψη. Στη συνέχεια, η πρόβλεψη συγκρίνεται με την πραγματικότητα (πραγματικό δεδομένο που εξάγεται από τον εκπαιδευτή) και προκύπτει ένα σφάλμα το οποίο ανάλογα την απόκλιση, που έχει από το πραγματικό δεδομένο, θα επενεργήσει σαν παράγοντας για την τροποποίηση των τιμών των συναπτικών βαρών, έως ότου η πρόβλεψη να γίνει ίδια με το πραγματικό δεδομένο. Το σφάλμα πρόβλεψης $e_n(k)$, ορίζεται ως

$$e_n(k) = \hat{y}_n(k) - y_n(k), \quad (2.1)$$

Όπου,

n : ο αριθμός στοιβάδας,

k : δεδομένη χρονική στιγμή,

$\hat{y}_n(k)$: Πρόβλεψη πραγματικής τιμής δεδομένου από το νευρωνικό δίκτυο για κάποια χρονική στιγμή,

$y_n(k)$: Πραγματικό δεδομένο εξόδου από τον εκπαιδευτή για κάποια χρονική στιγμή

Και για να ελαχιστοποιηθεί, συνήθως χρησιμοποιείται ο κανόνας Δέλτα ή αλλιώς κανόνας Widrow-Hoff. Κατά τον οποίον ισχύει:

$$\Delta w_{nj}(k) = \eta \cdot e_n(k) \cdot x_{nj}(k) \quad (2.2)$$

Όπου,

j : ο αριθμός στοιχείου σιβάδας,

η : ρυθμός μάθησης

$e_n(k)$: σφάλμα που προκύπτει από τη σύγκριση του πραγματικού δεδομένου με την πρόβλεψη του νευρωνικού δικτύου για κάποια χρονική στιγμή,

$x_{nj}(k)$: Δεδομένο εισόδου συγκεκριμένης χρονικής στιγμής στον νευρώνα


Την επόμενη χρονική στιγμή τα συναπτικά βάρη της ίδιας σύναψης θα είναι:

$$w_{nj}(k+1) = w_{nj}(k) + \Delta w_{nj}(k) \quad (2.3)$$

Γενικά, σε κάθε χρονική στιγμή τα συναπτικά βάρη μετατοπίζονται, ανάλογα το σφάλμα και το κατά πόσο μεγάλη είναι η τιμή εισόδου στον νευρώνα.

2.3.3 Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning)

Στη μη επιβλεπόμενη μάθηση ή όπως αναφέρει ο S. Haykin [21] στην αυτο-οργανούμενη μάθηση, δεν υπάρχει ο εκπαιδευτής που <<επιβλέπει>> τις προβλέψεις του νευρωνικού δικτύου, δηλαδή το νευρωνικό δίκτυο δεν αποσκοπεί στο να μάθει τη σχέση μεταξύ δεδομένων εισόδου και εξόδου, αντιθέτως προσπαθεί να συσχετίσει τα δεδομένα εισόδου αναγνωρίζοντας τυχόν πρότυπα που έχουν μεταξύ τους. Για αυτό τον λόγο το νευρωνικό σύστημα χρειάζεται μόνο τα δεδομένα εισόδου όπως φαίνεται και στο Σχήμα 2.3.



Σχήμα 2.3: Σχηματικό Διάγραμμα Μη Επιβλεπομένης Μάθησης

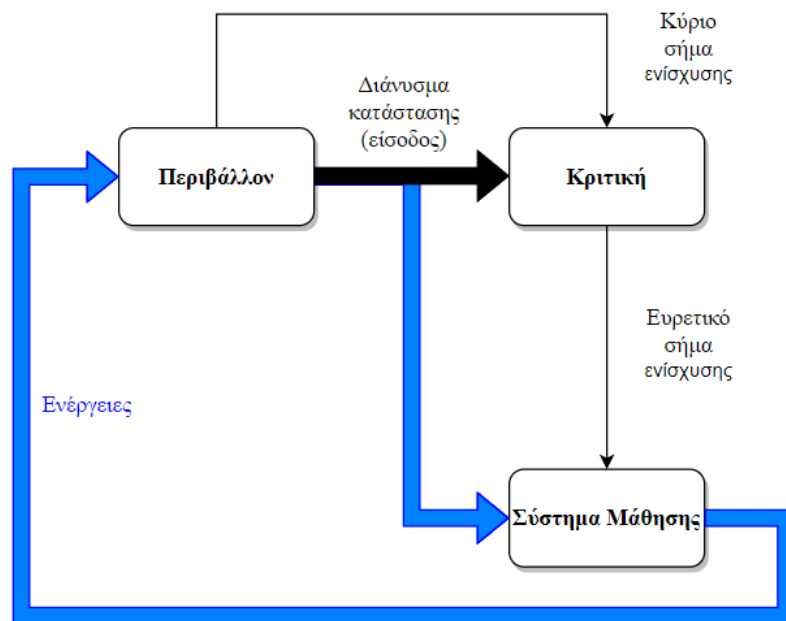
Στον συγκεκριμένο τρόπο μάθησης, εφαρμόζεται μία τακτική ανταγωνιστικότητας μεταξύ των νευρώνων η οποία οδηγεί τους νευρώνες να προσπαθούν να αποκριθούν σύμφωνα με τα δεδομένα εισόδου. <<Νικά>>, ο νευρώνας με τη μεγαλύτερη συνολική είσοδο, δηλαδή ενεργοποιείται ο νευρώνας που ανταποκρίνεται καλύτερα στα δεδομένα εισόδου και απενεργοποιούνται όλοι οι υπόλοιποι.

Αυτή η μέθοδος μάθησης χρησιμοποιείται κυρίως για ομαδοποίηση δεδομένων σε περιπτώσεις αναγνώρισης προτύπων.

2.3.4 Ενισχυτική Μάθηση (Reinforcement Learning)

Η ενισχυτική μάθηση όπως και η μη επιβλεπόμενη μάθηση, πραγματοποιεί την εκπαίδευση μη γνωρίζοντας τα επιθυμητά δεδομένα εξόδου. Παρά ταύτα, όπως φαίνεται και στο Σχήμα 2.4, το νευρωνικό δίκτυο αλληλεπιδρά συνεχώς με το περιβάλλον.

Στο συγκεκριμένο είδος μάθησης υπάρχει ένας κριτής που <<επιβραβεύει>> ή <<τιμωρεί>> το σύστημα μάθησης, λαμβάνοντας ένα σήμα ενίσχυσης και παράγοντας ένα σήμα υψηλότερης ενίσχυσης, το ευρετικό σήμα ενίσχυσης. Το κύριο σήμα ενίσχυσης αποτελεί μία ανατροφοδότηση του περιβάλλοντος στον κριτή όσον αφορά το μέτρο απόδοσης του νευρωνικού δικτύου. Στόχος του νευρωνικού δικτύου είναι να ελαχιστοποιήσει όσο το δυνατόν περισσότερο το μέτρο απόδοσης, προσπαθώντας να ερμηνεύσει την αλληλουχία των σημάτων που δέχεται από τον κριτή, και αυτό το καθιστά σχετικά αργό όσον αφορά την ταχύτητα μάθησης. Ωστόσο, είναι μία μέθοδος μάθησης κατά την οποία το νευρωνικό δίκτυο μαθαίνει βιωματικά από τις δικές του εμπειρίες (συνεχής αλληλεπίδραση με το περιβάλλον του).



Σχήμα 2.4: Σχηματικό Διάγραμμα Ενισχυμένης Μάθησης

Η ενισχυτική μάθηση χρησιμοποιείται κυρίως σε επίλυση προβλημάτων δυναμικού προγραμματισμού καθώς επίσης και σε συστήματα προσαρμοστικού αυτόματου ελέγχου. [21]

2.4 Αλγόριθμοι Μηχανικής Μάθησης

Οι αλγόριθμοι μηχανικής μάθησης αποτελούν τη διαδικασία κατά την οποία επιτυγχάνεται η μάθηση σε ένα σύστημα μηχανικής μάθησης. Ανάλογα την περίπτωση χρησιμοποιούνται και διαφορετικοί αλγόριθμοι που επιτελούν το επιθυμητό έργο.

Σε αυτήν την ενότητα περιγράφονται κάποιοι βασικοί αλγόριθμοι μηχανικής μάθησης, ώστε να γίνει αντιληπτή η λειτουργία και η χρησιμότητά τους, όσον αφορά την επίλυση μη γραμμικών προβλημάτων.

2.4.1 Perceptron

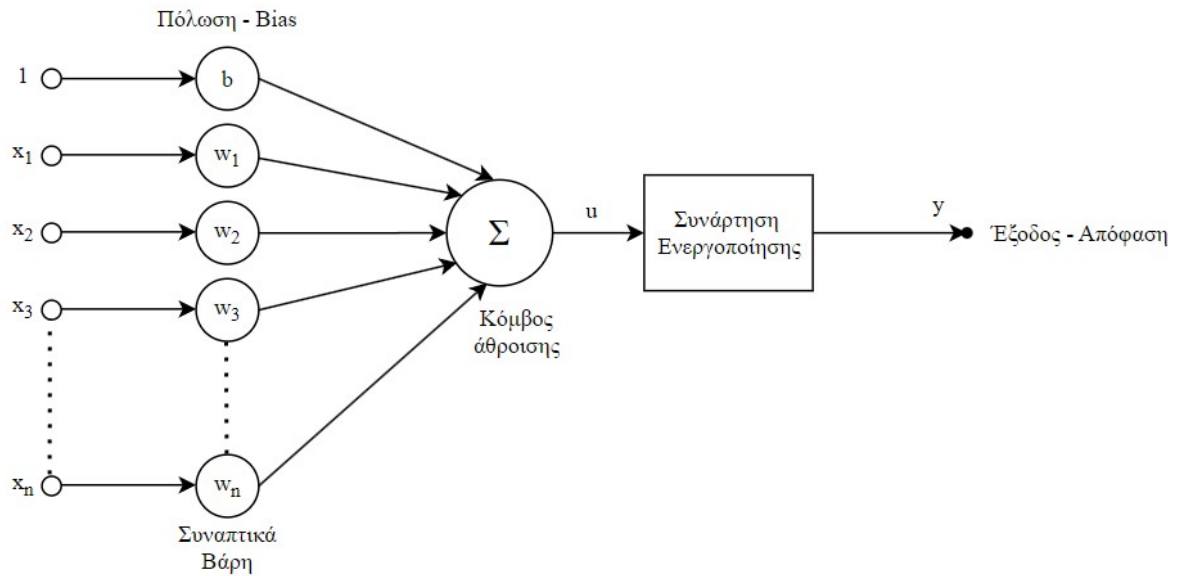
Όπως αναφέρεται και στην *Ενότητα 2.1 Σύντομη Ιστορική Αναδρομή*, ο Perceptron είναι το πρώτο μοντέλο προσέγγισης νευρωνικού δικτύου και το απλούστερο όλων, καθώς αποτελείται μόνο από έναν νευρώνα. Σύμφωνα με το *Σχήμα 2.5 Perceptron*, ο τεχνητός νευρώνας δέχεται ένα διάνυσμα εισόδου, τις τιμές του οποίου τις πολλαπλασιάζει με τα συναπτικά βάρη και το αποτέλεσμα του κάθε πολλαπλασιασμού αθροίζεται στον κόμβο άθροισης. Ο κόμβος άθροισης υπολογίζει ένα γραμμικό συνδυασμό των εισόδων και εισάγει έναν εξωτερικό παράγοντα που ονομάζεται πόλωση ή προδιάθεση (bias). [21]

Επομένως, η έξοδος του κόμβου άθροισης (και είσοδος της συνάρτησης ενεργοποίησης) εκφράζεται από την παρακάτω σχέση.

$$u = \sum_{i=1}^n (w_i \cdot x_i) + b \quad (2.4)$$

Η συνάρτηση ενεργοποίησης δέχεται στην είσοδό της, το αποτέλεσμα από τον κόμβο άθροισης και στην έξοδό της, παράγεται μία απόφαση. Ο συγκεκριμένος τεχνητός νευρώνας χρησιμοποιεί

ως συνάρτηση ενεργοποίησης τη βηματική συνάρτηση (Threshold Function) η οποία σαν έξοδο παράγει είτε -1, στην περίπτωση που δέχεται ως είσοδο αρνητική τιμή, είτε 1, στην περίπτωση που δέχεται θετική τιμή στην είσοδο.

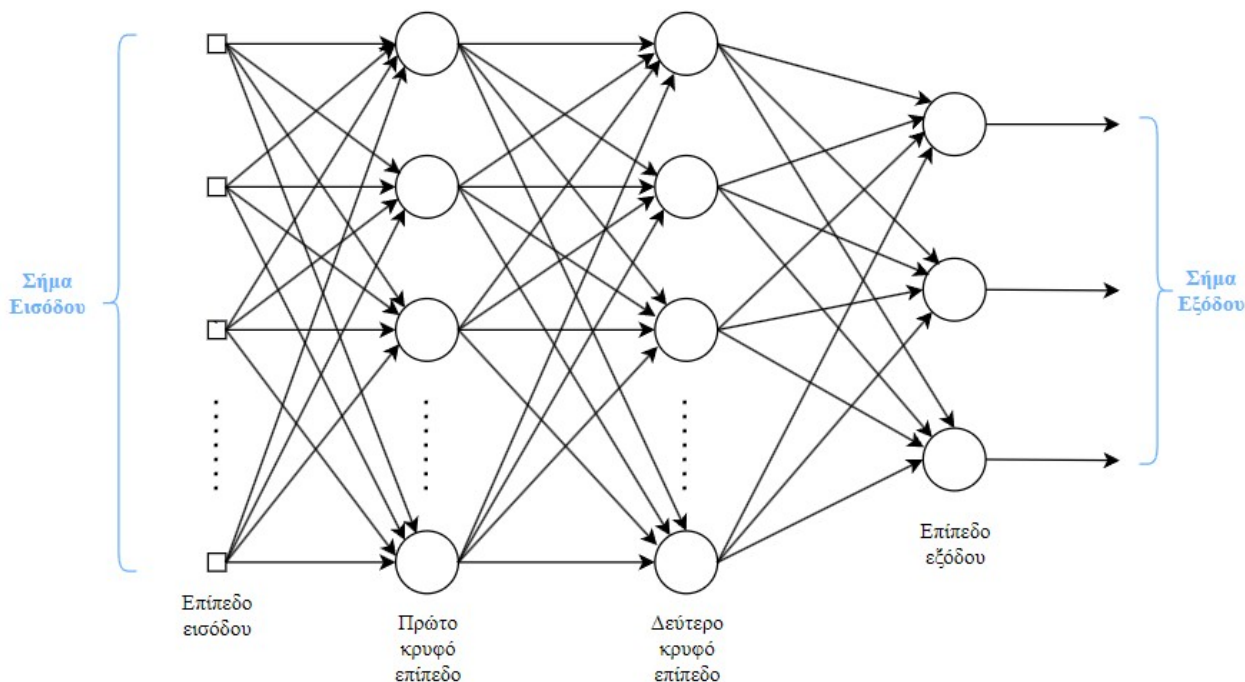


Σχήμα 2.5: Perceptron

Στόχος του Perceptron είναι να ταξινομήσει τα γραμμικά διαχωρίσιμα δεδομένα, που δέχεται στην είσοδο, σε δύο κλάσεις. Αυτό, το πραγματοποιεί μετατοπίζοντας το όριο απόφασης, ανάλογα την επίδραση της πόλωσης (bias), σε έναν χώρο όπου οι διαστάσεις καθορίζονται από τον αριθμό των μεταβλητών εισόδου.

2.4.2 Perceptrons Πολλαπλών Στοιβάδων (MLP: Multilayer Perceptrons)

Η τοπολογία Perceptrons πολλαπλών επιπέδων ή στοιβάδων είναι από τα πιο συνηθισμένα νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης και χαρακτηρίζεται από τη μη γραμμική συνάρτηση ενεργοποίησης στην έξοδο του κάθε νευρώνα, τα πολλαπλά επίπεδα τα οποία είναι κρυφά για την είσοδο και την έξοδο του δικτύου και την υψηλή διασυνδεσιμότητα, ο βαθμός της οποίας εξαρτάται από τα συναπτικά βάρη του δικτύου.[\[21\]](#)



Σχήμα 2.6: Αρχιτεκτονική δομή Perceptron πολλαπλών επιπέδων με δύο κρυφά επίπεδα

Εξαιτίας της υψηλής πολυπλοκότητας διασυνδεσιμότητας των νευρώνων του δικτύου, είναι δύσκολη η θεωρητική ανάλυση εκπαίδευσης των κρυφών στοιβάδων. Λύση σε αυτό έφερε, η ανάπτυξη του αλγορίθμου <<Back Propagation>>, ο οποίος ακολουθεί την αντίθετη διαδρομή της εμπρόσθιας τροφοδότησης, παράγοντας ένα σήμα σφάλματος, το οποίο συγκρίνεται με την έξοδο του κάθε νευρώνα και αναπροσαρμόζει τα συναπτικά βάρη του δικτύου. Η διαδικασία αυτή ονομάζεται οπισθοδιάδοση σφάλματος.

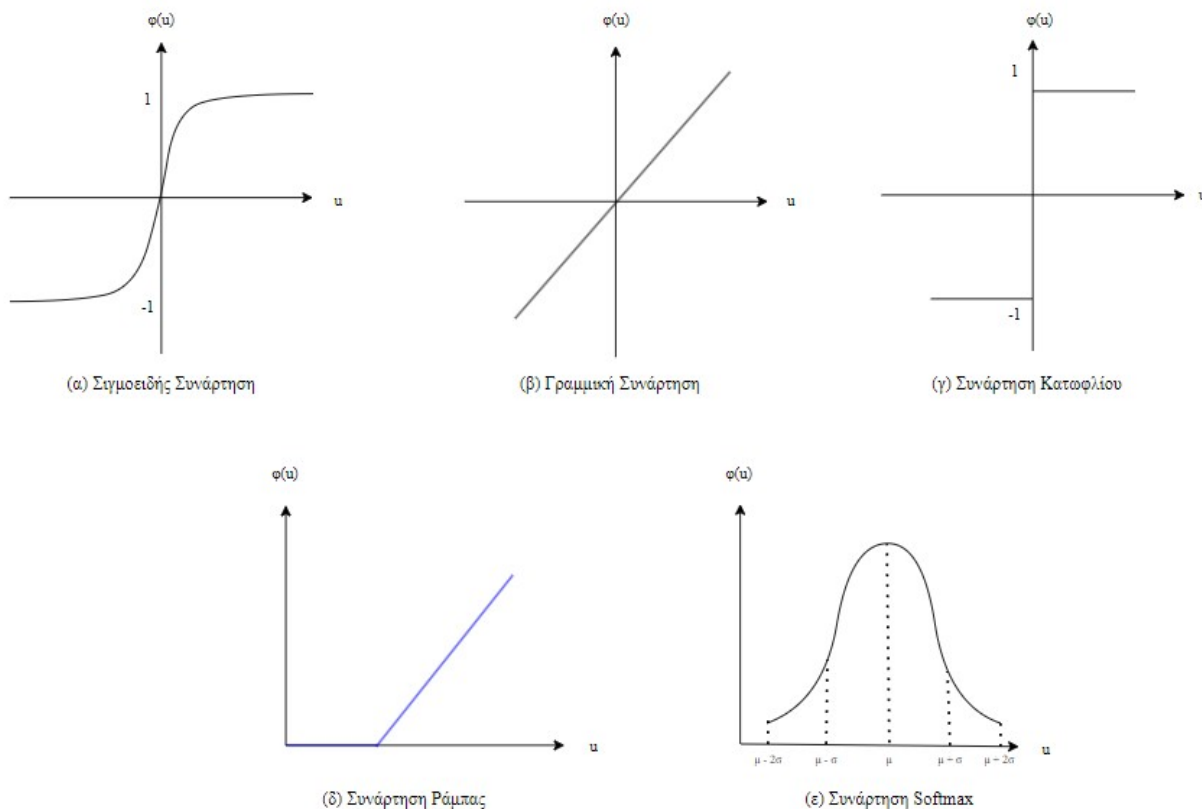
Σύμφωνα με τον Kolmogorov (1957), ένα δίκτυο MLP μπορεί να προσεγγίσει οποιαδήποτε μαθηματική συνάρτηση και χάρι σε αυτή την ιδιότητα, ένα τέτοιο δίκτυο, μπορεί να εκπαιδευτεί να μάθει τη συμπεριφορά οποιουδήποτε συστήματος.

2.4.3 Νευρωνικά Δίκτυα Εμπρόσθιας Τροφοδότησης (FNN: Feedforward Neural Network)

Τα Νευρωνικά Δίκτυα Εμπρόσθιας Τροφοδότησης έχουν την ίδια αρχιτεκτονική που απεικονίζεται στο Σχήμα 2.6. Όταν οι έξοδοι όλων των νευρώνων μίας στοιβάδας είναι είσοδοι όλων των νευρώνων της επόμενης στοιβάδας, τότε λέγεται ότι το δίκτυο είναι πλήρως συνδεδεμένο. Στην αντίθετη περίπτωση το δίκτυο είναι μερικώς συνδεδεμένο.

Όπως αναφέρθηκε στην προηγούμενη ενότητα τα MLP είναι μία κατηγορία FNN. Αυτό που διαφοροποιεί άλλα FNNs από τα MLP δίκτυα, είναι η συνάρτηση ενεργοποίησης των νευρώνων. Εφόσον τα MLP αποτελούνται από νευρώνες Perceptron, η συνάρτηση ενεργοποίησής τους θα είναι, αυστηρά, η συνάρτηση Κατωφλίου (Threshold Function), Σχήμα 2.7 (γ).

Τα FNNs, σε αντίθετη περίπτωση, μπορούν να έχουν και άλλες συναρτήσεις ενεργοποίησης, στις εξόδους των κόμβων άθροισης των νευρώνων, όπως για παράδειγμα τη σιγμοειδή συνάρτηση ή τη γραμμική συνάρτηση. Η σιγμοειδής συνάρτηση, Σχήμα 2.7 (α), χρησιμοποιείται για μεγαλύτερη ακρίβεια στις αποφάσεις του δικτύου, σε περιπτώσεις ταξινόμησης μη γραμμικά διαχωρίσιμων δεδομένων σε δύο κλάσεις, ενώ η γραμμική συνάρτηση, Σχήμα 2.7 (β), εφαρμόζεται σε περιπτώσεις προσέγγισης συνάρτησης,



Σχήμα 2.7: Συναρτήσεις Ενεργοποίησης Νευρωνικών Δικτύων Εμπρόσθιας Τροφοδότησης

Άλλες εξίσου αποδοτικές συναρτήσεις ενεργοποίησης είναι η συνάρτηση ράμπας ή αλλιώς Ανορθωμένη Γραμμική Μονάδα (ReLU: Rectified Linear Unit) *Σχήμα 2.7 (δ)*, η οποία προτιμάται για την χαμηλή υπολογιστική κατανάλωσή της και την καλύτερη διάδοση κλίσης, και η Κανονική Εκθετική Συνάρτηση (Softmax ή Softargmax) *Σχήμα 2.7 (ε)*. Η τελευταία χρησιμοποιείται κυρίως στους νευρώνες εξόδου διότι φτιάχνει μία κανονική κατανομή των πιθανοτήτων των κλάσεων σε προβλήματα κατηγοριοποίησης. [11], [12]

Για τον έλεγχο της αποδοτικότητας ενός νευρωνικού δικτύου εμπρόσθιας τροφοδότησης, που χρησιμοποιείται για αναγνώριση προτύπων, μπορεί να υπολογιστεί ο Πίνακας Σύγχυσης του προβλήματος. Όταν το νευρωνικό δίκτυο καλείται να κατηγοριοποιήσει τα δεδομένα που λαμβάνει σε δύο κλάσεις, τότε με τη χρήση του πίνακα αυτού μπορεί να φανεί πόσο καλά εκπαιδεύτηκε και πόσο αποδίδει στις προβλέψεις του.

		Πραγματικές Τιμές	
		Θετικό	Αρνητικό
Προβλέψεις	Θετικό	ΑΘ	ΨΑ
	Αρνητικό	ΨΘ	ΑΑ

Πίνακας 2.1: Παράδειγμα Πίνακα Σύγχυσης Δύο Κλάσεων

Όπου:

- ΑΘ: Αληθώς Θετικό
- ΨΘ: Ψευδώς Θετικό
- ΑΑ: Αληθώς Αρνητικό
- ΨΑ: Ψευδώς Αρνητικό

Ο συγκεκριμένος πίνακας παρουσιάζει είτε τα ποσοστά επιτυχίας και αποτυχίας των προβλέψεων είτε τα δεδομένα που αντιστοιχούν στην κάθε κατηγορία (ΑΘ, ΨΘ, ΑΑ, ΨΑ) σύμφωνα με τον Πίνακα 2.1. Αν το πρόβλημα απαιτεί ταξινόμηση σε άνω των δύο κλάσεων, τότε υπολογίζεται ο 2x2 πίνακας σύγκρισης για διαφορετικό συνδυασμό κλάσεων. Η συγκεκριμένη μέθοδος ελέγχου της αποδοτικότητας του νευρωνικού δικτύου μπορεί να εφαρμοστεί μόνο σε κατηγορίες μοντέλων επιβλεπομένης μάθησης.

2.4.4 Συσταδοποίηση μέσω Bayes (Naive Bayes)

Ο αλγόριθμος Naive Bayes χρησιμοποιείται για ομαδοποίηση των δεδομένων. Ανήκει στους αλγόριθμους επιβλεπομένης μηχανικής μάθησης και βασίζεται στο Θεώρημα του Bayes σύμφωνα με το οποίο ισχύει:

$$P(A \vee B) = \frac{P(B \vee A) \cdot P(A)}{P(B)} \quad (2.4) \quad [22]$$

όπου:

A, B : ενδεχόμενα,

P(A): Η πιθανότητα να συμβεί το ενδεχόμενο A,

P(B): Η πιθανότητα να συμβεί το ενδεχόμενο B,

P(A|B): Η πιθανότητα να συμβεί το ενδεχόμενο A δοθέντος ότι συνέβη το ενδεχόμενο B,

P(B|A): Η πιθανότητα να συμβεί το ενδεχόμενο B δοθέντος ότι συνέβη το ενδεχόμενο A.

Σε πλαίσια αλγορίθμου μηχανικής μάθησης η παραπάνω σχέση μπορεί να εκφραστεί ως εξής:

$$P(A \vee B) = \frac{P(B \vee A) \cdot P(A)}{P(B)} \Leftrightarrow \text{Posterior} = \frac{\text{Likelihood} \cdot \text{Prior}}{\text{Normalization}} \quad (2.5)$$

όπου,

A: το αποτέλεσμα ή υπόθεση,

B: το χαρακτηριστικό που δόθηκε,

Posterior: Η πιθανότητα εμφάνισης αποτελέσματος υπό την προϋπόθεση ότι ικανοποιεί το χαρακτηριστικό που δόθηκε,

Likelihood: Η πιθανότητα του χαρακτηριστικού (B) να ισχύει υπό την υπόθεση (A),

Prior: Η πιθανότητα ενός χαρακτηριστικού να ισχύει πριν διαβαστεί το χαρακτηριστικό.


Normalization: Αποτελεί την κλίμακα που ορίζει ότι το άθροισμα των εκ των υστέρων (posterior) πιθανοτήτων είναι 1.

Υπάρχουν τρία είδη μοντέλων κατά Naive Bayes και αυτά είναι:

- το Bernoulli Naive Bayes,
- το Gaussian Naive Bayes,
- και το Multinomial Naive Bayes.

Στην συγκεκριμένη διπλωματική εργασία δίνεται έμφαση στο μοντέλο εκπαίδευσης GNB (Gaussian Naive Bayes). Το μοντέλο αυτό, χρησιμοποιείται όταν τα δεδομένα εκπαίδευσης είναι συνεχή. Με τον όρο 'συνεχή' εννοείται ότι τα δεδομένα μπορούν να πάρουν οποιαδήποτε τιμή σε μια ροή δεδομένων.

Το μοντέλο GNB, βασίζεται στην Συνάρτηση Πυκνότητας Πιθανότητας (ΣΠΠ) της κανονικής κατανομής.



Εικόνα 2.1 Κανονική Κατανομή Πιθανοφάνειας μίας Παραμέτρου [22]

Για να πραγματοποιηθούν προβλέψεις, βάσει αυτού του μοντέλου, αρκεί να υπολογιστούν η τυπική απόκλιση και η μέση τιμή των τιμών των δεδομένων και να εφαρμοστούν στην ΣΠΠ, ώστε να υπολογιστούν οι πιθανότητες των νέων τιμών να ανήκουν σε μία κλάση. [22]

Η ΣΠΠ της κανονικής κατανομής εκφράζεται από την παρακάτω σχέση:

$$pdf(x, mean, sd) = \frac{e^{-\frac{x - mean^2}{2 \cdot sd^2}}}{\sqrt{2\pi} \cdot sd} \quad (2.6)$$

όπου,

$$mean(x) = \frac{\sum(x)}{n} \quad (2.7) \quad \text{και} \quad Standard\ Deviation(x) = \sqrt{\frac{\sum(x_i - mean(x))^2}{n}} \quad (2.8)$$

2.4.5 Αλγόριθμος Ακραίας Ενίσχυσης Κλίσης (XGBoost: eXtreme Gradient Boosting)

Ο συγκεκριμένος αλγόριθμος μηχανικής μάθησης αποτελεί μία μέθοδο μάθησης βασιζόμενη σε αλγορίθμους δενδρικής δομής και συγκεκριμένα σε αυτούς που χρησιμοποιούν ενίσχυση κλίσης (Gradient Boosting Algorithms). Η κύρια διαφορά του με άλλους αλγορίθμους ενίσχυσης κλίσης είναι ότι, ο συγκεκριμένος, αντί να δημιουργεί δένδρα διαδοχικά -δηλαδή, αργή μάθηση που πραγματοποιείται με τη δημιουργία δένδρων το ένα μετά το άλλο, ο XGBoost δημιουργεί δένδρα παράλληλα και αυτό τον καθιστά έναν από τους καταλληλότερους αλγορίθμους συσταδοποίησης και παλινδρόμησης συνεχών δεδομένων.


Ο XGBoost χρησιμοποιεί έναν αλγόριθμο εκτίμησης, ο οποίος τοποθετεί τα συνεχή δεδομένα σε διακριτούς “κάδους” με αποτέλεσμα να επιταχύνεται η διαδικασία μάθησης. Σε κάθε επανάληψη του αλγορίθμου δημιουργείται νέα ομάδα “κάδων” δεδομένων και με τη βοήθεια ενός αλγορίθμου Ιστογράμματος, συγκρίνονται τα ιστογράμματα των “κάδων” κάθε επανάληψης, αυξάνοντας την αποδοτικότητα εκπαίδευσης. [23]

2.4.6 Μηχανή Ελαφράς Ενίσχυσης Κλίσης (LightGBM: Light Gradient Boosting Machine)

Ο αλγόριθμος LightGBM δημιουργήθηκε μεταγενέστερα του XGBoost και λειτουργεί με παρόμοια λογική. Αποτελεί, και αυτός, ένα είδος αλγορίθμου που χρησιμοποιεί δενδρικές δομές και ενίσχυση κλίσης. Σχεδιάστηκε ώστε να εκπαιδεύει με υψηλή ταχύτητα μεγάλο όγκο δεδομένων αποδοτικά.

Ο LightGBM ξεπερνά, σε ακρίβεια αποτελεσμάτων και ταχύτητα, τον XGBoost και αυτό το καταφέρει χάρη στη διαφορετική προσέγγιση εκπαίδευσης. Συγκεκριμένα, ο LightGBM χρησιμοποιεί την μέθοδο ανάπτυξης των δενδρικών δομών, που δημιουργεί, βασισμένη σε κόμβους.

Γενικά υπάρχουν δύο κύριες μέθοδοι ανάπτυξης δενδρικών δομών. Η πρώτη αναφέρεται στην ανάπτυξη βάσει κόμβου και η δεύτερη βάσει επιπέδου, όπως δεικνύει και η Εικόνα 2.2.



Εικόνα 2.2 Ανάπτυξη δενδρικών δομών βάσει επιπέδου (Level-wise) και βάσει κόμβου (Leaf-wise) [23]

Ο πιο διαδεδομένος τρόπος ανάπτυξης δενδρικών δομών είναι αυτός βάσει επιπέδου και χρησιμοποιείται από τους περισσότερους αλγόριθμους δενδρικών δομών, συμπεριλαμβανομένου και του XGBoost. Ο LightGBM παρουσιάζει τον δεύτερο τρόπο ανάπτυξης δενδρικών δομών, ο οποίος συγκλίνει ταχύτερα του πρώτου, με αποτέλεσμα την ελαχιστοποίηση του υπολογιστικού κόστους και την εμφάνιση μικρότερων σφαλμάτων. Αυτό επιτυγχάνεται καθώς, ο LightGBM, δημιουργεί ιστογράμματα σε κάθε κόμβο τα οποία συγκρίνονται σε κάθε επανάληψη ενισχύοντας την επίδοση της μάθησης. [23]

2.5 Μέθοδοι Βελτιστοποίησης Εκπαίδευσης Μηχανικής Μάθησης

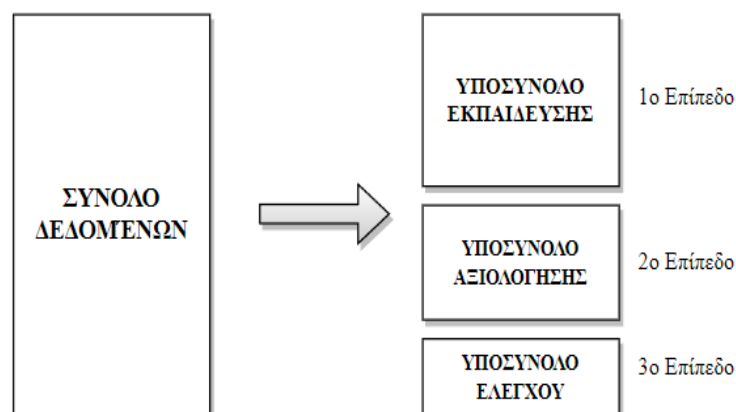
Πολλοί από τους αλγόριθμους που αναφέρονται στην *Ενότητα 2.4* εμφανίζουν όρια βελτιστοποίησης, καθώς είτε αργούν να συγκλίνουν είτε τα όρια απόφασης τους κυμαίνονται σε μεγάλα διαστήματα. Οι μέθοδοι βελτιστοποίησης εκπαίδευσης αποτελούν ένα εργαλείο που επιλύει προβλήματα αοριστίας και ανακρίβειας των αποτελεσμάτων έπειτα από την εκπαίδευση ενός συστήματος μηχανικής μάθησης. Μπορούν να αποδώσουν μεγαλύτερες ακρίβειες με διάφορες τεχνοτροπίες και να βοηθήσουν το σύστημα να εκπαιδευτεί όσο το δυνατόν πιο βέλτιστα. Σε αυτήν την ενότητα δεικνύονται κάποιες από τις πιο διαδεδομένες μεθόδους βελτιστοποίησης εκπαίδευσης σε συστήματα μηχανικής μάθησης.

2.5.1 Διασταυρωμένη Επικύρωση (Cross Validation)

Η τεχνική της *διασταυρωμένης επικύρωσης* αποτελεί εργαλείο της στατιστικής και βοηθάει ως προς τον ορισμό του αριθμού των νευρώνων και στοιβάδων σε ένα νευρωνικό δίκτυο. Η συγκεκριμένη τεχνική εφαρμόζεται όταν ο σχεδιαστής του νευρωνικού δικτύου επιθυμεί να αξιολογήσει το δίκτυο ως προς το πόσο καλά εκπαιδεύεται. Το πόσο καλά εκπαιδεύεται ένα νευρωνικό δίκτυο σημαίνει πόσο καλά μπορεί να γενικεύει.

Κατά τη *διασταυρωμένη επικύρωση*, χωρίζεται σε δύο τμήματα-επίπεδα (folds) το σύνολο των προς εκπαίδευση δεδομένων. Το πρώτο επίπεδο αποτελεί το κομμάτι των δεδομένων το οποίο θα χρησιμοποιηθεί για εκπαίδευση του νευρωνικού δικτύου και εφόσον ολοκληρωθεί, η εκπαίδευση, θα χρησιμοποιηθεί το δεύτερο υποσύνολο δεδομένων για αξιολόγηση της εκπαίδευσης του δικτύου.

Στη συνέχεια, μπορεί να χρησιμοποιηθεί το πρώτο υποσύνολο δεδομένων για αξιολόγηση και το δεύτερο για εκπαίδευση, ώστε να επιλεγθεί το βέλτιστο εκπαιδευμένο δίκτυο.



Σχήμα 2.8 Τεχνική Διασταυρωμένης Επικύρωσης

Στην περίπτωση που το δίκτυο υπερ-εκπαιδεύεται με δύο υποσύνολα, τότε ο σχεδιαστής του δικτύου ορίζει ένα τρίτο υποσύνολο το οποίο θα έχει τον ρόλο του ελέγχου όπως φαίνεται στο Σχήμα 2.8. Το φαινόμενο της υπερ-εκπαίδευσης (overfitting) συμβαίνει όταν το νευρωνικό δίκτυο έχει περισσότερους νευρώνες ανά στοιβάδα, επομένως και πολλές συνάψεις, με αποτέλεσμα να μην ανιχνεύεται ο θόρυβος των δεδομένων και το δίκτυο να μην μπορεί να γενικεύει. [21]

2.5.2 Διασταυρωμένη Επικύρωση K-Επιπέδων (K-Folds Cross Validation)

Ο πιο αξιόπιστος τρόπος να εφαρμοστεί με επιτυχία η τεχνική Διασταυρωμένης Επικύρωσης, είναι να χωριστεί το σύνολο δεδομένων σε περισσότερα από δύο υποσύνολα. Αν τα υποσύνολα είναι υπερπληθή, τότε το υπολογιστικό φορτίο αυξάνεται. Επομένως είναι στην κρίση του αναλυτή σε πόσα επίπεδα θα χωριστεί το σετ δεδομένων.

Κατά την εφαρμογή της διασταυρωμένης επικύρωσης πολλών επιπέδων, ένα υποσύνολο δεδομένων χρησιμοποιείται για αξιολόγηση - επικύρωση και τα υπόλοιπα για εκπαίδευση. Το Σχήμα 2.9 δεικνύει ένα παράδειγμα συνόλου δεδομένων το οποίο έχει διαιρεθεί σε τέσσερα επίπεδα (folds), το ένα εξ αυτών, που σκιάζεται με μωβ χρώμα, αποτελεί το υποσύνολο Αξιολόγησης.




Σχήμα 2.9 Πολλαπλά Επίπεδα Διασταυρωμένης Επικύρωσης και η μέθοδος Πολλαπλής Διασταύρωσης

Στη συγκεκριμένη τεχνική υπολογίζεται το μέσο τετραγωνικό σφάλμα της επικύρωσης για κάθε δοκιμή. Το μοντέλο, επομένως, που επιλέγεται είναι αυτό με το μικρότερο σφάλμα άρα και τη μεγαλύτερη απόδοση. [21]

2.5.3 Ισοκατανεμημένα Δεδομένα σε K-Επίπεδα (Stratified K-Folds)

Η συγκεκριμένη τεχνική αποτελεί μία επέκταση αυτής που αναφέρεται στην Ενότητα 2.5.2 και εφαρμόζεται ώστε να καλύψει σφάλματα της προηγούμενης. Συγκεκριμένα, χωρίζεται πάλι το σύνολο των δεδομένων σε υποσύνολα, με τη διαφορά ότι για κάθε κλάση, από τα τιλοφορημένα δεδομένα, δεσμεύεται ίσο τμήμα για το συνολικό υποσύνολο της αξιολόγησης και αντίστοιχα της εκπαίδευσης. Αυτό συμβαίνει, ώστε κάθε επίπεδο να διαθέτει την ανάλογη ποσότητα δεδομένων κάθε κλάσης για να επιτυγχάνεται καλύτερη εκπαίδευση και ακολούθως καλύτερη αξιολόγηση.



Σχήμα 2.10. Σχηματική αναπαράσταση μεθόδου Ισοκατανεμημένων Πολλαπλών Επιπέδων

Το παραπάνω σχήμα αποτελεί ένα παράδειγμα τεσσάρων επιπέδων όπου εφαρμόζεται η μέθοδος Ισοκατανεμημένων πολλαπλών επιπέδων διασταυρωμένης επικύρωσης.

Το αποδοτικότερο μοντέλο θα είναι, και σε αυτήν την περίπτωση, αυτό με το μικρότερο σφάλμα.

2.5.4 Διερευνητική Ανάλυση Δεδομένων (EDA: Exploratory Data Analysis)

Η Διερευνητική Ανάλυση Δεδομένων (EDA) αποτελεί ένα επιστημονικό πεδίο το οποίο ασχολείται με τεχνικές αξιολόγησης και ανάλυσης των δεδομένων που σκοπεύουν να τροφοδοτηθούν σε κάποιο αλγόριθμο μηχανικής μάθησης. Κάποιες από αυτές τις τεχνικές είναι οι παρακάτω.

A. Μετασχηματισμός Χαρακτηριστικών:

1. Αντικατάσταση δεδομένων (Imputation of the Data)

Κατά την τεχνική αυτή τα δεδομένα που έχουν μηδενική τιμή αντικαθίστανται με τη μέση τιμή ή τη διάμεσο της στήλης στην οποία ανήκουν. Το πλεονέκτημα αυτής της τεχνικής είναι ότι δεν χρειάζεται να αφαιρεθεί ολόκληρη η γραμμή του δεδομένου που μπορεί να περιέχει καλής ποιότητας χαρακτηριστικά. Το μειονέκτημα είναι ότι προστίθεται ένας βαθμός αβεβαιότητας όταν πραγματοποιείται προσέγγιση της τιμής που λείπει. [31]

2. Τυπική Κλιμάκωση Δεδομένων (Standard Scaling)

Η τυπική κλιμάκωση δεδομένων εφαρμόζεται σε συνεχή δεδομένα και χρησιμοποιείται για τον εντοπισμό ακραίων τιμών και την επιρροή αυτών. Η συγκεκριμένη κλιμάκωση πραγματοποιείται αφού η τιμή του δεδομένου αφαιρεθεί από τον μέσο όρο και διαιρεθεί με την τυπική απόκλιση αυτού. [32]

3. Κατώφλι Διακύμανσης (Variance Threshold)

Η συγκεκριμένη τεχνική είναι μία απλή τεχνική κατά την οποία αφαιρούνται τα δεδομένα τα οποία ξεπερνούν κάποιο όριο τιμής της διακύμανσης. Όταν χρησιμοποιείται χωρίς να οριστεί κάποια οριακή τιμή διακύμανσης, αφαιρούνται οι τιμές με μηδενική διακύμανση. [23]

2.5.5 Αλγόριθμος Βελτιστοποίησης Μηχανικής Μάθησης ADAM

Ο αλγόριθμος ADAM είναι ένας στοχαστικός αλγόριθμος καθόδου κλίσης και χρησιμοποιείται ευρέως για την βελτιστοποίηση μοντέλων μηχανικής μάθησης. Πρόκειται για έναν αλγόριθμο παρόμοιο με αυτόν της ελάχιστης καθόδου και η λειτουργία του είναι η προσαρμογή του ρυθμού μάθησης ανάλογα την κλίση, για κάθε παράμετρο ξεχωριστά.

Είναι ένας αποδοτικός αλγόριθμος αναφορικά με τον χειρισμό των κλίσεων σε μοντέλα βαθιάς μηχανικής μάθησης και πραγματοποιεί την παραμετροποίηση του μοντέλου με τα παρακάτω βήματα:

Βήμα 1ο: Ενημερώνει την εκτίμηση της πρώτης χρονικής στιγμής

$$m(t) = \beta_1 \cdot m(t-1) + (1 - \beta_1) \cdot g(t) \quad (2.9)$$

Βήμα 2ο: Ενημερώνει την εκτίμηση της δεύτερης χρονικής στιγμής

$$v(t) = \beta_2 \cdot v(t-1) + (1 - \beta_2) \cdot (g(t))^2 \quad (2.10)$$

Βήμα 3ο: Υπολογίζει την εκτίμηση διόρθωσης πρώτης χρονικής στιγμής

$$\hat{m}(t) = \frac{m(t)}{1 - \beta_1^t} \quad (2.11)$$

Βήμα 4ο: Υπολογίζει την εκτίμηση διόρθωσης δεύτερης χρονικής στιγμής

$$\hat{v}(t) = \frac{v(t)}{1 - \beta_2^t} \quad (2.12)$$

Βήμα 5ο: Ανανεώνει την παράμετρο

$$\hat{w}(t) = w(t-1) - a \cdot \frac{\hat{m}(t)}{\sqrt{\hat{v}(t) + \epsilon}} \quad (2.13)$$

όπου,

$m(t)$: η εκτίμηση της πρώτης χρονικής στιγμής

$v(t)$: η εκτίμηση της δεύτερης χρονικής στιγμής

$g(t)$: η κλίση την χρονική στιγμή t

β_1 και β_2 : οι παράμετροι που ελέγχουν τους ρυθμούς εξασθένησης

a : ο ρυθμός μάθησης

ϵ : αριθμός ελάχιστης τιμής για να μην υπάρξει διαίρεση με το μηδέν [30]

2.5.6 Μετρητικές Ποσοτικοποιήσεις Αξιολόγησης Απόδοσης

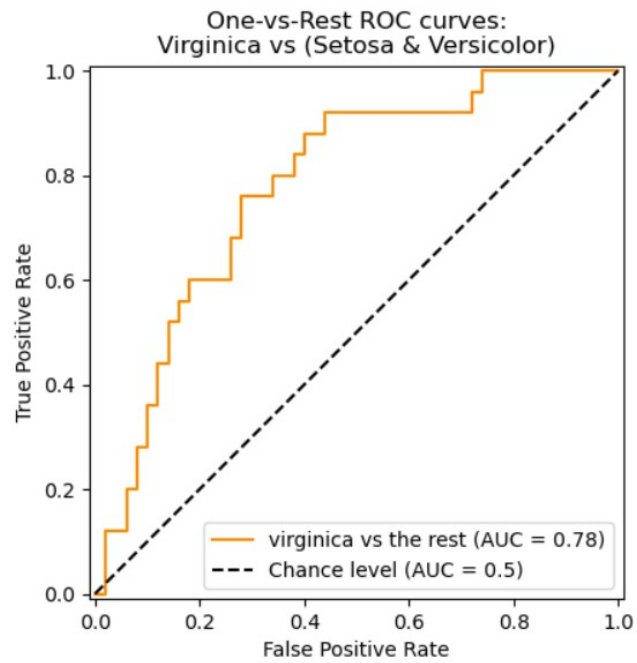
Κάποιες από τις πιο διαδεδομένες μετρητικές ποσοτικοποιήσεις αξιολόγησης απόδοσης που χρησιμοποιούνται σε προβλήματα κατηγοριοποίησης (classification) στην επιβλεπόμενη μάθηση είναι:

1. F1 macro

Είναι υποκατηγορία του F1 score, το οποίο μπορεί να αποδοθεί ως ο αρμονικός μέσος όρος της ακρίβειας και της ανάκλησης και παίρνει τιμές μεταξύ μηδέν και ένα με ένα να είναι το καλύτερο σκορ και μηδέν το χειρότερο. Το F1 macro υπολογίζει και βρίσκει το μη σταθμισμένο μέσο των κλάσεων χωρίς να λαμβάνει υπόψιν την ανισορροπία αυτών.

2. Περιοχή κάτω από τη λειτουργική χαρακτηριστική καμπύλη δέκτη ROC AUC

Η λειτουργική καμπύλη δέκτη (ROC) χρησιμοποιείται σε προβλήματα κατηγοριοποίησης δύο κλάσεων και αναπαριστά γραφικά τους ρυθμούς πρόβλεψης Αληθώς Θετικών και Ψευδώς Θετικών προβλέψεων όπως φαίνεται στην *Εικόνα 2.3*.



Εικόνα 2.3 Παράδειγμα Λειτουργικής Καμπύλης Δέκτη [\[15\]](#)

Η περιοχή κάτω από την καμπύλη ROC δεικνύει την συνολική απόδοση του μοντέλου και συγκεκριμένα με υψηλότερη AUC επιτυγχάνεται καλύτερη απόδοση.

3 ΚΕΦΑΛΑΙΟ 3^ο : Ασύρματη Ανίχνευση (Wireless Sensing)

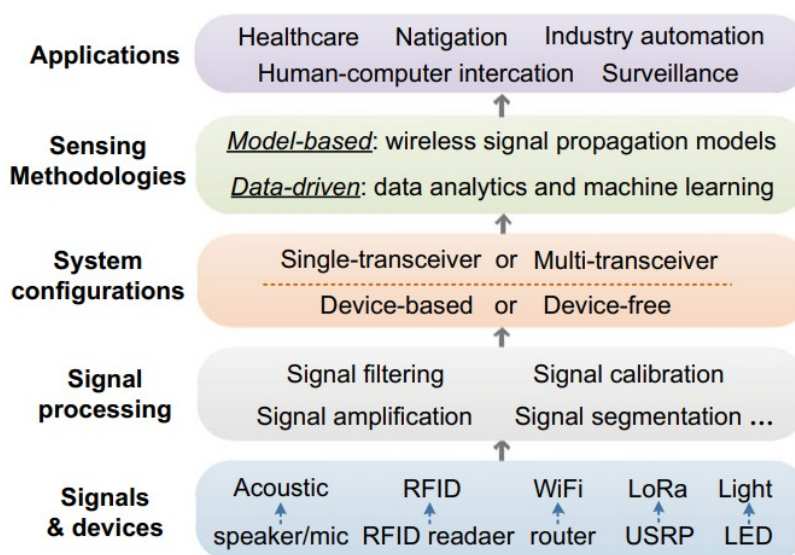
Στις μέρες μας υπάρχουν πολλά είδη τεχνολογιών ανίχνευσης (sensing), μίας επιθυμητής πληροφορίας, τα οποία προϋποθέτουν αισθητήρες ή αισθητήρια συστήματα ώστε να εξαχθεί η επιθυμητή πληροφορία σε κατάλληλη μορφή προς επεξεργασία. Η τεχνολογία ανίχνευσης πληροφοριών μέσω ασύρματης επικοινωνίας συστημάτων, αποτελεί μία τεχνολογία, η οποία χρησιμοποιείται όλο και περισσότερο στην σημερινή κοινωνία. Σε αυτό το κεφάλαιο παρουσιάζονται κάποιες γνωστές εφαρμογές, της συγκεκριμένης τεχνολογίας, και δίνεται έμφαση σε αυτήν που αφορά το αντικείμενο της διπλωματικής εργασίας, καθώς επίσης δεικνύονται αποτελέσματα τρίτων σχετικά με την συγκεκριμένη εφαρμογή.

3.1 Εισαγωγή στην Ασύρματη Ανίχνευση

Η ασύρματη ανίχνευση διαφέρει από τα υπόλοιπα είδη ανίχνευσης, καθώς δεν απαιτεί επιπλέον υλικοτεχνική υποδομή από την ήδη υπάρχουσα (κινητά, δρομολογητές κλπ). Είναι ένα είδος ανίχνευσης, το οποίο έχει ανέλθει τις τελευταίες δεκαετίες και εκμεταλλεύεται ακουστικά, οπτικά και RF σήματα ανάμεσα σε έναν ή πολλούς πομπούς και έναν ή πολλούς δέκτες για να πραγματοποιήσει την ανίχνευση.

Η ανίχνευση, συγκεκριμένα, αφορά ζωντανούς οργανισμούς, αντικείμενα και περιβάλλοντα και μπορεί να εξεταστεί σε δύο επίπεδα. Αρχικά, εξετάζεται αναφορικά με την κινητικότητα των προς ανίχνευση στόχων. Πιο αναλυτικά, όταν ένα αντικείμενο ή ζωντανός οργανισμός κινείται σε έναν χώρο, ο οποίος είναι ο δίαυλος επικοινωνίας ενός τηλεπικοινωνιακού συστήματος, τότε τα χαρακτηριστικά των σημάτων που ανταλλάσσονται μεταξύ πομπού και δέκτη αλλάζουν. Ανιχνεύοντας, τις αλλαγές αυτές μπορούν να αποσπαστούν πληροφορίες σχετικά με την ταχύτητα των στόχων, την θέση, το πλήθος κλπ.

Δεύτερον, η ανίχνευση μπορεί να εξεταστεί ως προς την στατικότητα του περιβάλλοντος, που διαδίδονται, ασύρματα, τα σήματα. Όταν προστίθεται ή αφαιρείται ένα αντικείμενο στον χώρο διάδοσης των σημάτων ή όταν αλλάζει ένα χαρακτηριστικό του περιβάλλοντος (πχ, η θερμοκρασία), τότε αλλάζει και το μέσο διάδοσης. Αν ανιχνευθούν αυτές οι αλλαγές, τότε μπορούν να εξαχθούν πληροφορίες σχετικά με το περιβάλλον από τη συμπεριφορά των σημάτων.



Εικόνα 3.1 Πλαίσιο Ασύρματης Ανίχνευσης [24]

Τα σήματα που χρησιμοποιούνται σε κάθε παράδειγμα περίπτωσης, έχουν διαφορετικά χαρακτηριστικά (μήκος κύματος, ζώνη συχνοτήτων κλπ.) και ανάλογα την περίπτωση χρήσης ανίχνευσης πρέπει να επιλεγούν με γνώμονα τις απαιτήσεις της περίπτωσης. [24]

3.2 Εφαρμογές

Η Ασύρματη Ανίχνευση έχει μεγάλο εύρος χρησιμότητας στην σημερινή κοινωνία και έχει βοηθήσει στην ανάπτυξη πολλών τεχνολογιών. Κάποια βασικά πεδία εφαρμογών της συγκεκριμένης τεχνολογίας είναι οι παρακάτω.

- **Εφαρμογές Υγείας και Καλύτερευσης Συνθηκών Ζωής**, οι οποίες αφορούν κυρίως την παρακολούθηση των ζωτικών ενδείξεων ενός ανθρώπου, την παρακολούθηση άσκησης σώματος ενός ανθρώπου και την αναγνώριση καθημερινών δραστηριοτήτων του με σκοπό την καλύτερευση της ζωής του.
- **Αλληλεπίδρασης Ανθρώπου-Υπολογιστή**. Οι εφαρμογές αυτές εστιάζουν κυρίως σε περιπτώσεις αναγνώρισης φωνής και σε περιπτώσεις αναγνώρισης και ανίχνευσης χειρονομιών που αποσκοπούν στην αλληλεπίδραση του ανθρώπου με έναν υπολογιστή.
- **Εφαρμογές σε Βιομηχανικούς Αυτοματισμούς**. Στους Βιομηχανικούς Αυτοματισμούς η ασύρματη ανίχνευση χρησιμοποιείται σε παραδείγματα περιπτώσεων όπως την παρακολούθηση απόδοσης μηχανών και την αναπαράσταση του περιβάλλοντος σε εικόνες τριών διαστάσεων (χρησιμεύει κυρίως στην πλοήγηση και αναγνώριση δραστηριοτήτων και αντικειμένων, των ρομπότ).
- **Εφαρμογές Ασφάλειας και Επιτήρησης**, οι οποίες αναφέρονται σε εφαρμογές ανίχνευσης παρουσίας ή μη ενός ατόμου, καταμέτρησης αριθμού ατόμων, ταυτοποίησης ατόμου και στον εντοπισμό ύποπτων αντικειμένων για λόγους ασφάλειας.
- **Πλοήγησης σε Εσωτερικό Χώρο**, οι οποίες χρησιμοποιούνται για τον εντοπισμό ανθρώπων και αντικειμένων σε εσωτερικό χώρο. [24]

Η περίπτωση εφαρμογής καταμέτρησης αριθμού ατόμων σε εσωτερικό χώρο αναλύεται περαιτέρω στην επόμενη υπο-ενότητα, καθώς αποτελεί το αντικείμενο μελέτης και πειραματισμού αυτής της διπλωματικής εργασίας.

3.2.1 Καταμέτρηση Αριθμού Ατόμων σε Εσωτερικό Χώρο

Η καταμέτρηση αριθμού ατόμων σε εσωτερικό χώρο χρησιμεύει στον έλεγχο ασφάλειας ενός χώρου και επιτήρησης του πλήθους ατόμων που βρίσκονται σε αυτόν. Μία μέθοδος επίτευξης λειτουργίας ενός τέτοιου συστήματος υλοποιείται με τη χρήση καμερών, αλλά η συγκεκριμένη μέθοδος εμφανίζει κάποια προβλήματα. Αρχικά, ένα τέτοιο σύστημα απαιτεί την κοστοβόρα εγκατάσταση δικτύου καμερών, έπειτα, δεν μπορεί να λειτουργήσει αποδοτικά στο σκοτάδι, δεν λειτουργεί όταν εμποδίζεται το LoS (Line-of-Sight βλ. Ενότητα 1) από τοίχους ή άλλα αντικείμενα και τέλος καταπατά την ιδιωτικότητα των ατόμων. [27]

Σε αντίθεση με το παραπάνω παράδειγμα υλοποίησης, η ανίχνευση ατόμων με χρήση ραδιοσυχνωτικών σημάτων (RF signals) λύνει τα παραπάνω ζητήματα καθώς τα ραδιοσυχνωτικά σήματα έχουν τη δυνατότητα να διαπερνούν τοίχους, δεν έχουν υψηλό κόστος και δυσκολία εγκατάστασης και δεν παραβιάζουν την ιδιωτικότητα των ατόμων.

Η ανίχνευση πλήθους ατόμων που χρησιμοποιεί ασύρματες συσκευές για την ανίχνευση, μπορεί να υλοποιηθεί με δύο τρόπους. Είτε με την κατοχή συσκευών επικοινωνίας (πομπούς ή δέκτες), από τα άτομα, είτε με τη μή κατοχή συσκευών. Στην πρώτη περίπτωση είναι πιο εύκολο να ανιχνευτεί ο ακριβής αριθμός των ατόμων, ενώ στη δεύτερη μπορεί να ανιχνευτεί ένας μέσος όρος

των ατόμων, ο οποίος κατηγοριοποιείται σε τρεις κατηγορίες: χαμηλό, μεσαίο και υψηλό, ανάλογα την ισχύ του σήματος στον δέκτη. [27], [29]

Με τη χρήση της συγκεκριμένης τεχνολογίας μπορούν να ανιχνευθούν εγκλωβισμένα άτομα, να διεκπεραιωθούν στατιστικές μελέτες αναφορικά με τους πελάτες μίας επιχείρησης κλπ.

3.3 Ανίχνευση μέσω WiFi και Βαθιάς Μάθησης

Η βασική ιδέα γύρω από την ανίχνευση ατόμων βασιζόμενη σε σήματα WiFi, είναι η ανίχνευση των κινήσεων ενός ατόμου σε έναν χώρο (εσωτερικό), όπου καθώς κινείται ή απλά στέκεται, το πλάτος των σημάτων αλλάζει. Αυτή η αλλαγή εντοπίζεται στη ροή των CSI δεδομένων που συλλέγονται και αφού ολοκληρωθεί η συλλογή, τροφοδοτούνται σε έναν αλγόριθμο βαθιάς μάθησης ώστε να πραγματοποιηθεί η εκπαίδευση και τελικά να προβλέπεται ο αριθμός ατόμων σε έναν εσωτερικό χώρο.

Στην πραγματικότητα, για να μπορέσει να υλοποιηθεί η παραπάνω διαδικασία πρέπει να ληφθούν υπόψιν κάποια τεχνικά ζητήματα ζωτικής σημασίας. Αρχικά, θα πρέπει να βρεθεί ένας τρόπος να συσχετιστούν τα CSI δεδομένα με τον αριθμό των ατόμων. Έπειτα, πρέπει να εξαχθεί ένας μεγάλος όγκος από ποιοτικά δεδομένα ώστε να μπορέσει να γίνει η εκπαίδευση ενός μοντέλου μηχανικής μάθησης πιο αντικειμενικά. [28] Τέλος πρέπει να επιλεγθεί το κατάλληλο μοντέλο μηχανικής μάθησης και οι κατάλληλες τεχνικές επεξεργασίας των δεδομένων ώστε να εκπαιδευτεί και κατά επέκταση να μπορεί να προβλέπει αποδοτικά τον αριθμό των παρευρισκομένων ατόμων στον χώρο μελέτης.

Εφόσον επιλυθούν τα παραπάνω τεχνικά ζητήματα, μπορεί να χρησιμοποιηθεί το εκάστοτε μοντέλο μηχανικής μάθησης για οποιοδήποτε παράδειγμα περίπτωσης όπου απαιτείται ή επιθυμείται η ανίχνευση αριθμού ατόμων σε εσωτερικό χώρο.

4 ΚΕΦΑΛΑΙΟ 4^ο : Τεχνικό μέρος

Στο συγκεκριμένο κεφάλαιο παρουσιάζεται αναλυτικά η υλοποίηση ενός συστήματος ανίχνευσης αριθμού ατόμων σε εσωτερικό χώρο με χρήση ασύρματης ανίχνευσης WiFi και μηχανικής μάθησης. Συγκεκριμένα, συγκροτούνται οι γνώσεις που αποκομίσθηκαν κατά τη διένεξη έρευνας για την εκπόνηση των προηγούμενων κεφαλαίων και εφαρμόζονται στην υλοποίηση των συστημάτων ανίχνευσης. Επιπροσθέτως, δεικνύεται η διαχείριση των συλλεχθέντων δεδομένων, όπως επίσης και η χρήση, των αναλυμένων στο 2ο Κεφάλαιο, αλγορίθμων μηχανικής μάθησης ώστε να εξαχθεί το καλύτερο δυνατό αποτέλεσμα.

4.1 Προσέγγιση Υλοποίησης

Η προσέγγιση της υλοποίησης των συστημάτων, ακολουθεί τη διάταξη συστήματος ασύρματης ανίχνευσης, κατά την οποία τα υποκείμενα δεν απαιτείται να εξοπλίζονται με συσκευές (πχ. Πομπούς, δέκτες κλπ) για την επιτυχή ανίχνευση από τα συστήματα.

4.1.1 Περιγραφή

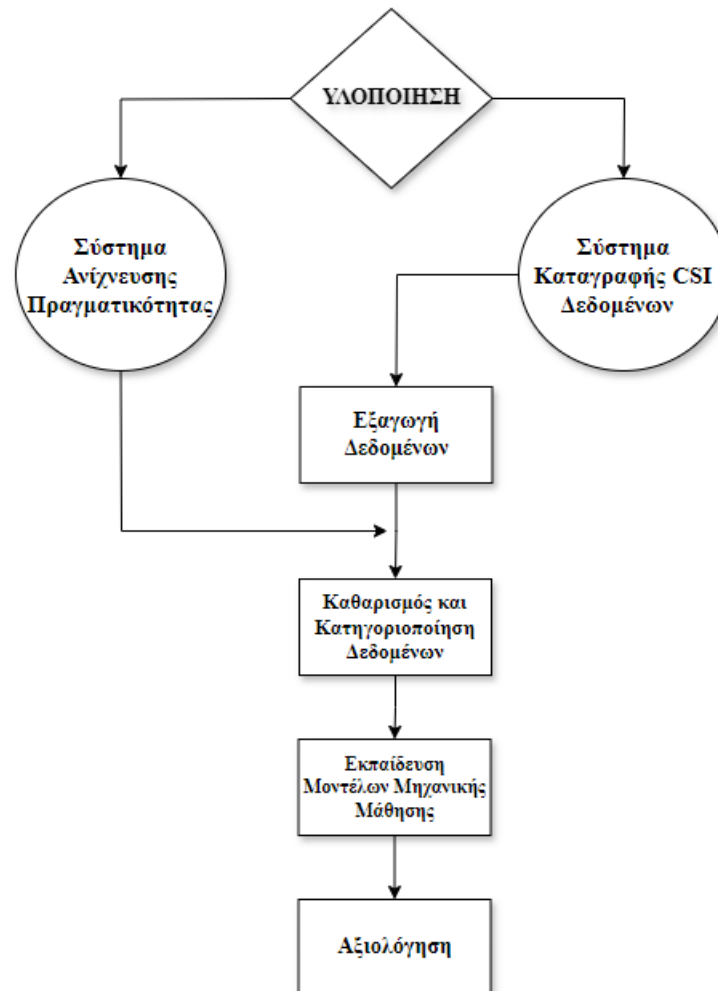
Το σύστημα ασύρματης ανίχνευσης ατόμων σε εσωτερικό χώρο με χρήση μηχανικής μάθησης, που υλοποιήθηκε, αποτελείται από δύο υποσυστήματα. Το πρώτο αφορά την επικοινωνία ενός πομπού με έναν δέκτη για την εξαγωγή των CSI δεδομένων και το δεύτερο αποτελεί ένα σύστημα, το οποίο, παράλληλα με το προηγούμενο, καταγράφει τον πραγματικό αριθμό των ατόμων που βρίσκονται στον χώρο μελέτης. Ο λόγος ύπαρξης του δεύτερου συστήματος είναι για να μπορούν με κάποιον τρόπο να συσχετιστούν οι πληροφορίες των CSI δεδομένων με την πραγματική κατάσταση του χώρου.

Τα δεδομένα που εξάγονται από τα δύο συστήματα συγκρίνονται μεταξύ τους μέσω timestamp και έπειτα τιτλοφορούνται. Στη συνέχεια, πραγματοποιείται καθαρισμός του σετ δεδομένων που έχουν συλλεχθεί, ώστε να εξασφαλιστεί όσο το δυνατόν καλύτερη ποιοτικά πληροφορία δεδομένων για την εν συνεχεία τροφοδότηση των μοντέλων μηχανικής μάθησης.

Μετά την προεπεξεργασία των δεδομένων, το σετ δεδομένων δοκιμάζεται ως είσοδος σε τέσσερις αλγόριθμους μηχανικής μάθησης και από τα αποτελέσματα του καθενός, πραγματοποιείται αξιολόγηση και επιλογή του μοντέλου μηχανικής μάθησης που αποδίδει καλύτερα την ανίχνευση αριθμού ατόμων σε εσωτερικό χώρο.

4.1.2 Σχέδιο-Αρχιτεκτονική Υλοποίησης

Η διαδικασία που αναφέρεται στην *Ενότητα 4.1.1* μπορεί να αποδοθεί σχηματικά, αποσκοπώντας στην καλύτερη κατανόηση των διαδικασιών, με το διάγραμμα που φαίνεται στο *Σχήμα 4.1*.



Σχήμα 4.1 Διάγραμμα Διαδικασιών Υλοποίησης Συστήματος

4.2 Πειραματική Διαδικασία

Για τη διεκπεραίωση της υλοποίησης των συστημάτων, ακολουθήθηκε μία σειρά ενεργειών και διαδικασιών. Αρχικά, προμηθεύτηκε ο εξοπλισμός για την κατασκευή και εγκατάσταση των δύο υποσυστημάτων. Έπειτα διεκπεραιώθηκε ο προγραμματισμός και η ευρωστία των συστημάτων και πραγματοποιήθηκε κατασκευή και εγκατάσταση των συστημάτων στον χώρο μελέτης.

Τέλος, καταγράφηκε ο επιθυμητός αριθμός δεδομένων, θεσπίστηκε το τελικό σετ δεδομένων, εκπαιδεύτηκαν τέσσερα μοντέλα μηχανικής μάθησης και επιλέχθηκε το καλύτερο βάσει των αποτελεσμάτων.

4.2.1 Εισαγωγή στη Διεξαγωγή Πειραμάτων

Η πειραματική διαδικασία έλαβε χώρα σε εσωτερικό χώρο του πανεπιστημίου και συγκεκριμένα σε αίθουσα που διεξάγεται έρευνα από συγκεκριμένο αριθμό ατόμων. Ο μέγιστος αριθμός ατόμων που καταγράφηκε στον χώρο μελέτης ήταν πέντε άτομα.

Κατά την εξαγωγή των δεδομένων, θεωρήθηκε καλή πρακτική η δημιουργία και αποθήκευση, σε διάφορους χώρους αποθήκευσης (πχ. OneDrive, Flash USB Memory, κλπ), αρχείου καταγραφών των δεδομένων που συλλέχθηκαν ανά μέρα, ώστε σε περίπτωση εμφάνισης προβλήματος ή απώλειας δεδομένων να υπάρχει η δυνατότητα ανάκτησης αυτών.

Τα δύο υλοποιηθέντα συστήματα εξάγουν αρχεία σε μορφή JSON, ώστε σε επόμενο χρόνο να μπορούν να συγκριθούν.

4.3 Λογισμικά Προγράμματα

Κατά την εκπόνηση του πειραματικού μέρους της διπλωματικής εργασίας έγινε χρήση των προγραμμάτων Arduino IDE, Putty, Matlab και Visual Studio Code. Συγκεκριμένα, τα Arduino IDE και Putty χρησιμοποιήθηκαν για το σύστημα ανίχνευσης πραγματικού αριθμού ατόμων στον χώρο μελέτης, το Matlab για το σύστημα καταγραφής των CSI δεδομένων και το Visual Studio Code για την εκπαίδευση τεσσάρων μοντέλων μηχανικής μάθησης.

Τέλος, χρησιμοποιήθηκαν οι διαδικτυακές πλατφόρμες EasyEDA και draw.io για την σχηματική αναπαράσταση συστημάτων, αλγορίθμων κα.

4.3.1 Arduino IDE

Το Arduino IDE είναι ένα περιβάλλον ανάπτυξης λογισμικού για πλακέτες Arduino, όπου ο χρήστης μπορεί να προγραμματίσει τους μικροελεγκτές των πλακετών Arduino κυρίως σε γλώσσες προγραμματισμού c και c++ για την υλοποίηση διαφόρων λειτουργιών. Σε αυτήν την εργασία χρησιμοποιήθηκε για τον προγραμματισμό της πλακέτας Arduino UNO, και συγκεκριμένα για τον προγραμματισμό των λειτουργιών του συστήματος ανίχνευσης πραγματικού αριθμού ατόμων που βρίσκονται στον υπό μελέτη χώρο.

Για την επιτυχή υλοποίηση των λειτουργιών του συστήματος, ήταν απαραίτητο να εγκατασταθούν κάποιες επιπλέον βιβλιοθήκες, των οποίων η χρησιμότητα αναλύεται περαιτέρω στην *Ενότητα 4.4*.

4.3.2 Matlab

Το Matlab είναι και αυτό ένα περιβάλλον ανάπτυξης κώδικα, στο οποίο χρησιμοποιείται η γλώσσα προγραμματισμού Matlab για πληθώρα σκοπών. Η γλώσσα Matlab είναι ανώτερου επιπέδου γλώσσα και χρησιμοποιείται κυρίως για την ανάπτυξη αλγορίθμων σε διάφορα επιστημονικά πεδία. Το Matlab μπορεί να υποστηρίξει επεκτάσεις για την ανάπτυξη χρήσιμων εργαλείων που αποσκοπούν σε έρευνα, λειτουργία, δημιουργία και ανάλυση συστημάτων και αλγορίθμων.

Στην συγκεκριμένη διπλωματική εργασία, χρησιμοποιείται η έκδοση Matlab 2023a και ήταν αναγκαία η εγκατάσταση επιπλέον πακέτων ώστε να μπορεί να επικοινωνεί ο εξοπλισμός με τις λειτουργίες που υλοποιήθηκαν. Πιο συγκεκριμένα, εγκαταστάθηκε το πακέτο ADALM-PLUTO Radio Support from Communications Toolbox για την επιτυχή λειτουργικότητα του συστήματος καταγραφής CSI δεδομένων.

Επιπλέον, χρησιμοποιήθηκε ένα GUI, το οποίο δημιουργήθηκε μέσω Matlab, για την επικοινωνία πομπού με δέκτη και την καταγραφή των δεδομένων, του οποίου οι λειτουργίες αναλύονται περαιτέρω στην *Ενότητα 4.5*.

4.3.3 Putty

Το Putty, αποτελεί το λογισμικό που χρησιμοποιείται κυρίως για απομακρυσμένη επικοινωνία μεταξύ υπολογιστών, αξιοποιώντας πρωτόκολλα όπως SSH, Telnet, rlogin και SCP. Σε αυτήν τη διπλωματική εργασία αξιοποιείται στο σύστημα ανίχνευσης πραγματικού αριθμού ατόμων και

συγκεκριμένα για την δημιουργία sessions στα οποία θεσπίζεται η επικοινωνία με την πόρτα που επικοινωνεί το Arduino UNO, ώστε να καταγραφούν οι ενδείξεις των ανιχνεύσεων του συστήματος και να αποθηκευτούν σε μορφή JSON.

4.3.4 Visual Studio Code

Το Visual Studio Code είναι ένα περιβάλλον προγραμματισμού στο οποίο μπορεί κανείς να προγραμματίσει σε πολλές γλώσσες προγραμματισμού. Στην συγκεκριμένη διπλωματική εργασία χρησιμοποιείται για το κομμάτι της επεξεργασίας των δεδομένων και για την εκπαίδευσης μοντέλων μηχανικής μάθησης, σε γλώσσα Python.

Για την επιτυχή εκτέλεση των κελιών κώδικα που δημιουργήθηκαν σε Jupiter Notebook, ήταν αναγκαία η εγκατάσταση της έκδοσης Python 3.11.4, όπως επίσης και των παρακάτω βιβλιοθηκών για την εκτέλεση κώδικα των επιλεγθέντων αλγορίθμων μηχανικής μάθησης.

Οι βιβλιοθήκες που εγκαταστάθηκαν και χρησιμοποιήθηκαν ήταν οι εξής:

- xgboost
- json
- numpy
- pandas
- lightgbm
- tensorflow
- sklearn
- matplotlib.pyplot

Επιπλέον, με τη χρήση του Visual Studio Code δημιουργήθηκαν τα τέσσερα παρακάτω αρχεία, σε Python, για την ενοποίηση, την διόρθωση τιμών και τιτλοφόρηση των CSI δεδομένων, όπως επίσης και την διόρθωση μορφής του json αρχείου που δημιουργείται μέσω Putty, αντίστοιχα:

- MERGING_JSON_FILES.py
- IDX and POW Correction.py
- LABELING.py
- JSON_FORMAT_CORRECTION.py

Στις παρακάτω ενότητες γίνεται ανάλυση των συστημάτων που υλοποιήθηκαν, όπως επίσης και εμφάνιση στις τεχνικές που αναπτύχθηκαν για την εξαγωγή και επεξεργασία των δεδομένων.

4.4 Αισθητήριο Σύστημα Ανίχνευσης Πραγματικού Αριθμού Ατόμων

Η θέσπιση του αισθητήριου συστήματος ανίχνευσης πραγματικού αριθμού ατόμων αποτελείται από τρία μέρη, την κατασκευή των υλικών στοιχείων που το αποτελούν, τον προγραμματισμό λειτουργίας του συστήματος και την επιτυχή εγκατάστασή του στο χώρο.

Η λογική πίσω από την ανάγκη ύπαρξης ενός τέτοιου συστήματος, βασίζεται στην λογική λειτουργίας των μοντέλων επιβλεπόμενης μηχανικής μάθησης. Συγκεκριμένα, και εφόσον χρησιμοποιείται επιβλεπόμενη μάθηση για κατηγοριοποίηση δεδομένων, είναι απαραίτητο τα δεδομένα που θα εξαχθούν να τιτλοφορηθούν πριν την εκπαίδευση. Για αυτόν το σκοπό, δημιουργήθηκε το συγκεκριμένο σύστημα, το οποίο μέσω της σύγκρισης του διακοπόμενου σήματος δύο Πυροηλεκτρικών Υπέρυθρων αισθητήρων, στοιχισμένων σε σειρά και τοποθετημένων στο κατώφλι του εσωτερικού χώρου, εξάγει την πληροφορία του αν κάποιος

εισήλθε ή εξήλθε από τον χώρο, ώστε σε δεύτερο χρόνο να αξιοποιηθεί αυτή η πληροφορία για την τιτλοφόρηση των δεδομένων.

Στις παρακάτω υπο-ενότητες αναλύεται η λειτουργία του και τα χαρακτηριστικά του με περισσότερες λεπτομέρειες.

4.4.1 Εξοπλισμός

Για την υλοποίηση του συστήματος χρησιμοποιήθηκε η ακόλουθη υλικοτεχνική υποδομή:

- **PIR αισθητήρες**

Χρησιμοποιήθηκαν δύο Πυροηλεκτρικοί Υπέρυθροι (PIR) αισθητήρες κίνησης, οι οποίοι διαθέτουν τρεις ακροδέκτες ο καθένας, όπως φαίνεται στην *Εικόνα 4.1*.



Εικόνα 4.1 Πυροηλεκτρικός Υπέρυθρος Αισθητήρας Κίνησης [35]

Από τους τρεις ακροδέκτες που φαίνονται, ο αριστερός αποτελεί τον ακροδέκτη της τροφοδοσίας, ο μεσαίος τον ακροδέκτη από που εξάγεται ψηφιακό σήμα, δηλαδή παλμός όταν κάποιος βρίσκεται στην εμβέλεια ανίχνευσής του, και στον δεξιά ακροδέκτη συνδέεται η γείωση του.

- **Arduino UNO R3**

Ο Arduino UNO είναι μια πλακέτα η οποία με την βοήθεια του μικροελεγκτή ATMEGA328P μπορεί να υλοποιεί μεγάλο φάσμα εφαρμογών όσον αφορά επιθυμητούς ελέγχους και λειτουργίες.




Εικόνα 4.2 Arduino UNO R3 [36]

Στον συγκεκριμένο μικροελεγκτή πραγματοποιούνται όλες οι απαραίτητες λειτουργίες για την αποτελεσματική πραγμάτωση των στόχων του συστήματος.

- **Generic UNO Proto Shield Prototype Expansion**

Το συγκεκριμένο shield διαθέτει τα pinouts της πλακέτας Arduino UNO και επίσης έχει δέκα επιπλέον pinouts εκ των οποίων τα πέντε αφορούν τη γείωση και τα άλλα πέντε την τροφοδοσία. Επίσης, πάνω σε αυτό, μπορούν να κολληθούν οποιαδήποτε ειδικού σκοπού κυκλώματα, λόγω των οπών που υπάρχουν.




Εικόνα 4.3 Generic UNO Proto Shield Prototype Expansion [37]

Το συγκεκριμένο shield χρησιμοποιείται, καθώς παρέχει τις προαναφερθείσες επεκτάσεις, οι οποίες χρειάστηκαν για την διασύνδεση όλων των στοιχείων που αποτελούν το σύστημα.


- **Push Buttons Switches (κόκκινο και πράσινο)**
- **Για το RTC (Real Time Clock):**
 - Κενή πλακέτα THT (Throw Hole Technology)
 - DS1307
 - Μπαταρία λιθίου 3V
 - Αντιστάτες
- **Λοιπά Υλικά**
 - Καλώδια
 - Ξύλα Κόντρα Πλακέ
 - Θερμόκολλα
 - Καλάι

4.4.2 Κατασκευή, Προγραμματισμός και Εγκατάσταση Συστήματος

Όπως αναφέρθηκε και σε προηγούμενη ενότητα η υλοποίηση του συστήματος διαιρείται σε τρία στάδια υλοποίησης. Στο πρώτο στάδιο, κατασκευάστηκαν οι ξύλινες κατασκευές που φιλοξενούν τα ηλεκτρονικά στοιχεία και τις πλακέτες και δημιουργήθηκε η πλακέτα με το κύκλωμα του RTC. Αρχικά, κατασκευάστηκε ένα ορθογώνιο παραλληλεπίπεδο κουτί, στο οποίο στην πάνω έδρα τοποθετήθηκαν τα δύο κουμπιά (κόκκινο και πράσινο), στην αριστερή δημιουργήθηκε μία οπή, ώστε να μπορούν να εξέρχονται τα καλώδια και τέλος, δημιουργήθηκε οπή στην εμπρόσθια έδρα, ώστε να υπάρχει υποδοχή για το καλώδιο USB του Arduino UNO.



Εικόνα 4.4 Εξωτερική Εμφάνιση Κουτιού




Εικόνα 4.5 Εσωτερική Τοπολογία Κουτιού

Στη συνέχεια, κατασκευάστηκαν οι δύο τριγωνικές ξύλινες κατασκευές, στις οποίες τοποθετήθηκαν οι PIR αισθητήρες, όπως φαίνεται στην παρακάτω εικόνα.

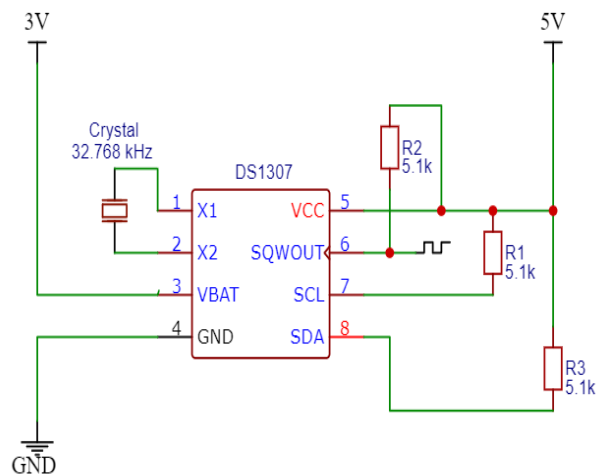


Εικόνα 4.6 Τριγωνικές Ξύλινες Κατασκευές

Τέλος, υλοποιήθηκε το κύκλωμα της πλακέτας και κολλήθηκαν τα στοιχεία στην κενή πλακέτα.



Εικόνα 4.7 Τελειοποιημένη πλακέτα RTC



Εικόνα 4.8 Τοπολογία RTC

Στο δεύτερο στάδιο, πραγματοποιήθηκε ο προγραμματισμός στο περιβάλλον ανάπτυξης κώδικα Arduino IDE. Συγκεκριμένα, δημιουργήθηκαν δύο αρχεία το RTC_Check.ino και το Ground_Truth_Sensor_Sketch.ino. Το πρώτο χρησιμοποιήθηκε για την αρχικοποίηση της ώρας στο ολοκληρωμένο DS1307 και την μορφοποίηση αυτής, ώστε να αποστέλλεται στην επιθυμητή μορφή στον μικροελεγκτή του Arduino UNO (δηλαδή σε timestamp).

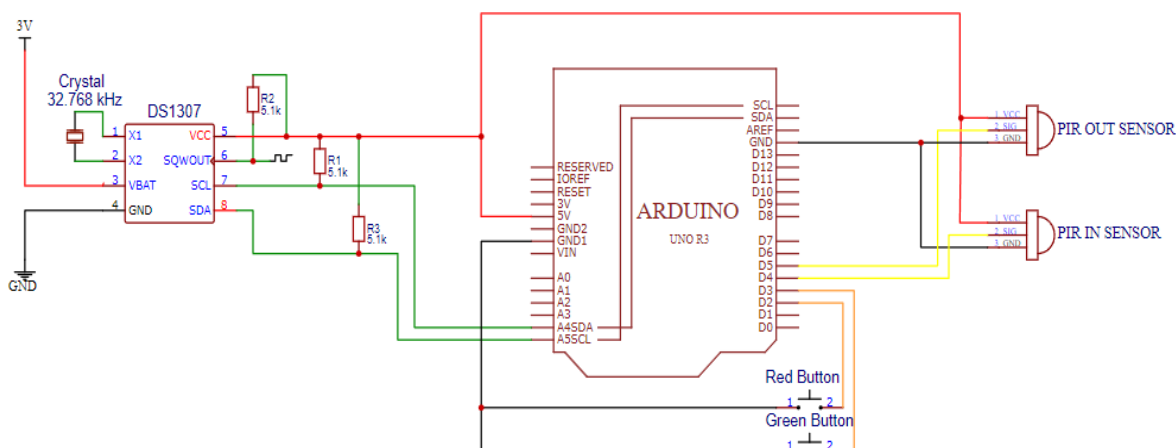
Το δεύτερο αρχείο αποτελεί τον κώδικα που υλοποιεί τις συγκριτικές διαδικασίες για τον σκοπό της καταγραφής του ακριβούς αριθμού ατόμων και οι λειτουργίες που επιτελούνται αναλύονται σε επόμενη ενότητα.

Στο τελευταίο στάδιο της υλοποίησης εγκαταστάθηκαν τα δύο συστήματα στον εσωτερικό χώρο καταγραφής δεδομένων, όπως φαίνεται στο Σχήμα 4.2.

4.4.3 Αρχιτεκτονική Συστήματος

Η αρχιτεκτονική διάταξη του συστήματος ανίχνευσης πραγματικού αριθμού ατόμων αναπαρίσταται σχηματικά στο Σχήμα 4.2.

ΣΥΣΤΗΜΑ ΑΝΙΧΝΕΥΣΗΣ ΠΡΑΓΜΑΤΙΚΟΥ ΑΡΙΘΜΟΥ ΑΤΟΜΩΝ



Σχήμα 4.2 Συνδεσμολογική Διάταξη Συστήματος Ανίχνευσης Πραγματικού Αριθμού Ατόμων

4.4.4 Τρόπος Χρήσης και Λειτουργίας

Η λογική της ανίχνευσης πραγματικού αριθμού ατόμων, υλοποιείται μέσω του διακοπτόμενου σήματος των δύο πυροηλεκτρικών υπέρυθρων αισθητήρων. Συγκεκριμένα, διαβάζονται διαρκώς οι τιμές των PIR αισθητήρων και όταν ανιχνευθούν οι παρακάτω αλληλουχίες διακοπτόμενων σημάτων πραγματοποιούνται οι καταγραφές:

- i. Όταν διαβαστούν οι τιμές:
 $in_sensor = 0$ και $out_sensor = 0$, δεν πραγματοποιείται καμία καταγραφή.
- ii. Όταν διαβαστούν σε ακολουθία οι τιμές:
 1. $in_sensor = 0$ και $out_sensor = 1$,
 2. $in_sensor = 1$ και $out_sensor = 1$Καταγράφεται το timestamp, η κατάσταση: “ Είσοδος ”, και ο νέος αριθμός ατόμων αυξημένος κατά 1.
- iii. Όταν διαβαστούν σε ακολουθία οι τιμές:
 1. $in_sensor = 1$ και $out_sensor = 0$,
 2. $in_sensor = 1$ και $out_sensor = 1$Καταγράφεται το timestamp, η κατάσταση: “ Έξοδος ”, και ο νέος αριθμός ατόμων μειωμένος κατά 1.

Για την εξασφάλιση της αξιοπιστίας του συστήματος, εφαρμόστηκε η λειτουργία των κουμπιών, τα οποία υπάρχουν ώστε να μπορούν να διορθωθούν εσφαλμένες καταγραφές των αισθητήρων ή εσφαλμένες μη καταγεγραμμένες καταστάσεις. Συγκεκριμένα, όταν το πράσινο κουμπί πατιέται καταγράφεται αύξηση του αριθμού ατόμων και χρησιμοποιείται για να διορθωθεί ο αριθμός ατόμων, στις περιπτώσεις :

1. Όταν οι αισθητήρες καταγράφουν ότι κάποιος εσφαλμένα εξήλθε του χώρου,
2. Όταν οι αισθητήρες δεν καταγράφουν ότι κάποιος εισήλθε του χώρου.

Ακολούθως, όταν το κόκκινο κουμπί πατιέται καταγράφεται μείωση του αριθμού ατόμων κατά ένα και χρησιμοποιείται για να διορθωθεί ο αριθμός ατόμων, στις περιπτώσεις :

1. Όταν οι αισθητήρες καταγράφουν ότι κάποιος εσφαλμένα εισήλθε του χώρου,
2. Όταν οι αισθητήρες δεν καταγράφουν ότι κάποιος εξήλθε του χώρο.

Οι καταγραφές πραγματοποιούνται σε αρχεία μορφής JSON.

Όπως προαναφέρθηκε, οι παραπάνω λειτουργίες, του συστήματος, υλοποιούνται στο αρχείο `Ground_Truth_Sensor_Sketch.ino` και στο *Παράρτημα Α* δεικνύονται τα τμήματα κώδικα τους.

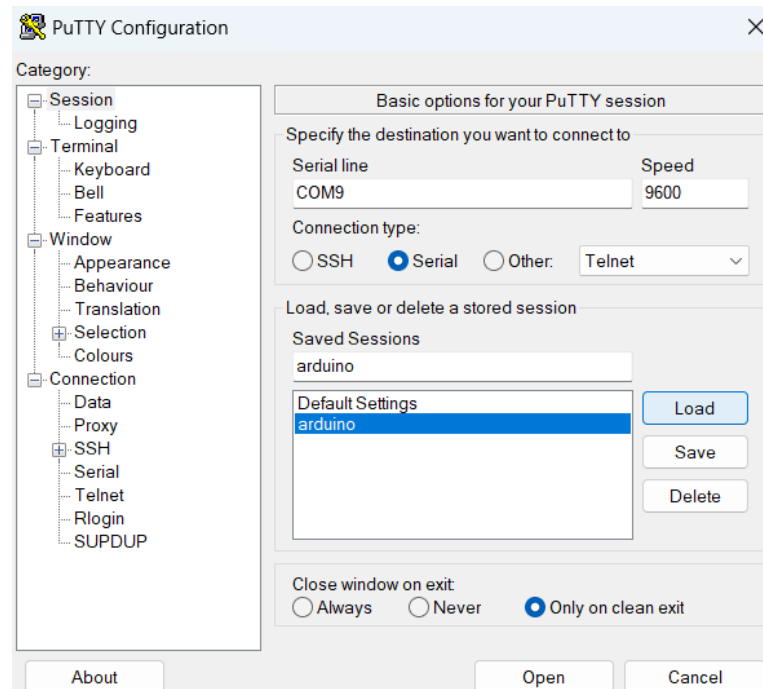
Να σημειωθεί ότι για την επιτυχή εξαγωγή του timestamp, έπρεπε να αρχικοποιηθεί η ώρα στο ολοκληρωμένο DS1307, μέσω του αρχείου `RTC_Check.ino` με τον τρόπο που δεικνύεται στο *Παράρτημα Α*.

4.4.5 Εξαγωγή Δεδομένων

Η εξαγωγή των δεδομένων του συστήματος ανίχνευσης πραγματικού αριθμού ατόμων πραγματοποιήθηκε, όπως προαναφέρθηκε, με τη χρήση του λογισμικού προγράμματος Putty. Συγκεκριμένα, στην κατηγορία *Session* αποθηκεύτηκε ένα Session με όνομα *arduino* και χαρακτηριστικά:

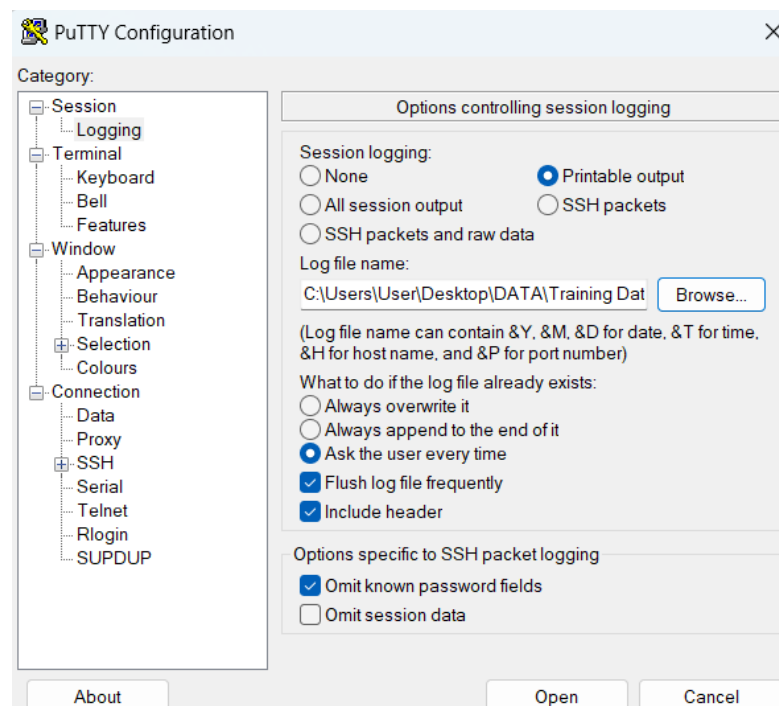
- Πόρτα επικοινωνίας: COM9
- Σειριακή Επικοινωνία

- Baud Rate: 9600 (ρυθμός μετάδοσης δεδομένων που απαιτείται για την επικοινωνία με τον μικροελεγκτή ATMEGA328P)



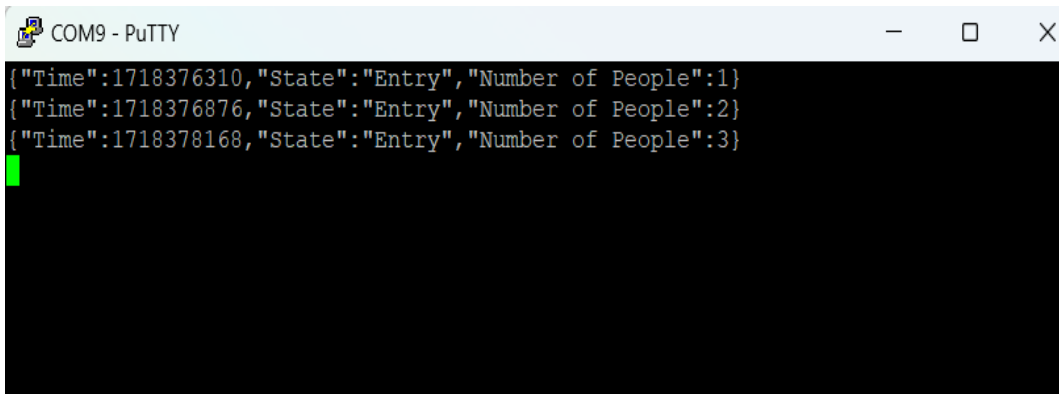
Εικόνα 4.9 Χαρακτηριστικά Επικοινωνίας για Καταγραφή Δεδομένων

Σε επόμενο στάδιο, στην υπο-κατηγορία “Logging” επιλέχθηκε η επιλογή “Printable output” και καθορίστηκε το path που αποθηκεύεται το αρχείο και το όνομα αυτού με την κατάληξη “.json”.



Εικόνα 4.10 Καταγραφή Δεδομένων και Δημιουργία JSON Αρχείου

Τέλος, ανοίγει η οθόνη του τερματικού στην οποία φαίνονται οι καταγραφές την στιγμή που συμβαίνουν και όταν κλείσει το *Session* (δηλαδή η οθόνη του τερματικού), ό,τι καταγράφηκε στην οθόνη αποθηκεύεται στο αρχείο JSON που καθορίστηκε.



```
COM9 - PuTTY
{"Time":1718376310,"State":"Entry","Number of People":1}
{"Time":1718376876,"State":"Entry","Number of People":2}
{"Time":1718378168,"State":"Entry","Number of People":3}
```

Εικόνα 4.11 Εμφάνιση Καταγραφών Συστήματος

Τα πεδία που αποθηκεύονται ανά γραμμή καταγραφής είναι:

1. Time: το χρονικό στιγμιότυπο που έγινε μία καταγραφή.
2. State: Η κατάσταση που καταγράφηκε “Entry” αν ανιχνεύθηκε είσοδος από το διακοπτόμενο σήμα των αισθητήρων, ή “Exit” αν ανιχνεύθηκε έξοδος.
3. Number of People: ο αριθμός των ατόμων, ο οποίος αυξάνεται ή μειώνεται αναλόγως την καταγραφή.


4.5 Σύστημα καταγραφής CSI Δεδομένων

Το σύστημα καταγραφής CSI δεδομένων αποτελεί τον πυλώνα της θέσπισης του σετ δεδομένων, καθώς βάσει αυτού εξάγονται οι πληροφορίες των RF σημάτων που αργότερα αξιοποιούνται για την εκπαίδευση των αλγορίθμων μηχανικής μάθησης.


4.5.1 Εξοπλισμός

Ο εξοπλισμός που χρειάστηκε για την υλοποίηση του συγκεκριμένου συστήματος ήταν:

- BK7235 ο οποίος έχει τη λειτουργία του πομπού.




Εικόνα 4.12 (α) BK7235



Εικόνα 4.12 (β) BK7235

- ADALM PLUTO SDR το οποίο χρησιμοποιείται για την λειτουργία του δέκτη.



Εικόνα 4.13 ADALM PLUTO SDR

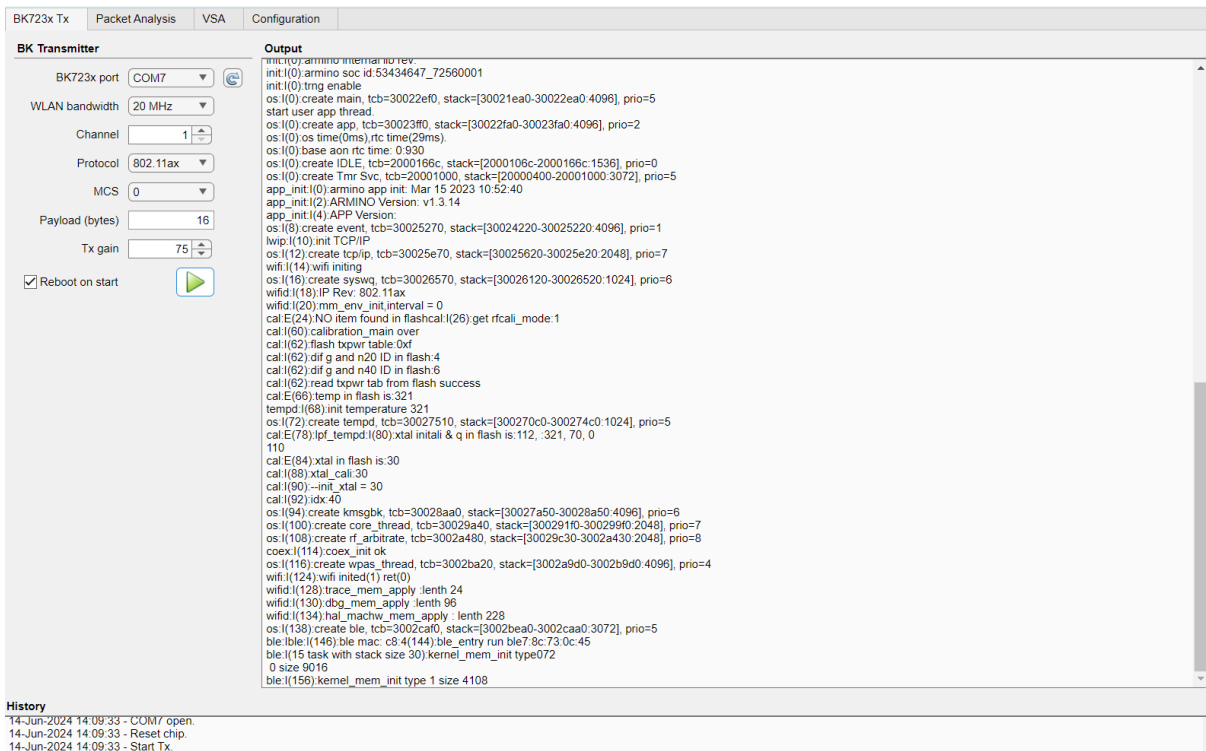
- 3 x USB Extender 5m

4.5.2 Τρόπος Λειτουργίας και Εξαγωγή Δεδομένων

Για τη λειτουργικότητα του συστήματος καταγραφής CSI δεδομένων δημιουργήθηκε ένα GUI το οποίο προγραμματίστηκε σε γλώσσα MATLAB. Στη συγκεκριμένη διπλωματική εργασία χρησιμοποιείται η εφευρεθείσα μορφή το GUI και σε αυτήν την ενότητα αναλύονται οι λειτουργίες του και ο τρόπος με τον οποίο καταγράφονται τα δεδομένα μέσω αυτού.

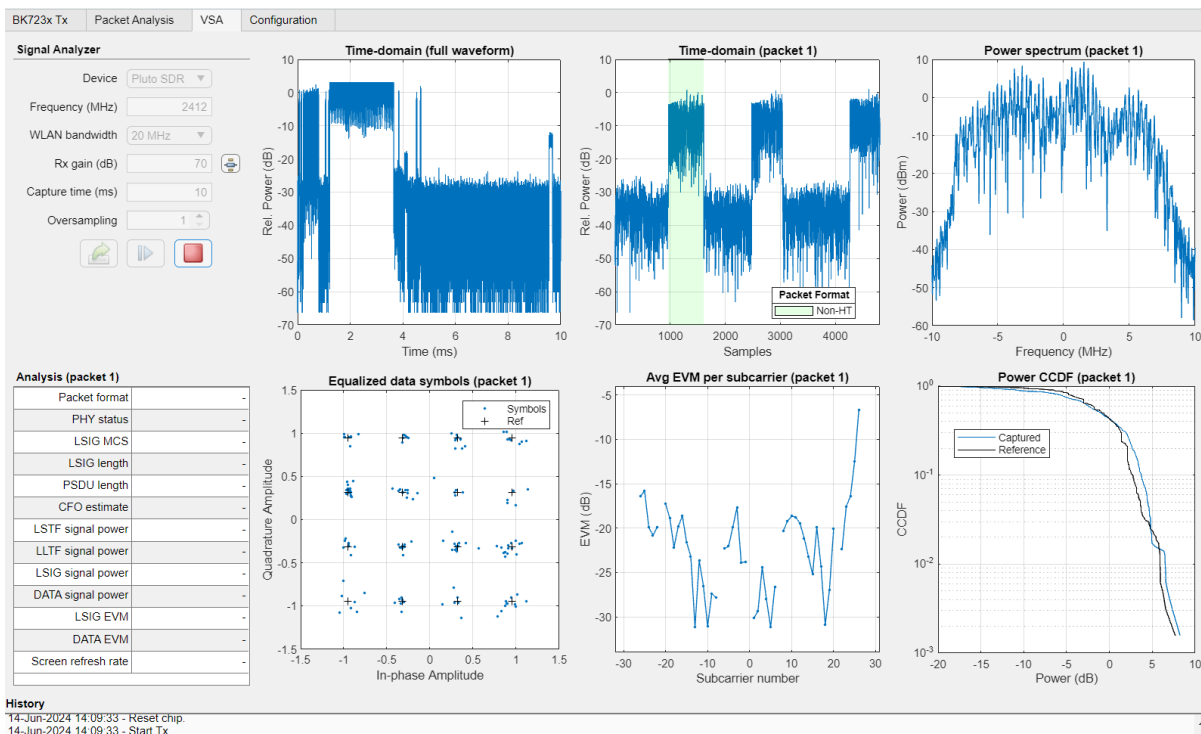
Αρχικά, για την έναρξη καταγραφής δεδομένων, συνδέθηκε ο πομπός και ο δέκτης με προσωπικό υπολογιστή. Αυτό σημαίνει ότι η επικοινωνία τους με το GUI διεκπεραιώνεται μέσω UART πρωτοκόλλου.

Σαν πρώτο στάδιο λοιπόν πρέπει να εξασφαλιστεί η επικοινωνία του πομπού με το GUI και στη συνέχεια να επιβεβαιωθεί η επικοινωνία του με τον δέκτη. Στην *Εικόνα 4.14* διαφαίνεται ο τρόπος εξασφάλισης επικοινωνίας πομπού-δέκτη και πομπού – GUI.



Εικόνα 4.14 Ρύθμιση Παραμέτρων Πομπού και Έλεγχος Επικοινωνίας

Όπως φαίνεται στην παραπάνω εικόνα για την επιτυχή επικοινωνία του πομπού με τον δέκτη πρέπει να καθοριστούν τα χαρακτηριστικά επικοινωνίας τους. Συγκεκριμένα, πρέπει να καθοριστεί η πόρτα που επικοινωνεί σειριακά ο πομπός, η συχνότητα επικοινωνίας, το κανάλι, το πρωτόκολλο (που στην συγκεκριμένη εργασία είναι το 802.11ax), η πληροφορία ανά πακέτο που στέλνεται σε bytes και η ισχύς του σήματος σε db.



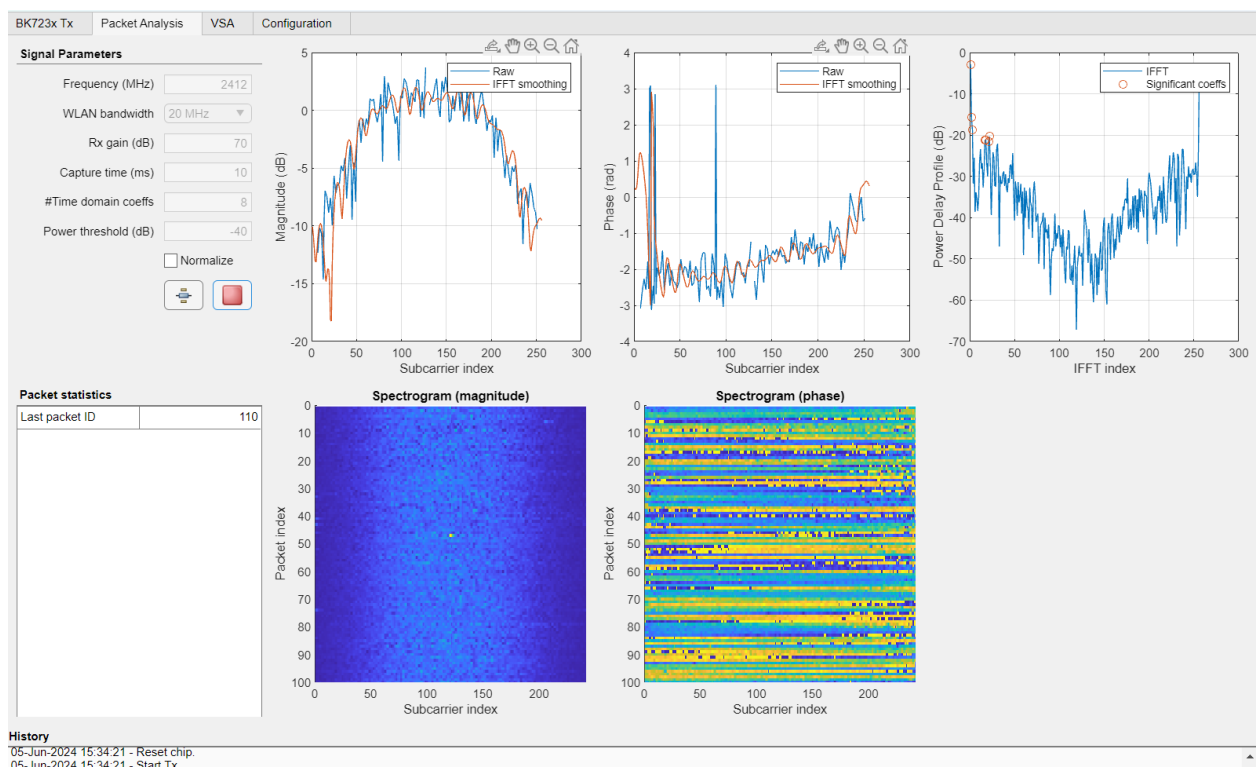
Εικόνα 4.15 Ρύθμιση Παραμέτρων Δέκτη και Έλεγχος Επικοινωνίας

Εφόσον εξασφαλιστεί η επικοινωνία με τον πομπό, στην καρτέλα VSA του GUI, ρυθμίζονται οι παράμετροι επικοινωνίας του δέκτη αντίστοιχα. Σε αυτήν την εργασία, ο δέκτης επικοινωνεί στα 70 db, και καταγράφει δεδομένα με time window: 10 ms, όπως φαίνεται στην *Εικόνα 4.15*.

Στην *Εικόνα 4.15* δεικνύονται έξι γραφήματα εκ των οποίων:

- Το πρώτο δείχνει την κυματομορφή που δέχεται ο δέκτης στο time window των 10 ms, συναρτήσει της ισχύος.
- Το δεύτερο δείχνει την μορφοποίηση των πακέτων, καθώς επίσης και την ισχύ ανά δείγμα του πακέτου που απεστάλη.
- Το τρίτο, την ισχύ του σήματος του πακέτου συναρτήσει της συχνότητας.
- Το τέταρτο, την διαμόρφωση QAM που πραγματοποιήθηκε (στην συγκεκριμένη εικόνα 16-QAM) καθώς και τα σύμβολα ανά φάση και πλάτος.
- Το πέμπτο γράφημα παρουσιάζει το μέσο διανυσματικό σφάλμα μέτρου σε db ανά υπο-φέρων σήμα.
- Τέλος, στο έκτο γράφημα παρουσιάζεται η πληροφορία πιθανοκατανομής της ισχύος του σήματος.

Αφού παραμετροποιηθούν τα χαρακτηριστικά επικοινωνίας του πομπού και του δέκτη και εξασφαλιστεί η επικοινωνία μεταξύ τους πραγματοποιείται η καταγραφή των δεδομένων. Στην *Εικόνα 4.16* προβάλλεται η αναπαράσταση κάποιων πληροφοριών που καταγράφονται κατά την καταγραφή.



Εικόνα 4.16 Περιβάλλον Καταγραφής και Παρουσίασης Καλύτερων Πακέτων

Συγκεκριμένα, παρατηρούνται τρία γραφήματα εκ των οποίων:

- Το πρώτο παρουσιάζει την κυματομορφή του μέτρου συναρτήσει των 256 OFDM συμβόλων.
- Το δεύτερο, την αντίστοιχη κυματομορφή της φάσης συναρτήσει των 256 OFDM συμβόλων.

- Το τρίτο δεικνύει το σήμα που δέχτηκε ο δέκτης και τις καθυστερήσεις αυτού που προκύπτουν από τις ανακλάσεις που πραγματοποιούνται στα άτομα και στον χώρο.

Και δυο σπεκτρογράμματα εκ των οποίων:

- Το πρώτο αναπαριστά το σπεκτρόγραμμα του μέτρου στο οποίο κάθε γραμμή αναπαριστά την κυματομορφή του μέτρου του RF σήματος συναρτήσεως των OFDM συμβόλων του.

- Και το δεύτερο παρουσιάζει το αντίστοιχο σπεκτρόγραμμα της φάσης.

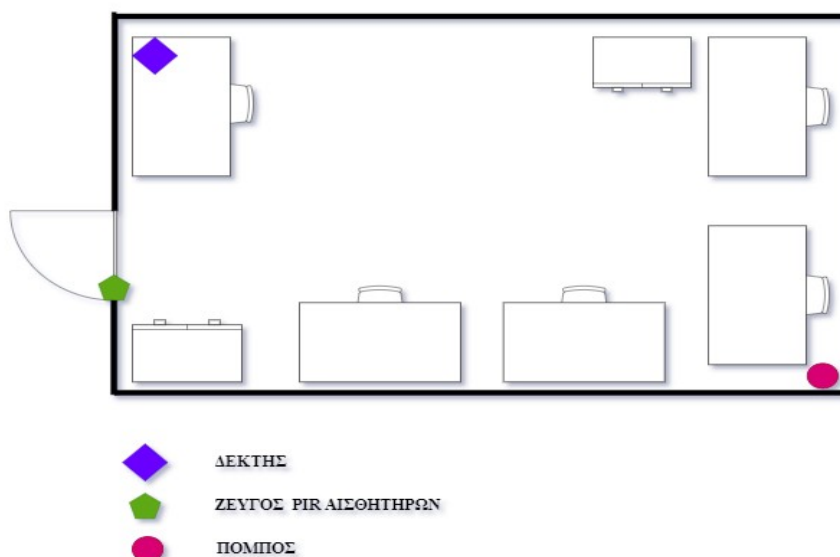
Όταν πατηθεί το κουμπί play ξεκινούν οι καταγραφές των δεδομένων. Οι πληροφορίες που εξάγονται ανά γραμμή δεδομένων είναι οι παρακάτω:

- datetime: το χρονικό στιγμιότυπο με ακρίβεια τεσσάρων δεκαδικών ψηφίων
- cfo (carrier frequency offset)
- snr (signal to noise ratio): η ισχύς του ωφέλιμου σήματος συναρτήσεως του θορύβου σε db
- pow: η ισχύς του σήματος σε db
- idx: ο αριθμός γραμμής δεδομένου
- real: 256 OFDM σύμβολα του πραγματικού μέρους του RF σήματος
- imag: 256 OFDM σύμβολα του φανταστικού μέρους του RF σήματος
- best_coeffs_idx: τους οκτώ καλύτερους αριθμούς OFDM συμβόλων πραγματικού και φανταστικού μέρους.

Κατά την καταγραφή των δεδομένων, ο δέκτης, φιλτράρει τα καλύτερα πακέτα επικοινωνίας που έλαβε από τον πομπό. Κάθε πακέτο που επιλέγεται ως καλύτερο αποτελεί μία γραμμή δεδομένων και αποθηκεύεται σε ένα json αρχείο στο φάκελο του GUI με όνομα csi_data.json.


4.6 Κατόψεις Χώρων Διεξαγωγής

Ο χώρος στον οποίο διεξήχθη η καταγραφή δεδομένων εκπαίδευσης, έχει εμβαδόν 33 τ.μ. και αποδίδεται σχηματικά στο Σχήμα 4.3. Στη συγκεκριμένη χωρική διάταξη θεωρήθηκε ορθό ο πομπός και ο δέκτης να τοποθετηθούν σε σχετικά υψηλή θέση και σε διαγώνια στοίχιση στον χώρο, ώστε ο δέκτης να μπορεί να δέχεται όσο δυνατόν καλύτερα το κύριο σήμα πληροφορίας (Line-of-Sight) και τις ανακλάσεις αυτού.



Σχήμα 4.3 Κάτοψη Χώρου Διεξαγωγής Καταγραφής Δεδομένων Εκπαίδευσης

Έπειτα, για το κομμάτι της αξιολόγησης καταγράφηκαν δεδομένα αξιολόγησης (inference data) από δύο χώρους. Ο πρώτος χώρος είναι μία εργαστηριακή αίθουσα 67τμ και αποδίδεται σχηματικά στο Σχήμα 4.4. Στην συγκεκριμένη διάταξη εφαρμόστηκε το σύστημα αισθητήρων στο κατώφλι της πόρτας της αίθουσας και το σύστημα πομπού δέκτη σε διαγώνια διάταξη εξασφαλίζοντας LoS.



Σχήμα 4.4 Κάτοψη Χώρου Α Διεξαγωγής Καταγραφής Δεδομένων Αξιολόγησης

Ο δεύτερος χώρος είναι χώρος γραφείου 33τμ, όμοιος του χώρου εξαγωγής δεδομένων εκπαίδευσης, με διαφορά στην τοπολογία του συστήματος πομπού – δέκτη και στην χωροταξία των επίπλων που εμπεριέχονται σε αυτόν.

4.7 Καταγραφή, Επεξεργασία και Τιτλοφόρηση Δεδομένων

Στην εκπονηθείσα διπλωματική εργασία συλλέχθηκαν 80.127 δεδομένα, τα οποία τέθηκαν υπό αρκετή επεξεργασία έως την οριστικοποίηση του τελικού σετ δεδομένων. Παρακάτω παρατίθενται η διαδικασία συλλογής των δεδομένων, η ενοποίηση και η επεξεργασία των αρχείων των δεδομένων, η τιτλοφόρηση αυτών και η οριστικοποίηση του τελικού σετ.

4.7.1 Διαδικασία Καταγραφής Δεδομένων

Όπως αναφέρθηκε σε προηγούμενη ενότητα η καταγραφή των CSI δεδομένων εν παραλλήλω με την καταγραφή του πραγματικού αριθμού ατόμων πραγματοποιήθηκαν με τη χρήση του GUI και του Arduino.

Κατά την εκάστοτε καταγραφή δημιουργούνται δύο αρχεία JSON εκ των οποίων το πρώτο αφορούσε τις καταγραφές του συστήματος καταμέτρησης πραγματικού αριθμού ατόμων και το δεύτερο τις καταγραφές των CSI δεδομένων. Στο τέλος της κάθε ημέρας ενοποιούνται τα αρχεία JSON, της κάθε κατηγορίας δεδομένων, και στο τέλος κάθε εβδομάδας ενοποιούνται τα αρχεία κάθε ημέρας.

Για την ενοποίηση των αρχείων δημιουργήθηκε το αρχείο MERGING_JSON_FILES.py, το οποίο επιτελεί το σκοπό αυτό. Συγκεκριμένα του δίνεται η διαδρομή του φακέλου που περιέχονται τα αρχεία, στη συνέχεια συγχωνεύει όλα τα αρχεία με κατάληξη .json και δημιουργεί ένα νέο αρχείο με τα ενοποιημένα δεδομένα, όπως φαίνεται στο *Παράρτημα Α: Κώδικας*.

Αφού ενοποιήθηκαν τα αρχεία κάθε εβδομάδας, για τις δύο κατηγορίες, διαμορφώθηκαν τα δύο σετ δεδομένων:

- Ground_Truth_Data.json και
- CSI_Data.json

4.7.2 Επεξεργασία JSON αρχείων

Κατά την επεξεργασία των αρχείων Ground_Truth_Data.json και CSI_Data.json, δημιουργήθηκαν και αξιοποιήθηκαν δύο αρχεία σε γλώσσα προγραμματισμού Python :

i. IDX and POW Correction.py

Το συγκεκριμένο αρχείο αποσκοπούσε στην διόρθωση των ετικετών “idx” και “row” του αρχείου CSI_Data.json. Οι λειτουργίες που πραγματοποιεί το αρχείο αυτό είναι η απαλοιφή του πεδίου “idx”, επανατοποθέτηση του πεδίου και εκ νέου απαρίθμηση αυτού, και αλλαγή του ονόματος του πεδίου “row” σε “rowr” για την επιτυχή μετέπειτα διαχείρισή του. Ο κώδικας του αρχείου συμπεριλαμβάνεται στο *Παράρτημα Α: Κώδικας*.

ii. JSON_FORMAT_CORRECTION.py

Το αρχείο αυτό χρησιμοποιήθηκε στη διόρθωση της μορφής των json αρχείων που εξάγονταν από το σύστημα καταγραφής πραγματικού αριθμού ατόμων μετατρέποντας τα αρχεία σε μορφή λίστας. Στο *Παράρτημα Α* παρουσιάζεται ο κώδικας που επιτελεί τον παραπάνω σκοπό.


4.7.3 Τιτλοφόρηση Δεδομένων (Labeling)

Για την επιτυχή τιτλοφόρηση των δεδομένων δημιουργήθηκε το αρχείο LABELING.py, το οποίο εκτελεί σύγκριση των χρονικών στιγμιότυπων που περιέχονται στα αρχεία Ground_Truth_Data.json και CSI_Data.json. Εφόσον είναι ίσα ή η τιμή του χρονικού στιγμιότυπου του αρχείου Ground_Truth_Data.json είναι μεγαλύτερη, διαβάζει την τιμή του πεδίου “Number of People”, η οποία βρίσκεται στο αρχείο Ground_Truth_Data.json. Στη συνέχεια, δημιουργεί καινούριο πεδίο στο τέλος της γραμμής δεδομένου του αρχείου CSI_Data.json με όνομα “class” και του αποδίδει την τιμή που έχει καταγραφεί στο πεδίο “Number of People”.

Η παραπάνω διαδικασία πραγματοποιείται για κάθε γραμμή δεδομένου του αρχείου CSI_Data.json μέχρι να τιτλοφορηθούν όλα τα CSI δεδομένα που συλλέχθηκαν. Στο *Παράρτημα Α: Κώδικας* διαφαίνονται οι προαναφερθείσες λειτουργίες με περισσότερες λεπτομέρειες.

4.7.4 Προεπεξεργασία και Οριστικοποίηση Τελικού Σετ Δεδομένων

Το μεγαλύτερο κομμάτι προεπεξεργασίας, για τους τέσσερις αλγόριθμους που χρησιμοποιήθηκαν, έλαβε χώρα στο αρχείο `Machine_Learning_Models.ipynb`. Συγκεκριμένα και αφού προηγήθηκαν οι διαδικασίες των προηγούμενων ενότητων, κατά την επεξεργασία των δεδομένων, φορτώθηκε το ενοποιημένο σετ δεδομένων με κατανομή δεδομένων ανά κλάση, αυτήν που αποτυπώνεται στο παρακάτω ιστόγραμμα.



Εικόνα 4.17 Ιστόγραμμα Κατανομής Συνολικών Δεδομένων

Συγκεκριμένα τα συνολικά δεδομένα που συλλέχθηκαν ανά κλάση είναι:

- Κλάση 0 : 11.730 δεδομένα
- Κλάση 1 : 15.845 δεδομένα
- Κλάση 2 : 16.750 δεδομένα
- Κλάση 3 : 18.774 δεδομένα
- Κλάση 4 : 15.749 δεδομένα
- Κλάση 5 : 1.279 δεδομένα

Η πέμπτη κλάση αφαιρέθηκε και στη συνέχεια εξήχθησαν τα χαρακτηριστικά, που χρησιμοποιήθηκαν για εκπαίδευση, και οι κλάσεις. Τα χαρακτηριστικά που αντιστοιχίστηκαν στο X μέρος ήταν τα `real`, `imaginary`, `snr` και η ισχύς του σήματος και στο y αντιστοιχίστηκαν οι κλάσεις. Τα χαρακτηριστικά δέχονται διάφορες μετατροπές για να διεξαχθούν οι ενέργειες αυτές και για να είναι σε κατάλληλη και λογική μορφή ώστε να μην υπάρξει πρόβλημα κατά την τροφοδότησή τους στα μοντέλα μηχανικής μάθησης.

Τελικώς, το οριστικοποιημένο σετ δεδομένων αποτελείται από 486 χαρακτηριστικά των δεδομένων ως X , εκ των οποίων τα 242 είναι το πραγματικό μέρος του πακέτου σημάτων, τα 242 είναι το φανταστικό και τα υπόλοιπα δύο είναι η ισχύς και το `snr`. Επομένως, το προς εκπαίδευση και αξιολόγηση σετ δεδομένων είναι 78.848 γραμμές με 486 στήλες για το X και 78.848 γραμμές και μία στήλη για το y .

Στην περίπτωση εκπαίδευσης 18 χαρακτηριστικών, μαζί με τα παραπάνω χαρακτηριστικά εξάγεται και το `best_coeffs_idx`, το οποίο χρησιμοποιείται για τον εντοπισμό των οκτώ καλύτερων συντελεστών του πραγματικού και φανταστικού μέρους. Αφού εξαχθούν οι καλύτεροι 8

συντελεστές πραγματικού και φανταστικού μέρους, ενοποιούνται μαζί με τα χαρακτηριστικά της ισχύος και του snr, με αποτέλεσμα τα συνολικά χαρακτηριστικά εκπαίδευσης, από 486 να γίνονται 18. Τα αντίστοιχα τμήματα κώδικα δεικνύονται στο *Παράρτημα Α: Κώδικας*.

Τα μετέπειτα σετ δεδομένων που εξήχθησαν για την επιπλέον αξιολόγηση των μοντέλων μηχανικής μάθησης, δέχθηκαν την ίδια επεξεργασία ώστε να συνάδουν με τα συνολικά δεδομένα.

4.8 Εκπαίδευση Αλγορίθμων Μηχανικής Μάθησης

Όπως αναφέρθηκε και στην εισαγωγή αυτού του κεφαλαίου, χρησιμοποιήθηκαν τέσσερις αλγόριθμοι, ώστε να επιλεγθεί αυτός που μπορεί να αποδώσει με μεγαλύτερη επιτυχία το επιθυμητό αποτέλεσμα. Σε αυτήν την ενότητα αναλύονται με περισσότερες λεπτομέρειες οι λειτουργίες και ο τρόπος προγραμματισμού των τεσσάρων αυτών αλγορίθμων. Όλοι οι αλγόριθμοι εκτελέστηκαν στο `Jupiter Notebook Machine_Learning_Models.ipynb`.

4.8.1 GNB (Gaussian Naive Bayes)

Ο αλγόριθμος Gaussian Naive Bayes ήταν από τους πρώτους αλγόριθμους που εξετάστηκε σε αυτήν την διπλωματική εργασία και η δομή του παρουσιάζεται παρακάτω.

Αρχικά, εφαρμόζεται η τεχνική διαστρωμένης επικύρωσης ισοκατανεμημένων δεδομένων K επιπέδων με τέσσερα επίπεδα, ώστε να κατανεμηθούν τα δεδομένα ισανάλογα στα σετ δεδομένων εκπαίδευσης και αξιολόγησης σε κάθε επίπεδο. Συγκεκριμένα, χωρίζεται το σετ δεδομένων σε σετ εκπαίδευσης και σετ αξιολόγησης, κλιμακώνονται τα δεδομένα και πραγματοποιείται εκπαίδευση για κάθε επίπεδο από τα τέσσερα ισοκατανεμημένα που δημιουργήθηκαν. Αφού τελειώσει η εκπαίδευση, για κάθε επίπεδο, πραγματοποιούνται οι προβλέψεις μέσω ενός Gaussian Naive Bayes ταξινομητή.

Τέλος, για κάθε επίπεδο, εξάγεται το ποσοστό ακρίβειας και ο πίνακας σύγχυσης και εκτυπώνεται ο μέσος όρος τους.

Το κομμάτι κώδικα που πραγματοποιεί την παραπάνω διαδικασία αποτυπώνεται στο *Παράρτημα Α: Κώδικας*.

4.8.2 XGBoost

Ο αλγόριθμος έχει την ίδια δομική λειτουργία με τον Gaussian Naive Bayes με δύο κύριες διαφορές.

Αρχικά χρησιμοποιείται ο `xgboost` ταξινομητής για την εκπαίδευση και εξαγωγή προβλέψεων του μοντέλου για κάθε επίπεδο. Επιπροσθέτως, εφαρμόζονται τρία ισοκατανεμημένα επίπεδα έναντι των τεσσάρων του GNB.

Ο αλγόριθμος αυτός, όπως και ο GNB, εξάγει τον μέσο όρο ακρίβειας πρόβλεψης των μοντέλων, όπως επίσης και τον μέσο όρο των πινάκων σύγχυσης που δημιουργούνται ανά επίπεδο.

Ο κώδικας του μοντέλου XGBoost παρουσιάζεται στο *Παράρτημα Α: Κώδικας*.

4.8.3 LightGBM

Ο κώδικας που αναπτύχθηκε για τον αλγόριθμο LightGBM, αρχικά, χωρίζει το σετ δεδομένων σε σετ εκπαίδευσης και αξιολόγησης, με αναλογία 80% του συνολικού σετ για τη δημιουργία του σετ εκπαίδευσης και 20% για τη δημιουργία του σετ αξιολόγησης. Στη συνέχεια, εφαρμόζονται δύο μετασχηματισμοί στα δεδομένα του σετ εκπαίδευσης και του σετ αξιολόγησης, το Κατώτατο όριο διακύμανσης (Variance Threshold) και η Κλιμάκωση (Scaling) δεδομένων.

Έπειτα, καθορίζονται οι παράμετροι του μοντέλου με δύο επίπεδα διασταυρωμένης επικύρωσης και εικοσιπέντε επαναλήψεις σε ένα εύρος τιμών των παραμέτρων. Οι παράμετροι που εφαρμόστηκαν φαίνονται στο *Παράρτημα Α: Κώδικας*.

Ακολουθως, διαλέγονται οι καλύτερες παράμετροι, βάσει του καλύτερου σκορ επιτυχίας και επιλέγεται το καλύτερο μοντέλο.

Τέλος, αξιολογείται η εκπαίδευση του καλύτερου μοντέλου μέσω των προβλέψεων που προκύπτουν από τις κλάσεις του σετ δεδομένων αξιολόγησης και εκτυπώνεται το ποσοστό ακρίβειας πρόβλεψης και ο πίνακας σύγχυσης.

4.8.4 Feed-forward Neural Network

Στα πλαίσια ανάπτυξης του αλγόριθμου FNN, χρησιμοποιήθηκαν τα πακέτα Keras και Sklearn, για την αρχιτεκτονική του νευρωνικού δικτύου και την διαχείριση και ανάλυση των δεδομένων, εισόδου και εξόδου.

Τα δεδομένα που τροφοδοτήθηκαν στο μοντέλο, υπέστησαν επιπλέον προεπεξεργασία αυτής που αναφέρεται στην *Ενότητα 4.7.4*. Συγκεκριμένα, το X και το y , που καθορίστηκαν στην αρχική επεξεργασία, χωρίστηκαν σε τρία μέρη το καθένα:

- X_{train} , y_{train} :
Το πρώτο μέρος αντιστοιχεί στο 80% του συνολικού σετ δεδομένων και αποτελεί το σετ εκπαίδευσης, με X_{train} να συμβολίζονται τα χαρακτηριστικά των δεδομένων και y_{train} οι κλάσεις που αντιστοιχούν στο συγκεκριμένο σετ.
- X_{val} , y_{val} :
Το δεύτερο μέρος αντιστοιχεί στο 20% του συνολικού σετ δεδομένων και αποτελεί το σετ αξιολόγησης της εκπαίδευσης, με X_{val} να συμβολίζονται τα χαρακτηριστικά των δεδομένων και y_{val} οι κλάσεις που αντιστοιχούν στο συγκεκριμένο σετ.
- X_{test} , y_{test} :
Το τρίτο μέρος αντιστοιχεί στο 10% του συνολικού σετ δεδομένων και αποτελεί το σετ εξακρίβωσης της εκπαίδευσης, με X_{test} να συμβολίζονται τα χαρακτηριστικά των δεδομένων και y_{test} οι κλάσεις που αντιστοιχούν στο συγκεκριμένο σετ.

Έπειτα, εφαρμόστηκαν οι εξής μέθοδοι επεξεργασίας δεδομένων στα τρία σετ που δημιουργήθηκαν:

1. StandardScaler

Η μέθοδος StandardScaler αποτελεί έναν μετασχηματιστή χαρακτηριστικών των δεδομένων. Η λειτουργία της είναι να κλιμακώνει τα δεδομένα ώστε να έχουν μηδενική μέση τιμή και μοναδιαία τυπική απόκλιση. Χάρη σε αυτή τη λειτουργία τα χαρακτηριστικά με μεγαλύτερες τιμές δεν κυριαρχούν στις βαρύτητες που δημιουργούνται ανά στοιβάδα νευρώνων.

2. VarianceThreshold

Η μέθοδος αυτή αποτελεί και αυτή έναν μετασχηματιστή χαρακτηριστικών και χρησιμοποιήθηκε ώστε να αφαιρεθούν δεδομένα τα οποία είχαν μικρή τυπική απόκλιση. Η τυπική απόκλιση της μεθόδου καθορίζεται αφού πρώτα υπολογιστεί η μέση τιμή του

χαρακτηριστικού. Όταν η τυπική απόκλιση είναι χαμηλή, σημαίνει ότι το χαρακτηριστικό αυτό δεν έχει μεγάλη βαρύτητα στις προβλέψεις και έτσι αφαιρείται.

3. SMOTE (Synthetic Minority Over-sampling Technique)

Η συγκεκριμένη μέθοδος χρησιμοποιήθηκε σε ορισμένες περιπτώσεις εκπαίδευσης και ο ρόλος της είναι να δημιουργεί δεδομένα στις κλάσεις με τα λιγότερα δεδομένα ώστε να υπάρχει ισορροπία στα δεδομένα ανά κλάση. Τα δεδομένα που δημιουργούνται έχουν τιμές ενδιάμεσες των πραγματικών δεδομένων που καταγράφηκαν.

4. SimpleImputer

Η μέθοδος αυτή εφαρμόστηκε για τη διαχείριση χαμένων τιμών των δεδομένων και η λειτουργία της είναι να τοποθετεί την μέση τιμή των τιμών του χαρακτηριστικού του δεδομένου σε τιμές που χάθηκαν κατά την καταγραφή.

Στη συνέχεια, δημιουργήθηκε ένα μοντέλο, το οποίο αποτελείται από τέσσερις στοιβάδες πλήρως συνδεδεμένες μεταξύ τους. Η πρώτη αφορά την στοιβάδα εισόδου με 256 νευρώνες, η δεύτερη και η τρίτη αποτελούν τις κρυμμένες στοιβάδες με 128 και 64 νευρώνες αντίστοιχα και η τέταρτη αφορά την στοιβάδα εξόδου με νευρώνες αντίστοιχους του αριθμού των κλάσεων κάθε σεναρίου εκπαίδευσης (Ανίχνευση παρουσίας ατόμων, Ανίχνευση πληρότητας χώρου και Ανίχνευση αριθμού ατόμων στον χώρο).

Ακολούθως, εκπαιδεύτηκε το μοντέλο, ελέγχοντας τις απώλειες πρόβλεψης του σετ αξιολόγησης (Validation subset) και εφαρμόζοντας Early-Stopping με τιμή 20 (δηλαδή το μοντέλο εκτελεί άλλες είκοσι εποχές από την τελευταία χαμηλότερη τιμή των απωλειών πρόβλεψης του σετ αξιολόγησης). Όταν η τιμή των απωλειών σταματήσει να μειώνεται ανακτώνται τα καλύτερα βάρη.

Τέλος, η εκπαίδευση του μοντέλου αξιολογήθηκε προβλέποντας τις επιθυμητές κλάσεις μέσω του τρίτου μέρους του συνολικού σετ δεδομένων (X_{test}) και εκτυπώθηκαν οι καμπύλες εκπαίδευσης, αξιολόγησης συναρτήσεως των εποχών και αποτυπώθηκε ο πίνακας σύγκρισης όπως φαίνεται στο Παράρτημα Α: Κώδικας.

4.8.5 Μετα-μοντέλο FNN

Το μεταμοντέλο FNN αναπτύχθηκε σε διαφορετικό jupyter notebook από τα προηγούμενα μοντέλα μηχανικής μάθησης. Στο συγκεκριμένο notebook, με όνομα FNN_Models_Combination_of_Predictions.ipynb, πραγματοποιήθηκε η ίδια επεξεργασία και οριστικοποίηση του, προς εκπαίδευση και αξιολόγηση, σετ δεδομένων, με αυτήν που περιγράφηκε στην Ενότητα 4.7.4, με μόνη διαφοροποίηση τον ορισμό τριών y , το καθένα από τα οποία αποτελεί τις κλάσεις των τριών σεναρίων εκπαίδευσης (ανίχνευση παρουσίας, ανίχνευση πληρότητας και ανίχνευση ακριβή αριθμού ατόμων στον χώρο).

Αυτό επετεύχθη με την ομαδοποίηση των κλάσεων. Δηλαδή στο πρώτο σενάριο που εξετάστηκαν δύο κλάσεις (παρουσία και απουσία), οι κλάσεις με τιμές 2, 3, 4 πήραν την τιμή 1. Στο δεύτερο σενάριο (μικρή μεσαία και υψηλή πληρότητα), όπου εξετάστηκαν τρεις κλάσεις, τα δεδομένα με κλάσεις 0 και 1 έγιναν 0 και στο τρίτο σενάριο οι κλάσεις έμειναν ως είχαν κατά την εξαγωγή τους.

Έπειτα από την επεξεργασία των δεδομένων δημιουργήθηκαν τα τρία βασικά μοντέλα με αρχιτεκτονική ίδια με αυτή που υλοποιήθηκε στο FNN μοντέλο και με μόνη διαφοροποίηση τις

στοιβάδες εξόδου κάθε βασικού μοντέλου, που αντιστοιχούν στον μέγιστο αριθμό κλάσεων κάθε σεναρίου.

Εν συνεχεία, δημιουργήθηκε το σετ δεδομένων του μετά-μοντέλου. Σε αυτό το σετ δεδομένων, τα X ορίστηκαν ως οι προβλέψεις των τριών προαναφερθέντων σεναρίων, και τα y ο συνδυασμός των προβλέψεων αυτών. Τα X , συγκεκριμένα, προέκυψαν από τους νευρώνες εξόδου των τριών βασικών μοντέλων, με τιμές τις πιθανότητες η πρόβλεψη να αντιστοιχεί στην εκάστοτε κλάση για το εκάστοτε σενάριο (δηλαδή από το σενάριο ανίχνευσης παρουσίας εξάγονται δύο πιθανότητες, από το σενάριο πληρότητας εξάγονται τρεις πιθανότητες και από το σενάριο ακριβούς αριθμού εξάγονται πέντε πιθανότητες). Έτσι, τα χαρακτηριστικά του νέου σετ δεδομένων είναι 10 στήλες με 78.845 γραμμές. Τα y καθορίστηκαν με χρήση του σταθμισμένου μέσου όρου των κλάσεων πρόβλεψης των τριών σεναρίων. Συγκεκριμένα, βάσει των ακριβειών πρόβλεψης του κάθε σεναρίου υπολογίστηκαν τα βάρη, για τον ορισμό των τελικών κλάσεων. Οι τελικές κλάσεις είναι πέντε και ορίστηκαν βάσει τεσσάρων κατωφλιών που υπολογίστηκαν .

Οι παραπάνω υπολογισμοί πραγματοποιήθηκαν για τα σετ εκπαίδευσης, αξιολόγησης και δοκιμής που εφαρμόστηκαν στο μετά-μοντέλο. Η αρχιτεκτονική του μετά-μοντέλου καθορίστηκε με τρεις στοιβάδες νευρώνων. Η πρώτη αφορά την στοιβάδα εισόδου με 10 νευρώνες και συνάρτηση ενεργοποίησης την Ανορθωμένη Γραμμική Μονάδα (ReLU: Rectified Linear Unit), η δεύτερη αφορά την κρυμμένη στοιβάδα με 128 νευρώνες και την ίδια συνάρτηση ενεργοποίησης και η τρίτη στοιβάδα αφορά την στοιβάδα εξόδου με πέντε νευρώνες και συνάρτηση ενεργοποίησης την Softmax, η οποία εξάγει την κατανομή των εξόδων ως προς τις κλάσεις.

Τέλος, εκπαιδεύτηκε και αξιολογήθηκε το μετά-μοντέλο με την ίδια διαδικασία που αναφέρεται στην *Ενότητα 4.8.4* για το FNN μοντέλο και δημιουργήθηκαν τα γραφήματα απώλειας και ακρίβειας εκπαίδευσης και αξιολόγησης συναρτήσει των εποχών και αποτυπώθηκε ο πίνακας σύγχυσης για το σετ δοκιμής.

5 ΚΕΦΑΛΑΙΟ 5^ο : Αποτελέσματα και Αξιολόγηση

Σε αυτό το κεφάλαιο παρουσιάζονται τα αποτελέσματα των μοντέλων μηχανικής μάθησης που δοκιμάστηκαν, όπως επίσης και η μέθοδος με την οποία αξιολογήθηκαν τα αποτελέσματα των εμπρόσθιας τροφοδότησης νευρωνικών δικτύων που εφαρμόστηκαν για την επίλυση του συγκεκριμένου ζητήματος.

5.1 Αποτελέσματα

Οι παρακάτω ενότητες παρουσιάζουν τους πίνακες σύγκρισης και τα ποσοστά ακρίβειας επιτυχούς πρόβλεψης των κλάσεων των εκάστοτε σεναρίων, για κάθε αλγόριθμο μηχανικής μάθησης που δοκιμάστηκε. Για τους αλγόριθμους GNB (Gaussian Naive Bayes) και XGBoost παρουσιάζεται ο μέσος όρος κελιών των πινάκων σύγκρισης για κάθε επίπεδο εκπαίδευσης και αξιολόγησης που εφαρμόζει η τεχνική ισοκατανεμημένων K-επιπέδων.

5.1.1 Gaussian Naive Bayes

Για κάθε σενάριο που εφαρμόστηκε ο αλγόριθμος, η παραμετροποίηση ήταν ίδια, δηλαδή τέσσερα ισοκατανεμημένα επίπεδα διαφορετικών συνδυασμών ποσοστών σετ εκπαίδευσης και αξιολόγησης ανά επίπεδο.

Κύριο Σετ Εκπαίδευσης 486 Χαρακτηριστικών:

- Δύο Κλάσεις: Απουσία ή Παρουσία Ατόμων

```
0.39880529626623373
[[ 532.25 2400.25]
 [9450.5  7329.  ]]
```

Εικόνα 5.1 Αποτελέσματα GNB Δύο Κλάσεων

- Τρεις Κλάσεις: Μικρή, Μεσαία ή Υψηλή Πληρότητα Χώρου

```
0.27181412337662336
[[4561.  1289.25 1043.5 ]
 [7505.5  550.5  825.  ]
 [3074.25 616.5  246.5 ]]
```

Εικόνα 5.2 Αποτελέσματα GNB Τριών Κλάσεων

- Πέντε Κλάσεις: Κανένα, Ένα, Δύο, Τρία ή Τέσσερα Άτομα

```
0.178026075487013
[[ 196.5  1187.  1406.  47.25  95.75]
 [ 677.75 1371.75 1745.25  64.75 101.75]
 [ 614.5  1616.75 1845.  58.75  52.5 ]
 [ 823.75 1558.5 2110.75  30.75 169.75]
 [ 460.5  1335.5 1965.  111.  65.25]]
```

Εικόνα 5.3 Αποτελέσματα GNB Πέντε Κλάσεων

5.1.2 XGBoost

Για κάθε σενάριο που εφαρμόστηκε ο αλγόριθμος, η παραμετροποίηση ήταν ίδια, δηλαδή τρία ισοκατανεμημένα επίπεδα διαφορετικών συνδυασμών ποσοστών σετ εκπαίδευσεων και αξιολογήσεων ανά επίπεδο.

Κύριο Σετ Εκπαίδευσης 486 Χαρακτηριστικών:

- Δύο Κλάσεις: Απουσία ή Παρουσία Ατόμων

```
0.8203238745305939
[[ 887.66666667 3022.33333333]
 [ 1700.        20672.66666667]]
```

Εικόνα 5.4 Αποτελέσματα XGBoost Δύο Κλάσεων

- Τρεις Κλάσεις: Μικρή, Μεσαία ή Υψηλή Πληρότητα Χώρου

```
0.40972627910915566
[[4425.66666667 4391.66666667 374.33333333]
 [4960.66666667 4747.33333333 2133.33333333]
 [1391.66666667 2262.33333333 1595.66666667]]
```

Εικόνα 5.5 Αποτελέσματα XGBoost Τριών Κλάσεων

- Πέντε Κλάσεις: Κανένα, Ένα, Δύο, Τρία ή Τέσσερα Άτομα

```
0.2756949367876685
[[1177.        1071.66666667 641.66666667 984.33333333 35.33333333]
 [ 829.66666667 1805.        1095.33333333 1094.33333333 457.33333333]
 [ 639.66666667 1193.66666667 734.        2078.66666667 937.33333333]
 [ 183.33333333 926.33333333 1696.66666667 1726.66666667 1725.        ]
 [ 287.33333333 910.33333333 483.        1765.66666667 1803.33333333]]
```

Εικόνα 5.6 Αποτελέσματα XGBoost Πέντε Κλάσεων

5.1.3 LightGBM

Για τον αλγόριθμο αυτό εφαρμόστηκαν δύο επίπεδα διασταυρωμένης επικύρωσης με 25 επαναλήψεις το κάθε ένα, δηλαδή συνολικό αριθμό εκπαιδύσεων το 50.

Κύριο Σετ Εκπαίδευσης 486 Χαρακτηριστικών:

- Δύο Κλάσεις: Απουσία ή Παρουσία Ατόμων

```
0.9350031705770451
[[ 1557 767]
 [ 258 13188]]
```

Εικόνα 5.7 Αποτελέσματα LightGBM Δύο Κλάσεων

- Τρεις Κλάσεις: Μικρή, Μεσαία ή Υψηλή Πληρότητα Χώρου

```
0.69429296131896
[[4400  662  490]
 [1141 4401 1539]
 [ 300  689 2148]]
```

Εικόνα 5.8 Αποτελέσματα LightGBM Τριών Κλάσεων

- Πέντε Κλάσεις: Κανένα, Ένα, Δύο, Τρία ή Τέσσερα Άτομα

```
0.5769816106531389
[[1840  252  102   50   80]
 [ 230 2280  221  331  166]
 [ 207  542  998 1165  394]
 [  89  253  570 2140  723]
 [  75  218  315  688 1841]]
```


Εικόνα 5.9 Αποτελέσματα LightGBM Πέντε Κλάσεων

5.1.4 Feed-forward Neural Network


- Κύριο Σετ Εκπαίδευσης 486 Χαρακτηριστικών:
 - Δύο Κλάσεις: Απουσία ή Παρουσία Ατόμων

```
Epoch 73: early stopping
Restoring model weights from the end of the best epoch: 53.
493/493 ██████████ 2s 4ms/step
493/493 ██████████ 2s 5ms/step - accuracy: 0.9430 - loss: 0.1544
Test accuracy: 0.9464172720909119
```


Εικόνα 5.10 Ακρίβειες FNN Δύο Κλάσεων



Εικόνα 5.11 Καμπύλες Ακρίβειας Εκπαίδευσης και Αξιολόγησης FNN Δύο Κλάσεων



Εικόνα 5.12 Καμπύλες Απωλειών Εκπαίδευσης και Αξιολόγησης FNN Δύο Κλάσεων




Πίνακας 5.1 Πίνακας Σύγχυσης FNN Δύο Κλάσεων


→ Τρεις Κλάσεις: Μικρή, Μεσαία ή Υψηλή Πληρότητα Χώρου

```
Epoch 179: early stopping
Restoring model weights from the end of the best epoch: 159.
493/493 ██████████ 2s 4ms/step
493/493 ██████████ 2s 3ms/step - accuracy: 0.8303 - loss: 0.4280
Test accuracy: 0.829676628112793
```


Εικόνα 5.13 Ακρίβειες FNN Τριών Κλάσεων



Εικόνα 5.14 Καμπύλες Απωλειών Εκπαίδευσης και Αξιολόγησης FNN Τριών Κλάσεων



Εικόνα 5.15 Καμπύλες Ακρίβειας Εκπαίδευσης και Αξιολόγησης FNN Τριών Κλάσεων




Πίνακας 5.2 Πίνακας Σύγκρισης FNN Τριών Κλάσεων


→ Πέντε Κλάσεις: Κανένα, Ένα, Δύο, Τρία ή Τέσσερα Άτομα

```
Epoch 196: early stopping
Restoring model weights from the end of the best epoch: 176.
493/493 ————— 2s 3ms/step
493/493 ————— 2s 3ms/step - accuracy: 0.6856 - loss: 0.7418
Test accuracy: 0.6852885484695435
```


Εικόνα 5.16 Ακρίβειες FNN Πέντε Κλάσεων



Εικόνα 5.17 Καμπύλες Απωλειών Εκπαίδευσης και Αξιολόγησης FNN Πέντε Κλάσεων



Εικόνα 5.18 Καμπύλες Ακρίβειας Εκπαίδευσης και Αξιολόγησης FNN Πέντε Κλάσεων




Πίνακας 5.3 Πίνακας Σύγκρισης FNN Πέντε Κλάσεων

➤ Κύριο Σετ Εκπαίδευσης 18 Χαρακτηριστικών


FNN Presence: 90.98%

FNN Occupancy: 63.48%


FNN People Counting: 47.37%




Εικόνα 5.19 Ιστόγραμμα FNN 18 Χαρακτηριστικών Εκπαίδευσης



Εικόνα 5.20 Συνοπτικό Ιστόγραμμα FNN Δύο Κλάσεων



Εικόνα 5.21 Συνοπτικό Ιστόγραμμα FNN Τριών Κλάσεων




Εικόνα 5.22 Συνοπτικό Ιστόγραμμα FNN Πέντε Κλάσεων

➤ Μετά-Μοντέλο FNN:

→ Πέντε Κλάσεις: Κανένα, Ένα, Δύο, Τρία ή Τέσσερα Άτομα

```
Restoring model weights from the end of the best epoch: 182.  
493/493 ————— 25s 47ms/step - accuracy: 0.9974 - loss: 0.0070  
Meta-model performance: loss=0.0077, accuracy=0.9975  
247/247 ————— 1s 3ms/step  
247/247 ————— 1s 5ms/step - accuracy: 0.9965 - loss: 0.0085  
Meta-model performance on test set: loss=0.0093, accuracy=0.9958
```

Εικόνα 5.23 Ακρίβειες Μέτα-Μοντέλου FNN Πέντε Κλάσεων



Πίνακας 5.4 Πίνακας Σύγχυσης FNN Πέντε Κλάσεων

5.2 Αξιολόγηση

Κατά την αξιολόγηση επιλέχθηκαν τρεις χώροι διαφορετικών προδιαγραφών ώστε να ελεγχθεί αν τα μοντέλα μηχανικής μάθησης μπορούν να προβλέψουν τον αριθμό ατόμων και σε άλλους χώρους πέραν του χώρου εκπαίδευσης.

5.2.1 Αξιολόγηση Αποτελεσμάτων Πειραματικής Διαδικασίας


Για την αξιολόγηση των αποτελεσμάτων εγκαταστάθηκαν τα παραπάνω συστήματα σε δύο πανεπιστημιακούς χώρους με διαφορετικά χωροταξικά χαρακτηριστικά και καταγράφηκαν δεδομένα τα οποία χρησιμοποιήθηκαν για να δοκιμαστούν τα εκπαιδευμένα μοντέλα FNN.

Ο πρώτος χώρος ήταν παρόμοιων διαστάσεων με τον χώρο εκπαίδευσης των μοντέλων με διαφοροποίηση στην χωροταξία του χώρου και ο δεύτερος χώρος ήταν ο διπλάσιος σε τετραγωνικά από τον χώρο εκπαίδευσης. Παρακάτω παρατίθενται τα αποτελέσματα που προέκυψαν από τους δύο χώρους αυτούς.

Χώρος A (67 τμ):


➤ FNN

→ Δύο Κλάσεις: Απουσία ή Παρουσία Ατόμων, Ακρίβεια Πρόβλεψης 70.43%




Πίνακας 5.5 Πίνακας Σύγχυσης FNN Δύο Κλάσεων Χώρου Α

→ Τρεις Κλάσεις: Μικρή, Μεσαία ή Υψηλή Πληρότητα Χώρου, Ακρίβεια Πρόβλεψης 45.65%



Πίνακας 5.6 Πίνακας Σύγχυσης FNN Τριών Κλάσεων Χώρου Α

→ Πέντε Κλάσεις: Κανένα, Ένα, Δύο, Τρία ή Τέσσερα Άτομα, Ακρίβεια Πρόβλεψης 15.65%




Πίνακας 5.7 Πίνακας Σύγκρισης FNN Τριών Κλάσεων Χώρου Α

➤ Μετά-Μοντέλο FNN

```
Restoring model weights from the end of the best epoch: 91.
493/493 ██████████ 2s 3ms/step - accuracy: 0.9960 - loss: 0.0114
Meta-model performance: loss=0.0112, accuracy=0.9958
95/95 ██████████ 1s 5ms/step
95/95 ██████████ 0s 4ms/step - accuracy: 0.9987 - loss: 0.0065
Meta-model performance on test set: loss=0.0069, accuracy=0.9983
```

Εικόνα 5.24 Ακρίβειες Μέτα-Μοντέλου FNN Πέντε Κλάσεων Χώρου Α




Πίνακας 5.8 Πίνακας Σύγκρισης Μετά Μοντέλου FNN Πέντε Κλάσεων Χώρου Α

Χώρος Β (33 τμ):


➤ FNN

→ Δύο Κλάσεις: Απουσία ή Παρουσία Ατόμων, Ακρίβεια Πρόβλεψης 66.52%




Πίνακας 5.9 Πίνακας Σύγκρισης FNN Δύο Κλάσεων Χώρου Β

→ Τρεις Κλάσεις: Μικρή, Μεσαία ή Υψηλή Πληρότητα Χώρου, Ακρίβεια Πρόβλεψης 43.04%



Πίνακας 5.10 Πίνακας Σύγχυσης FNN Τριών Κλάσεων Χώρου Β

→ Πέντε Κλάσεις: Κανένα, Ένα, Δύο, Τρία ή Τέσσερα Άτομα, Ακρίβεια Πρόβλεψης 16.96%




Πίνακας 5.11 Πίνακας Σύγχυσης FNN Πέντε Κλάσεων Χώρου B

➤ Μετά-Μοντέλο FNN

```

Epoch 43: early stopping
Restoring model weights from the end of the best epoch: 23.
493/493 ————— 31s 63ms/step - accuracy: 0.9914 - loss: 0.0186
Meta-model performance: loss=0.0196, accuracy=0.9911
8/8 ————— 0s 26ms/step
    
```

Εικόνα 5.25 Ακρίβειες Μέτα-Μοντέλου FNN Πέντε Κλάσεων Χώρου B



Πίνακας 5.12 Πίνακας Σύγχυσης Μετά Μοντέλου FNN Πέντε Κλάσεων Χώρου B

5.3 Προβλήματα και Προβληματισμοί κατά την Υλοποίηση

Κατά την εκπόνηση της διπλωματικής εργασίας προέκυψαν τα παρακάτω ζητήματα και προβληματισμοί:

- Επειδή το Arduino UNO δεν είχε εσωτερικό ρολόι, δημιουργώντας έτσι πρόβλημα στην σύγκριση των timestamp, κατασκευάστηκε ένα RTC το οποίο στέλνει την ώρα στο Arduino UNO και έτσι επιτυγχάνεται η πραγματική καταγραφή του χρόνου.
- Τρόπος σύγκρισης δεδομένων μεταξύ των συστημάτων (λύθηκε με σύγκριση timestamp)
- Αρχικά είχε δημιουργηθεί άλλο σύστημα ανίχνευσης πραγματικού αριθμού ατόμων, αλλά απορρίφθηκε η χρήση του, καθώς χρησιμοποιούσε 2 υπέρυθρους αισθητήρες οι οποίοι είχαν εμβέλεια 15cm και παρουσίαζαν μεγάλο σφάλμα μέτρησης με αποτέλεσμα πολλές λανθασμένες έως και καθόλου καταγραφές.
- Αφαίρεση καπακιού των pir αισθητήρων ώστε η εμβέλεια ανίχνευσης να μην είναι 180 μοίρες, καθώς συνέβαιναν λάθος καταγραφές.
- Το idx θεωρήθηκε ορθό να διορθωθεί καθώς κατά την ενοποίηση των αρχείων δεν υπήρχε ακολουθία των τιμών του και το πεδίο "row" διορθώθηκε καθώς κατά την προεπεξεργασία των δεδομένων δεν μπορούσαν να μετατραπούν οι τιμές της ετικέτας αυτής σε λίστα.
- Στον αλγόριθμο LightGBM θα μπορούσε να εφαρμοστεί μεγαλύτερος αριθμός επιπέδων στα σενάρια με περισσότερες κλάσεις, αλλά δεν πραγματοποιήθηκε διότι απαιτούσε πολλούς υπολογιστικούς πόρους που ο υπολογιστής που χρησιμοποιήθηκε για την εκπόνηση της διπλωματικής εργασίας δεν μπορούσε να παρέχει. Ωστόσο βάσει των αποτελεσμάτων που παρουσιάζει στα δύο επίπεδα, θα μπορούσε κανείς να πιθανολογήσει ότι ίσως να ήταν καλύτερος αλγόριθμος από τον FNN για την επίλυση του προβλήματος κατηγοριοποίησης του αριθμού ατόμων σε εσωτερικό χώρο.

- Θα μπορούσαν να εφαρμοστούν τεχνικές όπως το Grid Search για την εύρεση των καλύτερων παραμέτρων για τους αλγορίθμους FNN και LightGBM αλλά απαιτούνταν αρκετοί υπολογιστικοί πόροι και δεν εφαρμόστηκε. Η παραμετροποίηση των μοντέλων πραγματοποιήθηκε έπειτα από δοκιμές.
- Η τοποθέτηση του δέκτη στον χώρο Α αρχικά πραγματοποιήθηκε στην γωνία της αίθουσας αλλά παρατηρήθηκε ότι δεν μπορούσε να επικοινωνήσει με τον πομπό λόγω απόστασης και θορύβου.

6 Συμπεράσματα και Παρατηρήσεις

Κατά την εκπόνηση της συγκεκριμένης διπλωματικής εργασίας προέκυψαν οι παρατηρήσεις που παρουσιάζονται παρακάτω, όπως επίσης και τα συμπεράσματα που εξάχθηκαν από τα αποτελέσματα που παράχθηκαν κατά τη διαδικασία της υλοποίησης.

6.1.1 Παρατηρήσεις

1. Τα δυο υποσυστήματα ήταν απαραίτητο να λειτουργούν ταυτόχρονα ώστε να μπορεί να γίνει η μετέπειτα σύγκριση μεταξύ των δεδομένων
2. Κατά την εκτέλεση του κώδικα του μοντέλου μηχανικής μάθησης LightGBM, χρησιμοποιείται η μέθοδος F1-score macro για την επιλογή του καλύτερου σκορ στο πρόβλημα πολλών κλάσεων και η μέθοδος roc_auc (Receiver Operating Characteristic Area Under the Curve) για το πρόβλημα των των δύο κλάσεων.
3. Η τεχνική SMOTE δοκιμάστηκε σε διάφορα σενάρια και παρατηρήθηκε ότι δεν έχει μεγάλη επίδραση στις εκπαιδεύσεις των μοντέλων καθώς το πρόβλημα εκπαίδευσης είναι περίπλοκο λόγω της πολυπλοκότητας των δεδομένων.
4. Από τους πίνακες σύγκρισης των μοντέλων GNB, XGBoost και LightGBM παρατηρείται μεγάλη σύγκριση στις προβλέψεις των σεναρίων πληρότητας και ακριβούς αριθμού ατόμων.
5. Από τον πίνακα σύγκρισης του FNN μοντέλου για το σενάριο πρόβλεψης του ακριβούς αριθμού ατόμων, παρατηρείται ότι το μοντέλο αντιμετωπίζει μεγαλύτερη σύγκριση στην πρόβλεψη 2 και 3 ατόμων.
6. Έπειτα από πέντε δοκιμές σετ δεδομένων για εκπαίδευση και αξιολόγηση μέσω των αλγορίθμων, παρατηρήθηκε ότι τα υψηλότερα σκορ επιτυγχάνονται με το σετ που είχε τα περισσότερα δεδομένα. Στην συγκεκριμένη διπλωματική εργασία παρουσιάζονται τα αποτελέσματα που προκύπτουν από το πέμπτο σετ δεδομένων με το μεγαλύτερο αριθμό δεδομένων που συλλέχθηκαν.
7. Έπειτα από διάφορες αρχιτεκτονικές που εφαρμόστηκαν στον αλγόριθμο FNN, παρατηρήθηκε ότι οι καλύτεροι αριθμοί νευρώνων για τις κρυμμένες στοιβάδες είναι 100 με 200 νευρώνες.
8. Στον Χώρο A η επικοινωνία πομπού με δέκτη εμπειρείχε πολύ θόρυβο, με αποτέλεσμα αναξιόπιστα δεδομένα.

6.1.2 Συμπεράσματα

1. Χρειάζονται πολλά δεδομένα για καλύτερη γενίκευση, καθώς η τιτλοφόρηση γίνεται ανά πακέτο κάνοντας το πρόβλημα περίπλοκο για τους αλγορίθμους (στιγμιότυπα καταστάσεων).
2. Όσο αυξάνεται ο αριθμός των κλάσεων τόσο πιο πολύπλοκο γίνεται το πρόβλημα της κατηγοριοποίησης, με αποτέλεσμα τη μείωση του ποσοστού επιτυχίας πρόβλεψης.
3. Βάσει του υπολογισμού των μέσων όρων των τιμών ακρίβειας και των τιμών των πινάκων σύγκρισης εξάγεται το συμπέρασμα ότι τα μοντέλα μηχανικής μάθησης GNB και XGBoost είναι εύρωστα.
4. Σύμφωνα με τα αποτελέσματα που προέκυψαν από τις εκπαιδεύσεις και αξιολογήσεις των τεσσάρων αλγορίθμων μηχανικής μάθησης, εξάγεται το συμπέρασμα ότι ο

καταλληλότερος, για την ανίχνευση του αριθμού ατόμων σε έναν εσωτερικό χώρο, είναι ο αλγόριθμος εμπρόσθιας τροφοδότησης νευρωνικών δικτύων.

5. Με τη χρήση του μετά-μοντέλου μηχανικής μάθησης επιτυγχάνεται μεγαλύτερο ποσοστό ακρίβειας πρόβλεψης του ακριβούς αριθμού ατόμων.
6. Από τα αποτελέσματα των σετ δοκιμής που χρησιμοποιήθηκαν για να αξιολογηθεί η γενίκευση που επιτυγχάνει το επιλεγθέν καλύτερο μοντέλο, εξάγεται το συμπέρασμα ότι οι ανακλάσεις του χώρου επηρεάζονται από τη διαμόρφωση του χώρου και τον θόρυβο που υπάρχει γύρω του.
7. Το σύστημα που υλοποιήθηκε είναι λειτουργικό όταν εκπαιδεύεται με δεδομένα του χώρου ενδιαφέροντος και μπορεί να χρησιμοποιηθεί είτε για έλεγχο αριθμού ατόμων, είτε για έλεγχο πληρότητας.
8. Τέλος, συμπεραίνεται ότι είναι αναγκαία η δημιουργία προφίλ χώρων, για κάθε χώρο πιθανής εφαρμογής του συστήματος ανίχνευσης αριθμού ατόμων με χρήση ανίχνευσης WiFi και μηχανικής μάθησης, ώστε να υπάρχει μία εξ αρχής παραμετροποίηση του συστήματος σε όσο το δυνατόν καλύτερες συνθήκες καταγραφής δεδομένων.

Βιβλιογραφία – Αναφορές - Διαδικτυακές Πηγές

Διαδικτυακές Πηγές:

- [1] Wikipedia, 2024, Ραδιοκύματα, [Online] Available at: <https://el.wikipedia.org/wiki/%CE%A1%CE%B1%CE%B4%CE%B9%CE%BF%CE%BA%CF%8D%CE%BC%CE%B1%CF%84%CE%B1> Accessed Dec. 20, 2023.
- [2] JEM ENGINEERING, 2024, Intro to Antenna Polarization, [Online] Available at: <https://jemengineering.com/blog-intro-to-antenna-polarization/> Accessed Dec. 22, 2023.
- [3] FRC, 2024, Why Circular Polarization Antenna?, [Online] Available at: <https://cdn.thomasnet.com/ccp/10014548/223252.pdf> Accessed Jan. 9, 2024.
- [4] A. Wolke, 2024, What's Your IQ – About Quadrature Signals..., [Online] Available at: <https://www.tek.com/en/blog/quadrature-iq-signals-explained> Accessed Jan. 10, 2024.
- [5] M. Steer and CC BY-NC, 2024, 3.4: Receiver and Transmitter Architecture, [Online] Available at: [https://eng.libretexts.org/Bookshelves/Electrical_Engineering/Electronics/Microwave_and_RF_Design_I_-_Radio_Systems_\(Steer\)/03%3A_Transmitters_and_Receivers/3.04%3A_Receiver_and_Transmitter_Architectures](https://eng.libretexts.org/Bookshelves/Electrical_Engineering/Electronics/Microwave_and_RF_Design_I_-_Radio_Systems_(Steer)/03%3A_Transmitters_and_Receivers/3.04%3A_Receiver_and_Transmitter_Architectures) Accessed Jan. 25, 2024.
- [6] M. Lichtman, 2024, PySDR: A Guide to SDR and DSP using Python, [Online] Available at: <https://pysdr.org/content/sampling.html#receiver-architectures> Accessed Jan. 26, 2024.
- [7] Wikipedia, 2024, Channel State Information, [Online] Available at: https://en.wikipedia.org/wiki/Channel_state_information Accessed Jan. 26, 2024.
- [8] A. D'mello, 2024, Understanding AoA and AoD: What do they mean for location, [Online] Available at: <https://www.iotglobalnetwork.com/iotdir/2019/09/13/understanding-aoa-and-aod-what-do-they-mean-for-location-21131/> Accessed Jan. 27, 2024.
- [9] Wikipedia, 2024, Carrier Frequency Offset, [Online] Available at: https://en.wikipedia.org/wiki/Carrier_frequency_offset Accessed Jan. 26, 2024.
- [10] Kelifos Physics Group, 2024, K2: A Course on Neural Networks, K2, 200-20, [Online] Available at: <http://kelifos.physics.auth.gr/COURSES/neural/K2.pdf> Accessed Feb. 12, 2024.
- [11] Wikipedia, 2024, Rectifier (neural networks), [Online] Available at: [https://en.wikipedia.org/wiki/Rectifier_\(neural_networks\)](https://en.wikipedia.org/wiki/Rectifier_(neural_networks)) Accessed Feb. 25, 2024.
- [12] Wikipedia, 2024, Softmax function, [Online] Available at: https://en.wikipedia.org/wiki/Softmax_function Accessed Feb. 25, 2024.
- [13] Wikipedia, 2024, Power delay profile, [Online] Available at: https://en.wikipedia.org/wiki/Power_delay_profile Accessed Feb. 25, 2024.

[14] AfterAcademy, 2024, What is the TCP/IP model and how it works?, [Online] Available at: <https://afteracademy.com/blog/what-is-the-tcp-ip-model-and-how-it-works/> Accessed Jul. 12, 2024.

[15] Scikit Learn, 3.4. Metrics and scoring: quantifying the quality of predictions, [Online] Available at: https://scikit-learn.org/stable/modules/model_evaluation.html#classification-metrics Accessed Feb. 26, 2024.

Βιβλία:

[16] Δ. Φωτόπουλου and Α. Λάσκαρη, "Διακριτός Μετασχηματισμός Fourier - DFT," in ΨΗΦΙΑΚΗ ΕΠΕΞΕΡΓΑΣΙΑ ΣΗΜΑΤΟΣ Βασικές έννοιες και εφαρμογές, Πάτρα, Ελλάδα, 2019, pp. 203-208.

[17] H. Rohlin, "Introduction," in OFDM Concepts for Future Communication Systems, Hamburg, Germany, 2011, pp. 5-10.

[18] E. Perahia and R. Stacey, "Introduction," in Next Generation Wireless LANs - 802.11n and 802.11ac, 2nd ed., New York, NY: McGraw-Hill, 2013, pp. 3-31.

[19] J. F. Kurose and K. W. Ross, ΔΙΚΤΥΩΣΗ ΥΠΟΛΟΓΙΣΤΩΝ ΠΡΟΣΕΓΓΙΣΗ ΑΠΟ ΠΑΝΩ ΠΡΟΣ ΤΑ ΚΑΤΩ, 8th ed., New York, NY: McGraw-Hill Education, 2021.

[20] C. Miller, "Recognizing the Business Need for Better Wi-Fi," in Understanding Key 802.11ax Technologies, Hoboken, NJ: Wiley, 2018, pp. 5-13.

[21] S. Haykin, "Introduction," in Neural Networks and Learning Machines, 3rd ed., Ontario, Canada: McGraw-Hill Ryerson, 2009, pp. 34-43, 123-125, 171-175.

[22] K. H. T. S. M. P. Singla and U. Kose, "Introduction to Naive Bayes and a Review on Its Subtypes with Applications," in Bayesian, Reasoning and Gaussian Processes for Machine Learning Applications, 1st ed., Abingdon, Oxon: Routledge, 2022, pp. 1-7.

[23] B. Quinto, "Supervised Learning," in Next-Generation Machine Learning with Spark, 1st ed., Carson, CA, USA: D & M Publishing, 2020, pp. 116-146.

[24] J. Cao and Y. Yang, "Introduction," in Wireless Sensing Principles, Techniques and Applications, Cham, Switzerland: Springer, 2022, pp. 1-10.

Papers:

[26] Wi-Fi Alliance, "Wi-Fi 6 Technology and Evolution White Paper," Mar. 2020. [Online]. Available: <https://www.wi-fi.org/wp-content/uploads/2020/03/Wi-Fi-6-Technology-and-Evolution-White-Paper.pdf>, pp. 12–19.

[27] J. Smith, "Crowd Counting Through Walls Using WiFi," in Proc. IEEE Int. Conf. Wireless Communication Systems, 2019, pp. 1-2.

[28] X. Wang, "DeepCount: Crowd Counting with WiFi via Deep Learning," in Recent Advances in Wireless Communication Systems, Y. Lee and Z. Zhang, Eds. 2020, ch. 3, pp. 1-2.

[29] X. Li, "Electronic Frog Eye Counting Crowd Using WiFi," in Proc. Int. Conf. Wireless Communications and Networking, 2020.

[30] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," in Proc. 32nd Int. Conf. Machine Learning, pp. 1313-1321, 2015.

Βίντεο:

[31] J. Santarcangelo, "Handling Missing Values and Outliers," in Exploratory Data Analysis for Machine Learning, IBM, Armonk, NY, 2024, 1:14-1:42.

[32] J. Santarcangelo, "Feature Engineering and Variable Transformation," in Exploratory Data Analysis for Machine Learning, IBM, Armonk, NY, 2024, 2:45-3:23.

Πηγές Εικόνων:

[33] RF Page, 2023, Wi-Fi Sensing: Understanding the Technology and Applications [Online] Available at: <https://www.rfpage.com/wi-fi-sensing-technology-and-applications/> Accessed Jul. 15, 2024

[34] ΕΛΙΝΥΑΕ, 2024, Ακτινοβολία, [Online] Available at: <https://www.elinyae.gr/index.php/themata-yae/aktinobolia/page/ilektromagnitiko-fasma> Accessed Dec. 20, 2023

[35] Sumozade, 2024, Robotic Market of the World, [Online] Available at: <https://www.sumozade.com/product/mini-pir-motion-sensor-module-sc0322-1> Accessed Jun. 10, 2023

[36] Why, 2024, Διερευνητική Μάθηση, [Online] Available at: <https://www.why.gr/%CE%BA%CE%B1%CF%84%CE%B1%CF%83%CF%84%CE%B7%CE%BC%CE%B1/open-hardware/arduino/arduino-main-boards/arduino-uno-r3wE>, Accessed Jun. 10, 2023

[37] GROBOTRONICS, 2024, Proto Shield for Arduino UNO with Mini Breadboard [Online] Available at: <https://grobotronics.com/proto-shield-for-arduino-uno-with-mini-breadboard.html?sl=en>, Accessed Jun. 10, 2023

Παράρτημα Α: Κώδικας

Κώδικας Ανίχνευσης Εισόδου :

```
43     if (digitalRead(out_sensor) && !digitalRead(in_sensor)){
44         while(!digitalRead(in_sensor) && digitalRead(out_sensor)){
45             // wait
46             delay(50);
47         }
48
49         if (digitalRead(in_sensor) && digitalRead(out_sensor)){
50
51             cnt = cnt +1;
52             DateTime now = RTC.now();
53             uint32_t unix =now.unixtime();
54             doc["Time"] = unix;
55             doc["State"] = "Entry";
56             doc["Number of People"] = cnt;
57             serializeJson(doc, Serial);
58             Serial.println();
59             deserializeJson(doc, Serial);
60
61         }
62         while(digitalRead(in_sensor) || digitalRead(out_sensor)){
63             delay(50);
64         }
```

Κώδικας Ανίχνευσης Εξόδου :

```
66  ✓   else if (!digitalRead(out_sensor) && digitalRead(in_sensor)){
67  ✓       while(digitalRead(in_sensor) && !digitalRead(out_sensor)){
68           // wait
69           delay(50);
70       }
71  ✓   if (digitalRead(in_sensor) && digitalRead(out_sensor)){
72       cnt = cnt -1;
73       DateTime now = RTC.now();
74       uint32_t unix =now.unixtime();
75       doc["Time"] = unix;
76       doc["State"] ="Exit";
77       doc["Number of People"] = cnt;
78       serializeJson(doc, Serial);
79       Serial.println();
80       deserializeJson(doc, Serial);
81   }
82  ✓   while(digitalRead(in_sensor) || digitalRead(out_sensor)){
83       delay(50);
84   }
```

Κώδικας ενεργοποίησης Πράσινου Κουμπιού:

```
94   // WHEN GREEN BUTTON IS PUSHED
95  ✓   if (!gB){
96       cnt = cnt + 1;
97       DateTime now = RTC.now();
99       uint32_t unix =now.unixtime();
100      doc["Time"] = unix;
101      doc["Number of People"] = cnt;
102      serializeJson(doc, Serial);
103      Serial.println();
104      deserializeJson(doc, Serial);
105  }
```

Κώδικας ενεργοποίησης Κόκκινου Κουμπιού:

```

106 // WHEN RED BUTTON IS PUSHED
107 ✓ else if (!rB){
108
109     cnt = cnt - 1;
110     DateTime now = RTC.now();
111     uint32_t unix =now.unixtime();
112     doc["Time"] = unix;
113     doc["Number of People"] = cnt;
114     serializeJson(doc, Serial);
115     Serial.println();
116     deserializeJson(doc, Serial);
117
118 }

```

Κώδικας Ενοποίησης JSON αρχείων:

```

1  import json
2  import os
3  import fileinput
4  # Δημιουργία κενής λίστας για να αποθηκεύτουν τα δεδομένα
5  merged_data = []
6
7  # Καθορισμός του φακέλου που περιέχει τα JSON αρχεία
8  folder_path = "C:/Users/User/Desktop/DATA/inference/set 75.70"
9
10 # Επανάληψη μέσα από τα αρχεία στο φάκελο
11 for filename in os.listdir(folder_path):
12     if filename.endswith('.json'):
13         with open(os.path.join(folder_path, filename), 'r') as file:
14             json_data = json.load(file)
15             merged_data.extend(json_data)
16
17 # Αποθήκευση του ενοποιημένου JSON αρχείου
18 output_file = 'C:/Users/User/Desktop/DATA/inference/inference_csi_data.json'
19 with open(output_file, 'w') as file:
20     json.dump(merged_data, file)
21

```

Κώδικας Μορφοποίησης JSON αρχείων:

```

1
2 import fileinput
3 for line in fileinput.input("C:/Users/User/Desktop/DATA/Training Data/TRAIN Week 1 (17.04 - 18.04)/TRAIN 18.04/6th_subset_18_04.json", inplace=True):
4     if 1 != fileinput.filelineno():
5         print('{}'.format(line), end='')
6     else:
7         print('{}'.format(line), end='')
8 open("C:/Users/User/Desktop/DATA/Training Data/TRAIN Week 1 (17.04 - 18.04)/TRAIN 18.04/6th_subset_18_04.json").write('']

```

Κώδικας Διόρθωσης Πεδίων “idx” και “row”:

```

1 import json
2
3 # Διάβαση του JSON αρχείου
4 with open('C:/Users/User/Desktop/DATA/inference/inference_csi_data.json', 'r') as f:
5     data = json.load(f)
6
7 # Αρχικοποίηση του αριθμητή idx
8 idx = 1
9
10 # Αφαίρεση του πεδίου "idx", προσθήκη του νέου πεδίου "idx" και διορθωση του ονόματος "row"
11 for line in data:
12     if "idx" in line:
13         del line["idx"]
14         line["idx"] = idx
15         idx += 1
16     if "row" in line:
17         line["rowr"] = line.pop("row")
18
19 # Αποθήκευση των αλλαγών σε ένα νέο JSON αρχείο
20 with open('C:/Users/User/Desktop/DATA/inference/inference_csi_data.json', 'w') as f:
21     json.dump(data, f)
22
23 # Convert the merged JSON list to a string with new lines
24 output_str = ',\n'.join(json.dumps(item) for item in data)
25
26 # Write the output to a new file
27 with open('C:/Users/User/Desktop/DATA/inference/inference_csi_data.json', "w") as f:
28     f.write('[')
29     f.write(output_str)
30     f.write(']')
31

```


Κώδικας Τιτλοφόρησης CSI Δεδομένων:

```

18     ground_truth_data = sorted(ground_truth_data, key=lambda x: x["Time"])
19     csi_data = sorted(csi_data, key=lambda x: x["datetime"])
20
21     #ΑΠΟΘΗΚΕΥΣΗ timestamps ΣΕ ΠΙΝΑΚΕΣ
22     for i in range(len(ground_truth_data)):
23         if "Time" in ground_truth_data[i]:
24             value = ground_truth_data[i]["Time"]
25             Time[i] = value
26         if "Number of People" in ground_truth_data[i]:
27             cnt = ground_truth_data[i]["Number of People"]
28             Num_of_People[i] = cnt
29
30     for i in range(len(csi_data)):
31         if "datetime" in csi_data[i]:
32             value = csi_data[i]["datetime"]
33             datetime[i] = int(float(value))
34
35     #ΣΥΓΚΡΙΣΗ ΚΑΙ ΤΙΤΛΟΦΟΡΗΣΗ
36     i=0
37     j=0
38     for line in csi_data:
39         if Time[i] >= datetime[j]:
40             line["class"] = Num_of_People[i]
41             j=j+1
42         else:
43             if i > ((len(ground_truth_data)-1)):
44                 break
45             elif i== ((len(ground_truth_data)-1)):
46                 line["class"] = Num_of_People[i]
47                 j=j+1
48             else:
49                 line["class"] = Num_of_People[i]
50                 i=i+1
51

```

Κώδικας GNB:

```

# create classifier
gnb = GaussianNB()

# stratified k-fold cross validation
skf = StratifiedKFold(n_splits=4)

# lists to store accuracy and confusion matrix for each fold
acc_list = []
cm_list = []

# create scaler
scaler = StandardScaler()

# iterate over folds
for train_index, test_index in skf.split(X, y):
    # split data into train and test set
    X_train, X_test = X[train_index], X[test_index]
    y_train, y_test = y[train_index], y[test_index]

    # fit and transform the training data
    X_train = scaler.fit_transform(X_train)

    # transform the testing data
    X_test = scaler.transform(X_test)

    # train classifier
    gnb.fit(X_train, y_train)

    # predict labels for test set
    y_pred = gnb.predict(X_test)

    # calculate accuracy and confusion matrix

    acc = accuracy_score(y_test, y_pred)
    cm = confusion_matrix(y_test, y_pred)

    # append accuracy and confusion matrix to lists
    acc_list.append(acc)
    cm_list.append(cm)

# print mean accuracy and mean confusion matrix
print(np.mean(acc_list))
print(np.mean(cm_list, axis=0))

```

Κώδικας XGBoost:

```
# create classifier
xgb = xgboost.XGBClassifier()

# stratified k-fold cross validation
skf = StratifiedKFold(n_splits=3)

# lists to store accuracy and confusion matrix for each fold
acc_list = []
cm_list = []

# create scaler
scaler = StandardScaler()

# iterate over folds
for train_index, test_index in skf.split(X, y):
    # split data into train and test set
    X_train, X_test = X[train_index], X[test_index]
    y_train, y_test = y[train_index], y[test_index]

    # fit and transform the training data
    X_train = scaler.fit_transform(X_train)

    # transform the testing data
    X_test = scaler.transform(X_test)

    # train classifier
    xgb.fit(X_train, y_train)

    # predict labels for test set
    y_pred = xgb.predict(X_test)

    # calculate accuracy and confusion matrix

    acc = accuracy_score(y_test, y_pred)
    cm = confusion_matrix(y_test, y_pred)

    # append accuracy and confusion matrix to lists
    acc_list.append(acc)
    cm_list.append(cm)

# print mean accuracy and mean confusion matrix
print(np.mean(acc_list))
print(np.mean(cm_list, axis=0))
```

Κώδικας LightGBM:

```

# assume we have a dataset X with labels y
X_train, X_test1, y_train, y_test1 = train_test_split(X, y, test_size=0.2, random_state=42)
# use variance threshold to remove features with low variances and scale the data
variance_threshold = VarianceThreshold(threshold=np.median(np.var(X_train, axis=0)))
scaler = StandardScaler()
# only fit train data and then transform all
for transformer in (scaler, variance_threshold):
    X_train = transformer.fit_transform(X_train)
    X_test1 = transformer.transform(X_test1)

# create a LightGBM classifier
clf = lgb.LGBMClassifier(class_weight= 'balanced')

# define search parameters
param_dist = {
    'num_leaves': list(range(30, 50)),
    'min_data_in_leaf': [30, 40],
    'max_depth': [int(x) for x in np.linspace(10, 50, num = 5)],
    'learning_rate': [0.01, 0.05, 0.1],
    'min_child_samples': list(range(100, 200, 20)),
    'boosting': ['gbdt'], 'objective': ['multiclass'], 'metric': ['multi_logloss'], 'num_class': [3],
    'feature_fraction': [0.6, 0.8], 'bagging_fraction': [0.8, 1.0],
    'bagging_freq': list(range(20, 30)),
    'subsample': [0.6, 0.8, 1.0], 'colsample_bytree': [0.6, 0.8, 1.0],
    'reg_alpha': [0, 1], 'reg_lambda': [1, 2],
}

# create randomized search 5-fold cross validation and 100 iterations
clf_cv = RandomizedSearchCV(clf, param_distributions = param_dist, n_iter = 25, scoring = 'f1_macro', n_jobs = -1, cv = 2, verbose = 3)
# fit model
clf_cv.fit(X_train, y_train)
# view best hyperparameters
print('Best Score:', clf_cv.best_score_)
print('Best Parameters:', clf_cv.best_params_)

# use the best estimator to make predictions
y_pred = clf_cv.best_estimator_.predict(X_test1)

# calculate accuracy and confusion matrix
acc_lgbm = accuracy_score(y_test1, y_pred)
cm = confusion_matrix(y_test1, y_pred)
# print accuracy and confusion matrix
print(acc_lgbm)
print(cm)

```

Κώδικας FNN:

```

input_shape = (X_train.shape[1],)
output_shape = len(np.unique(y_train))

# create the model
model = Sequential([
    Dense(256, input_shape=input_shape, activation='relu'),
    #BatchNormalization(),
    Dropout(0.4),
    Dense(128, activation='relu'),
    #BatchNormalization(),
    Dropout(0.3),
    Dense(64, activation='relu'),
    #BatchNormalization(),
    Dropout(0.2),
    Dense(output_shape, activation='softmax')
])

model.compile(loss='sparse_categorical_crossentropy', optimizer=Adam(), metrics=['accuracy'])

early_stopping = EarlyStopping(monitor='val_loss', patience=20, verbose=1, restore_best_weights=True)

# fit the model using the training and validation data
history = model.fit(X_train, y_train, epochs=500, validation_data=(X_val, y_val), batch_size=512, callbacks=[early_stopping])

# evaluate the model using the test data
y_pred = np.argmax(model.predict(X_test1), axis=-1)
test_loss, test_accuracy = model.evaluate(X_test1, y_test1)
print(f"Test accuracy: {test_accuracy}")

# retrieve the training and validation loss and accuracy
train_loss = history.history['loss']
train_accuracy = history.history['accuracy']
val_loss = history.history['val_loss']
val_accuracy = history.history['val_accuracy']

```

```

# generate the confusion matrix
cm = confusion_matrix(y_test1.astype(int), y_pred.astype(int))

# plot the confusion matrix using Matplotlib
plt.figure(figsize=(8, 6))
plt.imshow(cm, interpolation='nearest', cmap=plt.cm.Blues)
plt.title('Confusion Matrix')
plt.colorbar()

classes = np.unique(y_test)
tick_marks = np.arange(len(classes))
plt.xticks(tick_marks, classes, rotation=45)
plt.yticks(tick_marks, classes)

fmt = 'd'
thresh = cm.max() / 2.
for i in range(cm.shape[0]):
    for j in range(cm.shape[1]):
        plt.text(j, i, format(cm[i, j], fmt),
                 horizontalalignment='center',
                 color='white' if cm[i, j] > thresh else 'black')

plt.ylabel('True label')
plt.xlabel('Predicted label')
plt.tight_layout()
plt.show()

```

Κώδικας Μετά- Μοντέλου FNN:

```

# Define the meta-model architecture
meta_model = Sequential()
meta_model.add(Dense(256, input_shape=input_shape, activation='relu'))
meta_model.add(Dropout(0.3))
meta_model.add(Dense(128, activation='relu'))
meta_model.add(Dropout(0.2))
meta_model.add(Dense(output_shape, activation='softmax'))

early_stopping = EarlyStopping(monitor='val_loss', patience=20, verbose=1, restore_best_weights=True)

# Compile the meta-model
meta_model.compile(optimizer=Adam(), loss='sparse_categorical_crossentropy', metrics=['accuracy'])

# Train the meta-model
meta_history = meta_model.fit(X_train, y_train_final, epochs=500,
                             validation_data=(X_val, y_val_final), batch_size=512, callbacks=[early_stopping])

# Evaluate the meta-model
meta_loss, meta_accuracy = meta_model.evaluate(X_val, y_val_final)
print(f"Meta-model performance: loss={meta_loss:.4f}, accuracy={meta_accuracy:.4f}")

# Use the trained meta-model to make predictions on the test set
y_test1_pred = meta_model.predict(X_test1)

# Convert the predicted probabilities to class labels
y_test1_pred_class = pd.DataFrame(np.argmax(y_test1_pred, axis=1))

# Evaluate the performance of the meta-model on the test set
test_loss, test_accuracy = meta_model.evaluate(y_test1_pred_class, y_test1_final)
print(f"Meta-model performance on test set: loss={test_loss:.4f}, accuracy={test_accuracy:.4f}")

```

Παράρτημα Β: Πίνακες

Πίνακας 1.1: Ζώνες Συχνοτήτων κατά IEEE		
Ζώνη	Περιοχή Συχνοτήτων	Προέλευση Ονομασίας
HF Band	3 - 30 MHz	High Frequency
VHF Band	30 - 300 MHz	Very High Frequency
UHF Band	300 - 1000 MHz	Ultra High Frequency
L Band	1 - 2 GHz	Long Wave
S Band	2 - 4 GHz	Short Wave
C Band	4 - 8 GHz	Compromise ανάμεσα σε S και X
X Band	8 - 12 GHz	Χρησιμοποιήθηκε στο Β' Παγκόσμιο για σήματα ελέγχου πυρός
K _u Band	12 - 18 GHz	Kurz - under
K Band	18 - 27 GHz	Kurz (Βραχύς στα Γερμανικά)
K _a Band	27 - 40 GHz	Kurz - above
V Band	40 - 75 GHz	
W Band	75 - 110 GHz	Το W ακολουθεί το V στο αγγλικό αλφάβητο
mm Band	110 - 300 GHz	Χιλιοστομετρικά κύματα

Πίνακας 1.2: Ζώνες Συχνοτήτων κατά ITU				
Ονομασία	Αρχικά	Συχνότητα	Μήκος Κύματος	Εφαρμογές
Εξαιρετικά Χαμηλή Συχνότητα	ELF (Extremely Low Frequency)	3-30 Hz	10 ⁴ - 10 ⁵ km	Αντιλυπό ως ήχος αν μεατραπεί σε μηχανική ταλάντωση
Υπερ-Χαμηλή Συχνότητα	SLF (Super Low Frequency)	30-300 Hz	10 ³ - 10 ⁴ km	Ηλεκτρικά Δίκτυα Διανομής, Τηλεπικοινωνίες Υποβρυχίων
Κατ'εξοχήν Χαμηλή Συχνότητα	ULF (Ultra Low Frequency)	300-3000 Hz	10 ² - 10 ³ km	Τηλεπικοινωνίες σε Ορυχεία
Πολύ Χαμηλή Συχνότητα	VLF (Very Low Frequency)	3-30 kHz	10 - 10 ² km	Τηλεπικοινωνίες Υποβρυχίων
Χαμηλή Συχνότητα	LF (Low Frequency)	30-300 kHz	1 - 10 km	Ραδιοφωνικές Μεταδόσεις AM, Ραδιοφάροι (NDB), ερασιτεχνικά Walkie-Talkie
Μέση Συχνότητα	MF (Medium Frequency)	300-3000 kHz	10 ² - 10 ³ m	Ραδιοσυστήματα Πλοήγησης (NDB), Ραδιοφωνικές μεταδόσεις AM, Τηλεπικοινωνίες σε Ναυτηλία και Αεροναυτηλία

Υψηλή Συχνότητα	HF (High Frequency)	3-30 MHz	10 - 10 ² m	Βραχεία (Ραδιόφωνο), Ερασιτεχνικές Ραδιοεκπομπές, Walkie-Talkie
Πολύ Υψηλή Συχνότητα	VHF (Very High Frequency)	30-300 MHz	1 - 10 m	Ραδιοφωνικές Μεταδόσεις FM, Τηλεοπτικές Εκπομπές, Αεροναυπηλία, GPR
Κατ'εξοχήν Υψηλή Συχνότητα	UHF (Ultra High Frequency)	300-3000 MHz	10 - 10 ² cm	Τηλεοπτικές Εκπομπές, Κινητή Τηλεφωνία, Ασύρματα Τηλέφωνα, Ασύρματα Δίκτυα Η/Υ, Αυτόματες Κλειδαριές Αυτοκινήτων, Φούρνοι Μικροκυμάτων, GPR
Υπερ-Υψηλή Συχνότητα	SHF (Super High Frequency)	3-30 GHz	1 - 10 cm	Ασύρματα Δίκτυα, Δορυφορικές Συνδέσεις, Δορυφορική Τηλεόραση, Πόρτες Γκαράζ
Εξαιρετικά Υψηλή Συχνότητα	EHF (Extreme High Frequency)	30-300 GHz	1 - 10 mm	Ραδιοτηλεσκόπια, Τηλεσκόπηση, Οπτικά Συστήματα, Ανιχνευτές/Συστήματα Ασφαλείας