



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ
ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

**Συγκριτική Μελέτη Αλγορίθμων Μηχανικής Μάθησης (ML)
για τη Δυναμική Ανάθεση Ραδιοπόρων σε Κυψελωτά Δίκτυα
Επόμενης Γενιάς (5G and Beyond)**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Δημήτριος, Μ. Παπαγιάννης

Επιβλέπων : Δήμητρα – Θεοδώρα Ι. Κακλαμάνη
Καθηγήτρια ΕΜΠ

Αθήνα , Ιούλιος 2024



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ
ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Συγκριτική Μελέτη Αλγορίθμων Μηχανικής Μάθησης (ML) για τη Δυναμική Ανάθεση Ραδιοπόρων σε Κυψελωτά Δίκτυα Επόμενης Γενιάς (5G and Beyond)

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Δημήτριος, Μ. Παπαγιάννης

Επιβλέπων : Δήμητρα – Θεοδώρα Ι. Κακλαμάνη
Καθηγήτρια ΕΜΠ

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 31^η Μήνα Έτος.

.....
Κακλαμάνη Δήμητρα-Θεοδώρα
Καθηγήτρια ΕΜΠ

.....
Βενιέρης Στ. Ιάκωβος
Καθηγητής ΕΜΠ

.....
Παναγόπουλος Αθανάσιος
Καθηγητής ΕΜΠ

Αθήνα, Ιούλιος 2024

.....
Δημήτριος Μ. Παπαγιάννης

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

Copyright © Δημήτριος Παπαγιάννης, 2024

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

ΠΕΡΙΛΗΨΗ

Τα τελευταία χρόνια έχει συντελεστεί εντυπωσιακή αύξηση του όγκου δεδομένων που διακινούνται στα ασύρματα τηλεπικοινωνιακά δίκτυα, στην οποία σημαντικός παράγοντας είναι η ανάπτυξη των δικτύων επικοινωνιών πέμπτης και επόμενης γενιάς (5G/B5G), ώστε να ικανοποιηθούν οι ανάγκες ολοένα και πιο απαιτητικών εφαρμογών που χρησιμοποιούνται από κινητές συσκευές. Την ίδια στιγμή η Μηχανική Μάθηση έχει ωριμάσει αρκετά και χρησιμοποιείται σε ποικίλες εφαρμογές για την επίλυση σύνθετων προβλημάτων. Ήταν επομένως φυσικό να διερευνηθούν πιθανές εφαρμογές τεχνικών Μηχανικής Μάθησης προς την ανάπτυξη και τη βελτιστοποίηση των κινητών δικτύων επικοινωνιών. Σκοπός της παρούσας εργασίας λοιπόν είναι η εφαρμογή διαφόρων αλγορίθμων Μηχανικής Μάθησης για την ανάθεση και διαχείριση ραδιοπόρων (συχνοτήτων και υποφερόντων) σε κυψελωτά δίκτυα επικοινωνιών νέας γενιάς και, ως εκ τούτου, η συγκριτική αποτίμησή τους.

Πιο συγκεκριμένα, στο *Κεφάλαιο 1* πραγματοποιείται μια αναδρομή της ιστορικής πορείας εξέλιξης των ασύρματων δικτύων επικοινωνιών, καθώς και επισκόπηση των βασικών χαρακτηριστικών κάθε γενιάς, με έμφαση στα δίκτυα 5G/B5G. Στο *Κεφάλαιο 2* παρουσιάζονται οι βασικές αρχές που διέπουν τα ασύρματα τηλεπικοινωνιακά συστήματα, με μια λεπτομερέστερη επισκόπηση των κυψελωτών συστημάτων. Ενώ στο *Κεφάλαιο 3* εισάγονται οι έννοιες της Μηχανικής Μάθησης, με την παρουσίαση της βασικής κατηγοριοποίησης των διαφόρων τύπων μάθησης. Επιπλέον, παρουσιάζεται το θεωρητικό υπόβαθρο και η μαθηματική μοντελοποίηση των αλγορίθμων που χρησιμοποιούνται στην μελέτη του προβλήματος της ανάθεσης ραδιοπόρων (radio resource allocation - RRM) σε δυναμικές τοπολογίες 5G/B5G.

Στο *Κεφάλαιο 4* επικεντρωνόμαστε στην υλοποίηση του κυψελωτού δικτύου που χρησιμοποιήθηκε στα πλαίσια της εργασίας, και στην επιλογή των αλγορίθμων και τεχνικών Μηχανικής Μάθησης που αξιοποιήθηκαν για την ανάθεση των υποφερόντων του δικτύου στους χρήστες. Ιδιαίτερη έμφαση δίνεται στην προεπεξεργασία των δεδομένων που λαμβάνονται από το κυψελωτό δίκτυο, καθώς και στην παραμετροποίηση του συνελκτικού νευρωνικού δικτύου που χρησιμοποιήθηκε.

Τέλος, στο *Κεφάλαιο 5* γίνεται παρουσίαση των αποτελεσμάτων που προέκυψαν, με σύγκριση διαφορετικών συνόλων δεδομένων εισόδου αλλά και παραμετροποίησης των νευρωνικών μας δικτύων. Από κάθε σύγκριση εξάγονται ανάλογα συμπεράσματα, ενώ στο 6^ο κεφάλαιο γίνεται μια σύνοψη των αποτελεσμάτων εξήχθησαν και προτάσεις για μελλοντική μελέτη και προεκτάσεις του θέματος.

ΛΕΞΕΙΣ - ΚΛΕΙΔΙΑ: Ασύρματα Δίκτυα, 5G, B5G, Μηχανική Μάθηση, Κυψελωτά Δίκτυα Επικοινωνιών, Προεπεξεργασία Δεδομένων, Παραμετροποίηση Νευρωνικού Δικτύου, Συνελκτικά Νευρωνικά Δίκτυα, Σύνολα δεδομένων, Ταξινόμηση πολλαπλών ετικετών, Ανάθεση υποφερόντων

ABSTRACT

In recent years, there has been a significant increase in the volume of data transmitted over wireless telecommunication networks, primarily driven by the development of fifth and next-generation communication networks (5G/B5G). These advancements are essential to meet the demands of increasingly sophisticated applications used by mobile devices. Simultaneously, Machine Learning has matured considerably and is now employed in various applications to solve complex problems. Consequently, it was natural to explore potential applications of Machine Learning techniques in the development and optimization of mobile communication networks. The purpose of this study is to apply various Machine Learning algorithms for the allocation and management of radio resources (frequencies and subcarriers) in next-generation cellular communication networks and, consequently, to conduct a comparative evaluation of these algorithms.

Specifically, *Chapter 1* provides a historical overview of the evolution of wireless communication networks and reviews the key characteristics of each generation, with a focus on 5G/B5G networks. *Chapter 2* presents the fundamental principles governing wireless telecommunication systems, with a more detailed overview of cellular systems. *Chapter 3* introduces the concepts of Machine Learning, presenting the basic categorization of different types of learning. Additionally, it presents the theoretical background and mathematical modeling of the algorithms used in the study of the radio resource allocation (RRM) problem in dynamic 5G/B5G topologies.

Chapter 4 focuses on the implementation of the cellular network used in this study and the selection of Machine Learning algorithms and techniques utilized for the allocation of the network's subcarriers to users. Special emphasis is given to the preprocessing of data obtained from the cellular network and the parameterization of the convolutional neural network used. Finally, *Chapter 5* presents the results obtained, comparing different input data sets and the parameterization of our neural networks. Each comparison yields relevant conclusions, and *Chapter 6* provides a summary of the results obtained and suggestions for future study and extensions of the topic.

KEYWORDS: Wireless Networks, 5G, B5G, Machine Learning, Cellular Communication Networks, Data Preprocessing, Neural Network Parameterization, Convolutional Neural Networks, Data Sets, Multi-Label Classification, Subcarrier Allocation

Ευχαριστίες

Η παρούσα διπλωματική εργασία εκπονήθηκε κατά το ακαδημαϊκό έτος 2023-2024 στη σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου. Στο σημείο αυτό, θα ήθελα να εκφράσω τις θερμές και ειλικρινείς ευχαριστίες μου σε όσους συνέβαλαν με την ανεκτίμητη βοήθεια τους στην ολοκλήρωση αυτής της προσπάθειας. Πρώτα από όλα, θα ήθελα να ευχαριστήσω ιδιαίτερα την Καθηγήτρια κα Δήμητρα – Θεοδώρα Κακλαμάνη, η οποία μου έδωσε την ευκαιρία να ασχοληθώ με ένα τόσο ενδιαφέρον θέμα και να διευρύνω τις γνώσεις μου γύρω από αυτόν τον τομέα.

Επίσης ειδικές ευχαριστίες θα ήθελα να δώσω στον Ερευνητή Ηλεκτρολόγο Μηχανικό και Μηχανικό Υπολογιστών, Δρ. Ιωάννη Μπαρτσιώκα, για την πολύτιμη καθοδήγηση, την αδιάλειπτη βοήθεια της, καθώς και για το χρόνο που διέθετε πρόθυμα όποτε και αν χρειαζόταν.

Θα ήθελα ακόμη να ευχαριστήσω όλους τους συμφοιτητές με τους οποίους συμπορεύτηκα και μοιράστηκα εμπειρίες και γνώση καθ'όλη τη διάρκεια των σπουδών μου. Τέλος, μία ιδιαίτερη ευχαριστία για τους γονείς μου, για την αμέριστη στήριξη και συμπαράσταση που έδειξαν και συνεχίζουν να δείχνουν, βοηθώντας με να εκπληρώσω όσα βαθιά επιθυμώ.

Acknowledgements

This thesis was carried out during the academic year 2023-2024 at the School of Electrical and Computer Engineering of the National Technical University of Athens. At this point, I would like to express my warm and sincere thanks to those who contributed with their invaluable assistance to the completion of this effort.

First and foremost, I would like to extend special thanks to Professor Dimitra-Theodora Kaklamani, who gave me the opportunity to work on such an interesting topic and to expand my knowledge in this field.

I also wish to give special thanks to Researcher and Electrical and Computer Engineer, Dr. Ioannis Bartsiokas, for his valuable guidance, unwavering help, and for always willingly providing his time whenever needed.

I would also like to thank all my fellow students with whom I have shared experiences and knowledge throughout my studies. Finally, a special thank you goes to my parents for their unconditional support and encouragement, which has helped me to fulfill my deepest aspirations.

ΠΕΡΙΕΧΟΜΕΝΑ

| | |
|--|----|
| 1. ΕΙΣΑΓΩΓΗ ΣΤΑ ΣΥΣΤΗΜΑΤΑ ΑΣΥΡΜΑΤΩΝ ΕΠΙΚΟΙΝΩΝΙΩΝ | 13 |
| 1.1 Ιστορική ανασκόπηση και παραδείγματα ασύρματων επικοινωνιών | 13 |
| 1.1.1 Δίκτυα WiFi – 802.11..... | 13 |
| 1.1.2 Δίκτυα Προσωπικών Επικοινωνιών..... | 14 |
| 1.2 Κινητά Συστήματα Επικοινωνιών | 16 |
| 1.2.1 Συστήματα 1 ^{ης} Γενιάς..... | 16 |
| 1.2.2 Συστήματα 2 ^{ης} Γενιάς (GSM) | 17 |
| 1.2.3 Συστήματα 3 ^{ης} Γενιάς (UMTS)..... | 19 |
| 1.2.4 Συστήματα 4 ^{ης} Γενιάς (LTE)..... | 20 |
| 1.2.5 Συστήματα 5 ^{ης} και Επόμενης Γενιάς..... | 23 |
| 2. ΒΑΣΙΚΕΣ ΑΡΧΕΣ ΑΣΥΡΜΑΤΩΝ ΚΑΙ ΚΙΝΗΤΩΝ ΕΠΙΚΟΙΝΩΝΙΩΝ | 28 |
| 2.1 Συστήματα Κεραίων και Μοντέλα Διάδοσης | 28 |
| 2.1.1 Εμπειρικά μοντέλα απωλειών διάδοσης | 31 |
| 2.1.2 Διαλείψεις Μεγάλης Κλίμακας και Σκίαση..... | 32 |
| 2.1.3 Διαλείψεις μικρής κλίμακας..... | 33 |
| 2.2 Κυψελωτά συστήματα κινητών Επικοινωνιών | 37 |
| 3. ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ ΚΑΙ ΒΑΘΙΑ ΜΑΘΗΣΗ | 41 |
| 3.1 Η Μηχανική Μάθηση στα πλαίσια της τεχνητής νοημοσύνης | 41 |
| 3.2 Βασικές έννοιες και αρχές Μηχανικής Μάθησης | 44 |
| 3.3 Κατηγοριοποίηση Μηχανικής Μάθησης | 45 |
| 3.4 Αλγόριθμοι Μηχανικής Μάθησης | 48 |
| 3.4.1 Αλγόριθμοι Κοντινότερου Γείτονα (kNN)..... | 48 |
| 3.4.2 Αλγόριθμοι Δέντρων Αποφάσεων..... | 49 |
| 3.5 Νευρωνικά Δίκτυα και Βαθιά Μάθηση | 51 |
| 3.6 Συνελκτικά Νευρωνικά Δίκτυα | 54 |
| 4. ΧΡΗΣΗ ΤΕΧΝΙΚΩΝ ΜΗΧΑΝΙΚΗΣ ΚΑΙ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΓΙΑ ΑΝΑΘΕΣΗ ΡΑΔΙΟΠΥΡΩΝ ΣΕ 5G ΚΥΨΕΛΩΤΟ ΔΙΚΤΥΟ | 57 |
| 4.1 Χαρακτηριστικά προσομοιωμένου 5G Δικτύου | 57 |
| 4.2 Ορισμός προβλήματος στα πλαίσια μηχανικής μάθησης | 59 |
| 4.3 Επιλογή χαρακτηριστικών και προεπεξεργασία δεδομένων | 61 |
| 4.4 Αλγόριθμοι Μηχανικής Μάθησης | 66 |
| 4.4.1 Αλγόριθμος Κοντινότερου Γείτονα | 66 |
| 4.4.2 Αλγόριθμος δάσους από δέντρα CART..... | 67 |
| 4.4.3 Συνελκτικό Νευρωνικό Δίκτυο (CNN)..... | 67 |

| | |
|---|----|
| 5. ΑΠΟΤΕΛΕΣΜΑΤΑ ΠΡΟΣΟΜΟΙΩΣΕΩΝ | 70 |
| 5.1 Συγκριτικά αποτελέσματα αλγορίθμων | 73 |
| 5.2 Αποτελέσματα σύγκρισης παραμετροποίησης συνάρτησης απωλειών (focal loss) | 77 |
| 5.3 Σύγκριση αποτελεσμάτων ανά αριθμό αποδιδόμενων PRBs | 79 |
| 6. ΕΠΙΛΟΓΟΣ | 82 |
| Μελλοντικές επεκτάσεις | 82 |
| ΒΙΒΛΙΟΓΡΑΦΙΑ | 84 |

ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ

| | |
|--|----|
| Εικόνα 1.1 - Αποστολή Πλαισίου με το CSMA/CA [5]..... | 14 |
| Εικόνα 1.2 -Δίκτυο Zigbee τοπολογίας δέντρου [6] | 15 |
| Εικόνα 1.3 - Διαδικασία Μεταπομπής στο GSM [4]..... | 18 |
| Εικόνα 1.4 - Block διάγραμμα CDMA πομποδέκτη [3]..... | 19 |
| Εικόνα 1.5 - Σύστημα Μετάδοσης OFDM [1]..... | 22 |
| Εικόνα 1.6 - Σύστημα μετάδοσης SC-FDMA με προσθήκη DFT , Πηγή [2] | 22 |
| Εικόνα 1.7 - Ζητούμενη Βελτίωση 5G , πηγή: [10] | 24 |
| Εικόνα 1.8 - Περιπτώσεις χρήσης D2D επικοινωνίας..... | 26 |
| Εικόνα 2.9 - Διάγραμμα Ακτινοβολίας , Πηγή [12]..... | 29 |
| Εικόνα 2.10 - Υπέρθυση διαλείψεων μικρής και μεγάλης κλίμακας και σκίασης, [9] | 33 |
| Εικόνα 2.11 - Μετατόπιση Doppler [9]..... | 36 |
| Εικόνα 2.12 - Ομάδες(Clusters) 7 και 3 κυψελών , Implementing Smart Antenna System using Genetic Algorithm and Artificial Immune System..... | 38 |
| Εικόνα 2.13 - Τομεοποίηση 120 μοιρών,πηγή: [8] | 40 |
| Εικόνα 3.14 - Νευρωνικό Δίκτυο με πολλαπλή διαστρωμάτωση..... | 42 |
| Εικόνα 3.15 - Διάγραμμα Venn για τη σχέση μεταξύ AI-ML-DL, πηγή: [15]..... | 43 |
| Εικόνα 3.16 - Γενικευμένη Ροή Συστήματος Μηχανικής Μάθησης , [16] | 44 |
| Εικόνα 3.17 - Χώρος Χαρακτηριστικών 3 διαστάσεων [17]..... | 45 |
| Εικόνα 3.18 - Γραμμικός ταξινομητής για πρόβλημα 2 κλάσεων, [17] | 46 |
| Εικόνα 3.19 - Ομαδοποίηση δεδομένων με χρήση αλγορίθμου clustering, [18]..... | 47 |
| Εικόνα 3.20 - Σφάλμα του kNN σε σχέση με το σφάλμα Bayesian ταξινομητή, [18]..... | 49 |
| Εικόνα 3.21 - Παράδειγμα ταξινόμησης με 2 χαρακτηριστικά και 2 κλάσεις για $k=5$, [18].. | 49 |
| Εικόνα 3.22 - Δυαδικό δέντρο ταξινόμησης φρούτων , [18]..... | 50 |
| Εικόνα 3.23 - Σχηματική Αναπαράσταση Νευρώνα | 52 |
| Εικόνα 3.24 - Σιγμοειδής συνάρτηση για αύξουσες τιμές παραμέτρου κλίσης..... | 53 |
| Εικόνα 3.25 Απεικόνιση φίλτρου συνέλιξης..... | 56 |
| Εικόνα 3.26 Τυπική αρχιτεκτονική CNN δικτύου | 56 |
| Εικόνα 4.27 Κυψελωτό 2-tier δίκτυο με 3 τομείς ανά κυψέλη..... | 58 |
| Εικόνα 4.28 Σενάριο για αστικές μακροκυψέλες από το TR38.901 | 59 |
| Εικόνα 4.29 Απώλειες σε dB για ένα δείγμα 400 χρηστών | 62 |
| Εικόνα 4.30 Εναλλαγή των test folds για την επίτευξη του cross-validation | 65 |
| Εικόνα 5.31 Overfitting με βάση την εξέλιξη του Accuracy..... | 71 |
| Εικόνα 5.32 Overfitting με βάση την εξέλιξη του F1-Score..... | 71 |
| Εικόνα 5.33 Μείωση του overfitting με χρήση $a=0.9$ βάσει του Accuracy..... | 72 |
| Εικόνα 5.34 Μείωση του overfitting με χρήση $a=0.9$ βάσει του F1-Score | 73 |
| Εικόνα 5.35 Συγκριτικά αποτελέσματα Accuracy για διαφορετικούς αλγόριθμους..... | 74 |
| Εικόνα 5.36 Συγκριτικά αποτελέσματα F1-Score για διαφορετικούς αλγόριθμους | 75 |
| Εικόνα 5.37 Σύγκριση αλγορίθμων στο Accuracy, με a priori γνώση | 76 |
| Εικόνα 5.38 Σύγκριση αλγορίθμων στο F1-Score, με a priori γνώση..... | 76 |
| Εικόνα 5.39 Αποτελέσματα CNN για διαφορετική παραμετροποίηση συνάρτησης απωλειών | 77 |
| Εικόνα 5.40 Αποτελέσματα CNN για διαφορετική παραμετροποίηση συνάρτησης απωλειών με prior γνώση..... | 78 |
| Εικόνα 5.41 Αποτελέσματα με επιλογή ML ακολουθίας PRBs | 78 |

| | |
|---|----|
| Εικόνα 5.42 Σύγκριση αποτελεσμάτων Accuracy για υποσύνολα χρηστών με διαφορετικό αριθμό PRBs | 80 |
| Εικόνα 5.43 Σύγκριση αποτελεσμάτων F1-Score για υποσύνολα χρηστών με διαφορετικό αριθμό PRBs | 80 |

ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ

| | |
|--|----|
| Πίνακας 1 : Αποτελέσματα χωρίς prior γνώση αριθμού PRBs/χρήστη | 79 |
| Πίνακας 2: Αποτελέσματα με prior γνώση αριθμού PRBs/χρήστη | 79 |
| Πίνακας 3 : Αποτελέσματα με επιλογή ML ακολουθίας..... | 79 |

1. ΕΙΣΑΓΩΓΗ ΣΤΑ ΣΥΣΤΗΜΑΤΑ ΑΣΥΡΜΑΤΩΝ ΕΠΙΚΟΙΝΩΝΙΩΝ

1.1 Ιστορική ανασκόπηση και παραδείγματα ασύρματων επικοινωνιών

Τα πρώτα δίκτυα ασύρματων επικοινωνιών είχαν ήδη αναπτυχθεί πριν την εποχή της Βιομηχανικής Επανάστασης. Τα συστήματα αυτά μετέδιδαν την επιθυμητή πληροφορία σε απόσταση οπτικής επαφής (LOS, Line of Sight), με μια ποικιλία μέσων τα οποία περιλαμβάνουν σήματα καπνού, σηματοδότηση με πυρσούς, σήματα από εκλάμψεις και άλλα. Για αυτού του τύπου την επικοινωνία, αναπτύχθηκαν λεπτομερή σύνολα από συνδυασμούς σημάτων ή συμβόλων, ώστε να είναι δυνατή η μεταβίβαση περίπλοκων μηνυμάτων παρά τα στοιχειώδη σήματα που υπήρχαν διαθέσιμα. Τα δίκτυα αυτά αντικαταστάθηκαν αρχικά από τον τηλεγράφο, που εφευρέθηκε από τον Samuel Morse το 1838, και στη συνέχεια από την επικοινωνία μέσω τηλεφώνου. Το 1895, αρκετές δεκαετίες μετά την εφεύρεση του τηλεφώνου, ο Marconi έκανε για πρώτη φορά επίδειξη ραδιομετάδοσης σε απόσταση 18 μιλίων, και κάπως έτσι γεννήθηκαν και άρχισαν να αναπτύσσονται οι ασύρματες επικοινωνίες της σύγχρονης εποχής. Οι αποστάσεις μετάδοσης αυξήθηκαν με γρήγορους ρυθμούς, ενώ ταυτόχρονα βελτιώθηκε σημαντικά και η ποιότητα, μειώθηκε η απαιτούμενη ισχύς, και οι συσκευές εκπομπής και ιδιαίτερα λήψης έγιναν ολοένα και φθηνότερες, όπως επίσης και μικρότερες σε μέγεθος, με αποτέλεσμα οι ασύρματες επικοινωνίες να γίνονται ολοένα και πιο ελκυστικές στο ευρύτερο κοινό. Η κινητή τηλεφωνία τις τελευταίες δεκαετίες ειδικότερα έχει αναπτυχθεί ταχύτατα και έχει μπει πλέον για τα καλά στη ζωή μας, μια εξέλιξη που οφείλεται σε μεγάλο βαθμό στην εκρηκτική αύξηση των ρυθμών μετάδοσης που επιτρέπει την πρόσβαση σε ολοένα και πιο ενδιαφέρουσες λειτουργίες και εφαρμογές.

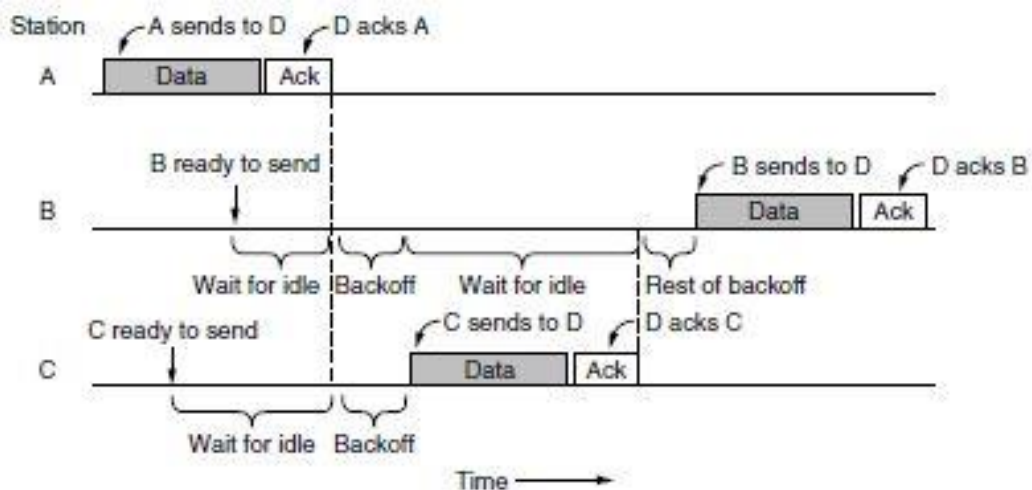
Τα πρώιμα ραδιοσυστήματα λειτουργούσαν με αναλογικό σήμα, το οποίο αργότερα κατά τις προηγούμενες δεκαετίες αντικαταστάθηκε με ψηφιακό σήμα, το οποίο αποτελείται από συνδυασμούς δυαδικών ψηφίων. Το ψηφιακό σήμα μεταδίδεται ως μια συνεχής ροή ψηφίων ή εναλλακτικά με τη μορφή πακέτων. Στη δεύτερη περίπτωση η μετάδοση πληροφορίας συμβαίνει σε ριπές, δηλαδή το κανάλι παραμένει (σχεδόν) αδρανές, εκτός από όταν συμβαίνει η μετάδοση πακέτου. Ο δεύτερος τρόπος είναι και ο επικρατέστερος, ιδιαίτερα στις περισσότερες σύγχρονες εμπορικές εφαρμογές.

1.1.1 Δίκτυα WiFi – 802.11

Μία από τις σημαντικότερες ασύρματες τεχνολογίες στις μέρες μας είναι τα ασύρματα δίκτυα LAN, που είναι ευρέως γνωστά με την ονομασία Wifi, σύμφωνα με το πρότυπο 802.11. Τα δίκτυα Wifi έχουν πολλές χρήσεις, με τη σημαντικότερη να είναι η σύνδεση φορητών υπολογιστών, αλλά πλέον και περισσότερων συσκευών οι

οποίες ονομάζονται συνήθως έξυπνες συσκευές, στο διαδίκτυο χωρίς να απαιτείται ενσύρματη σύνδεση με χρήση καλωδίου. Τα δίκτυα αυτά περιλαμβάνουν τους χρήστες, των οποίων οι συσκευές περιλαμβάνουν φορητούς υπολογιστές, κινητά τηλέφωνα, έξυπνες τηλεοράσεις και άλλες ηλεκτρονικές συσκευές, και από την δικτυακή υποδομή, η οποία συνήθως ονοματίζεται ως σημεία πρόσβασης (Access Points, APs). Τα σημεία πρόσβασης, στην πιο κοινή περίπτωση το γνωστό μας ρούτερ, έχουν πρόσβαση στο δίκτυο κορμού που αποτελείται από οπτική ίνα ή/και χαλκό, και μέσω αυτών οι χρήστες τελικά αποκτούν πρόσβαση στο διαδίκτυο. Υπάρχει όμως και μια διαφορετική, σπανιότερη περίπτωση, αυτή των ad-hoc δικτύων, στα οποία οι χρήστες μπορούν να επικοινωνήσουν μεταξύ τους χωρίς τη διαμεσολάβηση σημείου πρόσβασης.

Από δικτυακής άποψης, το Wifi στηρίζεται στο εξής πρωτόκολλο προσπέλασης μέσου, το CSMA/CA (δηλαδή αποφυγή συγκρούσεων). Ο κάθε σταθμός που θέλει να επικοινωνήσει με το υπόλοιπο δίκτυο αρχικά στέλνει ένα σύντομο αναγνωριστικό πλαίσιο, με το οποίο ανιχνεύει αν μπορεί να ξεκινήσει τη μετάδοση, το οποίο γίνεται μόνο όταν το κανάλι δεν είναι δεσμευμένο από άλλους χρήστες. Σε διαφορετική περίπτωση, θα χρησιμοποιήσει την τεχνική της εκθετικής οπισθοδρόμησης (exponential backoff), και θα δοκιμάσει να ξαναστείλει αργότερα, το οποίο μπορεί και να επαναληφθεί με αυξανόμενα διαστήματα αναμονής. Καθώς στο ασύρματο κανάλι δεν μπορούν να ανιχνευθούν όλες οι συγκρούσεις, εν μέρει λόγω του προβλήματος του κρυμμένου τερματικού (hidden terminal), γίνεται προσπάθεια αυτές να αποφεύγονται, χρησιμοποιώντας τυχαία διαστήματα αναμονής για κάθε χρήστη καθώς και δέσμευση του καναλιού από τον εκάστοτε χρήστη που το χρησιμοποιεί, ώστε να ολοκληρώνεται η επιτυχημένη μετάδοση των πλαισίων. Ακόμη και στην περίπτωση σύγκρουσης, τα πλαίσια δέσμευσης είναι σύντομα και επομένως μειώνεται το κόστος της [5].

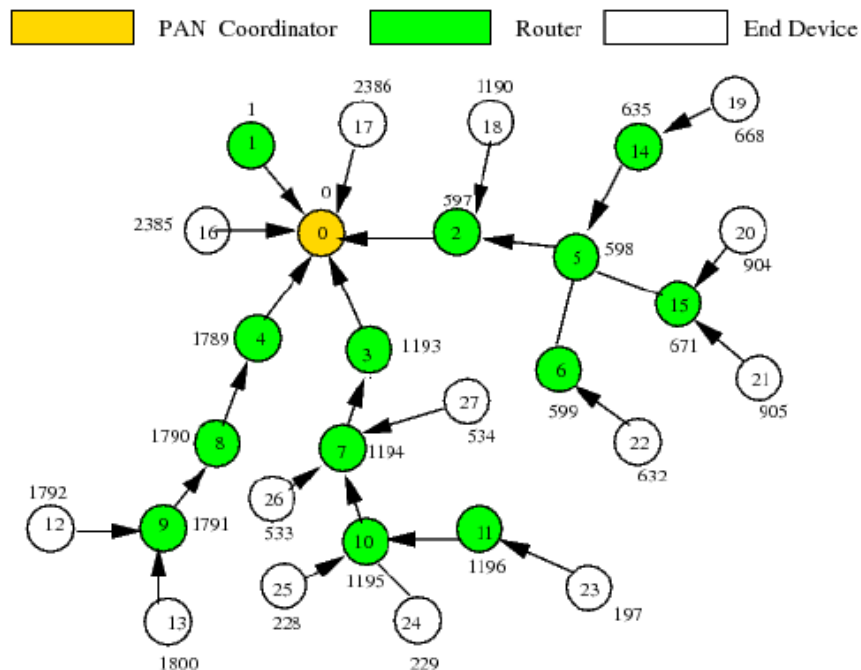


Εικόνα 1.1 - Αποστολή Πλαισίου με το CSMA/CA [5]

1.1.2 Δίκτυα Προσωπικών Επικοινωνιών

Μία άλλη ιδιαίτερη κατηγορία ασύρματων δικτύων είναι τα δίκτυα προσωπικής περιοχής (PAN, Personal Area Networks). Το πιο γνωστό είναι το Bluetooth, ωστόσο υπάρχουν και όπως περιπτώσεις όπως π.χ. το Zigbee. Τα δίκτυα αυτά έχουν ως στόχο τη μετάδοση πληροφορίας σε πολύ μικρές αποστάσεις, συνήθως μικρότερες των 10 μέτρων. Ουσιαστικά πρόκειται για μια τεχνολογία αντικατάστασης καλωδίων, με κύριο πλεονέκτημα το χαμηλό κόστος και χαμηλή κατανάλωση ισχύος, που αντισταθμίζουν τη μειωμένη εμβέλεια. Τα δίκτυα αυτά είναι συνήθως ad-hoc, δεν χρειάζεται δηλαδή σημείο πρόσβασης όπως στο Wifi, επομένως οι συσκευές επικοινωνούν μεταξύ όπως χωρίς να απαιτείται κάποια διαμεσολάβηση. Παρόλ'αυτά μία συσκευή τυπικά αναλαμβάνει το ρόλο του «κύριου» κόμβου του δικτύου και αναλαμβάνει το συγχρονισμό μεταξύ των υπολοίπων.

Εκτός από την επικοινωνία σε πολύ μικρές αποστάσεις, αυτά τα δίκτυα είναι κατάλληλα και για περιπτώσεις δικτύων αισθητήρων λόγω της μικρής κατανάλωσης ισχύος και πόρων, στο οποίο συμβάλλει και η ευχέρεια να βρίσκονται οι συσκευές σε κατάσταση αναμονής (εξοικονόμησης ενέργειας). Άλλα πλεονεκτήματα είναι : η μεγάλη ανεκτικότητα σε παρεμβολές από γειτονικά κανάλια(ACI), η μεγάλη διάρκεια ζωής μπαταρίας και η δυνατότητα αυτορύθμισης που συμβάλλει στη ικανοποίηση του χρήστη, ειδικά από τη στιγμή που αυτού του τύπου τα δίκτυα είναι κατάλληλα για εφαρμογές στην καθημερινότητα, αλλά και σε τομείς όπως π.χ. η ιατρική παρακολούθηση ασθενών. [6]



Εικόνα 1.2-Δίκτυο Zigbee τοπολογίας δέντρου [6]

1.2 Κινητά Συστήματα Επικοινωνιών

Αλλά φυσικά η σημαντικότερη περίπτωση ασύρματων επικοινωνιών είναι η κινητή τηλεφωνία, βασιζόμενη σε κυψελωτά συστήματα, με την οποία και θα ασχοληθούμε στην παρούσα εργασία. Τα κυψελωτά συστήματα λύνουν το πρόβλημα του περιορισμένου εύρους ζώνης στην ασύρματη μετάδοση, εκμεταλλευόμενα το γεγονός της ταχείας χωρικής απόσβεσης του σήματος, με αποτέλεσμα τη δυνατότητα πολλαπλών χρηστών να λειτουργούν στην ίδια συχνότητα, εφόσον βρίσκονται σε επαρκώς μεγάλη απόσταση μεταξύ τους.

Τα κινητά τηλέφωνα πρώτης γενιάς ήταν αναλογικά, μετέδιδαν μόνο δεδομένα φωνής και γενικότερα είχαν πολύ περιορισμένες δυνατότητες σε σχέση με μεταγενέστερα συστήματα, καθώς υπήρχαν ακόμη σημαντικοί περιορισμοί όσον αφορά το υλικό που χρησιμοποιούνταν, αλλά και οι διαθέσιμοι αλγόριθμοι αξιοποίησης του διαθέσιμου εύρους ζώνης ήταν ακόμη απλοϊκοί και σίγουρα όχι ιδιαίτερα αποτελεσματικοί. Αυτό όμως άλλαξε στη συνέχεια τη δεκαετία του 80, όταν και χρησιμοποιήθηκε για πρώτη φορά η ιδέα της επαναχρησιμοποίησης συχνότητας, με τη χρήση κυψελωτών συστημάτων. Η βασική ιδέα είναι η χρήση σχετικά μικρών (γεωγραφικά) κυψελών, με τη συχνότητα μιας κυψέλης να χρησιμοποιείται και σε κοντινές της κυψέλες, αρκεί να μην προκαλούνται παρεμβολές επώδυνες για την ποιότητα τους σήματος. Το δεύτερο κομβικό πλεονέκτημα με την μείωση του μεγέθους των κυψελών, είναι η μειωμένη απαιτούμενη ισχύς τόσο για τους σταθμούς βάσης αλλά και για τα τερματικά των χρηστών, που έχει ως αποτέλεσμα τη μείωση του κόστους και έχει συντελέσει ιδιαίτερα στην τεράστια εμπορική επιτυχία της κινητής τηλεφωνίας τις 3 τελευταίες δεκαετίες.

1.2.1 Συστήματα 1^{ης} Γενιάς

Σχετικά με τα συστήματα 1^{ης} γενιάς, αξίζει να αναφερθεί ότι αρχικά βασίστηκαν στο IMTS (Improved Mobile Telephone System, Βελτιωμένο Σύστημα Κινητής Επικοινωνίας), το οποίο χρησιμοποιούσε κεραία πομπού με υψηλή ισχύ στην κορυφή ενός λόφου, με χρήση δύο διαφορετικών συχνοτήτων για αποστολή και λήψη. Με τον τρόπο αυτό αντιμετωπίζονταν οι παρεμβολές μεταξύ εισερχόμενων και εξερχόμενων σημάτων φωνής. Το IMTS αξιοποιούσε το φάσμα από 150 μέχρι 450 MHz, και λόγω του μικρού αριθμού διαθέσιμων καναλιών, ο χρόνος αναμονής των χρηστών πριν κάθε κλήση ήταν ιδιαίτερα υψηλός, ενώ και η μεγάλη ισχύς που χρησιμοποιούσε η κεραία σταθμού βάσης οδηγούσε σε παρεμβολές για κοντινές αποστάσεις. Σαν αποτέλεσμα η χωρητικότητα του συστήματος ήταν σχετικά χαμηλή.

Αυτό όμως άλλαξε με το AMPS (Advanced Mobile Phone System, Προηγμένο Σύστημα Κινητής Τηλεφωνίας), το οποίο χρησιμοποιούσε την τεχνική επαναχρησιμοποίησης συχνότητας που προαναφέρθηκε. Με την τεχνική αυτή η χωρητικότητα του συστήματος πολλαπλασιάστηκε, καθώς στην ίδια περιοχή μπορούσαν να είναι ενεργές περισσότερες από μία κεραίες, οι οποίες λειτουργώντας σε διαφορετικές συχνότητες μπορούσαν να εξυπηρετούν κατά πολύ μεγαλύτερο

αριθμό χρηστών. Αξίζει επίσης να αναφερθεί ότι εκτός από την αύξηση της χωρητικότητας, με το μικρότερο μέγεθος των κυψελών και επομένως τη μείωση της εκπεμπόμενης ισχύος, μειώθηκε ταυτόχρονα και το κόστος του υλικού τόσο για τους πομπούς και, σημαντικότερα, για τους δέκτες. [5]

Το βασικό χαρακτηριστικό κάθε κυψέλης είναι ο σταθμός βάσης που βρίσκεται προσεγγιστικά στο κέντρο της, ο οποίος ουσιαστικά είναι μια κεραία και ένας υπολογιστής. Οι σταθμοί βάσης συνολικά συνδέονται σε μια κεντρική συσκευή που ονομάζεται MTSO (Mobile Telephone Switching Office, Κέντρο Μεταγωγής Κινητής Τηλεφωνίας). Αυτό είναι τερματικό κέντρο που επικοινωνεί με τους σταθμούς βάσης. Όταν ένα κινητό τηλέφωνο μετακινείται από την γεωγραφική περιοχή μιας κυψέλης σε μια άλλη, τότε ο έλεγχος μεταφέρεται στην κυψέλη που λαμβάνει το ισχυρότερο σήμα από το τερματικό του χρήστη. Η μεταφορά αυτή του κινητού σε διαφορετική κυψέλη ονομάζεται μεταβίβαση (handoff), και η εκ νέου εκχώρηση φάσματος στον χρήστη πραγματοποιείται από το MTSO, που αποτελεί σε αυτήν την περίπτωση τον «εγκέφαλο» του συστήματος.

1.2.2 Συστήματα 2^{ης} Γενιάς (GSM)


Η 2^η Γενιά κινητών επικοινωνιών ήταν σαφώς εκείνη με την οποία η κινητή τηλεφωνία γνώρισε αξιοσημείωτη διείσδυση από εμπορικής πλευράς σε ολόκληρο τον κόσμο. Χρησιμοποιήθηκε πλέον ψηφιακό σήμα, σε αντίθεση με το αναλογικό της 1^{ης} γενιάς, το οποίο σε συνδυασμό με την ραγδαία ανάπτυξη των ψηφιακών υπολογιστών και της ψηφιακής επεξεργασίας σήματος, προσέφερε σημαντικές βελτιώσεις, όπως τη συμπίεση των σημάτων φωνής αλλά και την μετάδοση ψηφιακών δεδομένων, που επέτρεψε την μετάδοση μηνυμάτων κειμένου (SMS, Short Message Service). Το σημαντικότερο πρότυπο που αναπτύχθηκε είναι το GSM (Global System for Mobile Communication, Παγκόσμιο Σύστημα Κινητών Επικοινωνιών) και μέχρι το 2004 είχε περισσότερους από 1 δισεκατομμύριο συνδρομητές σε όλο τον κόσμο. Άλλες υπηρεσίες που έγιναν διαθέσιμες με το GSM ήταν η υπηρεσία αυτόματου τηλεφωνητή, η διαχείριση εισερχόμενων κλήσεων και η επικοινωνία δεδομένων, η οποία φυσικά αναπτύχθηκε πολύ περισσότερο σε μεταγενέστερα συστήματα.

Το πρότυπο GSM χρησιμοποιεί έναν συνδυασμό FDMA (Frequency Division Multiple Access, Πολλαπλή Πρόσβαση Διαίρεσης Συχνότητας) και TDMA (Time Division Multiple Access, Πολλαπλή Πρόσβαση Διαίρεσης Χρόνου) για την πρόσβαση των χρηστών στο δίκτυο (Multiple Access, Πολλαπλή Πρόσβαση). Με την FDMA το κανάλι διαιρείται σε έναν αριθμό ζωνών συχνοτήτων, και απαιτούνται ζωνοπερατά φίλτρα καθώς και διαστήματα φύλαξης μεταξύ των υπο-καναλιών του διαύλου. Κάθε δίαυλος έχει μια κεντρική φέρουσα συχνότητα, και κάθε ένα από τα διαθέσιμα φέροντα έχουν έναν μοναδικό αριθμό που καλείται ARFCN (Absolute Radio Frequency Channel Number). Κάθε ένα από αυτά τα φέροντα όμως διαιρείται σε 8 χρονικά GSM κανάλια, τα οποία χρησιμοποιούνται με προκαθορισμένη χρονική σειρά. Τα δεδομένα μεταδίδονται σε ριπές, με ρυθμό μετάδοσης 271 kbps για κάθε κανάλι. Τελικά ο συνολικός αριθμός κλήσεων που μπορούν να εξυπηρετηθούν ισούται με το γινόμενο των ζωνών συχνοτήτων και των χρονικών θυρίδων. [5]

Έχει ενδιαφέρον να εξετάσουμε με περισσότερες λεπτομέρειες την διαδικασία της μεταπομπής στο GSM. Η μεταπομπή έχει ως αποτέλεσμα όχι μόνο τη μετάδοση τους σήματος από/προς ένα νέο σταθμό βάσης, αλλά και την αναδρομολόγηση της κλήσης που βρίσκεται σε εξέλιξη από ένα σημείο μεταγωγής στο νέο σταθμό βάσης. Κατά τη σύνδεση ενός κινητού τερματικού με ένα σταθμό βάσης, πραγματοποιούνται μετρήσεις ισχύος απ'τον τρέχοντα σταθμό βάσης καθώς και από άλλους κοντινούς σταθμούς βάσης. Οι μετρήσεις αυτές πραγματοποιούνται μέσω σήματος ραδιοφάρου.

Κατά τη διαδικασία της μεταπομπής ακολουθούνται τα εξής βήματα:

- Ενημερώνεται το MTSO από τον παλιό σταθμό βάσης ότι πρόκειται να γίνει μεταπομπή.
- Ενημερώνεται ο νέος σταθμός βάσης από το MTSO
- Ο νέος σταθμός βάσης δεσμεύει τους απαιτούμενους πόρους, δηλαδή ασύρματο δίαυλο.
- Ο νέος σταθμός ενημερώνει τον παλιό σταθμό και το MTSO, ότι το κινητό πρέπει να πληροφορηθεί για τη μεταπομπή, καθώς και τις πληροφορίες που θα χρειαστεί το κινητό για τη συσχέτιση με το νέο σταθμό
- Το κινητό πληροφορείται για τη μεταπομπή
- Το κινητό και ο νέος σταθμός ανταλλάσσουν τα απαραίτητα μηνύματα για την ενεργοποίηση της νέας σύνδεσης.
- Το κινητό στέλνει πλήρες μήνυμα μεταπομπής, που προωθείται στο MTSO, το οποίο αναδρομολογεί κατάλληλα την κλήση μέσω του νέου σταθμού βάσης
- Αποδεσμεύονται οι πόροι από τον παλιό σταθμό βάσης.




Εικόνα 1.3 - Διαδικασία Μεταπομπής στο GSM [4]

Να σημειωθεί εδώ ότι σε περίπτωση που εμπλέκονται περισσότερα από ένα MTSO, τότε χρησιμοποιούνται ενδιάμεσα κέντρα μεταγωγής που μεταδίδουν τις απαραίτητες πληροφορίες για τη μεταπομπή μεταξύ των εμπλεκόμενων κέντρων, τα οποία ανήκουν ουσιαστικά σε ανώτερο επίπεδο διαστρωμάτωσης και μπορούν να εκτελούν μεταπομπές μεταξύ διαφορετικών κέντρων μεταγωγής χαμηλότερου επιπέδου, χωρίς να επιβαρύνεται ο χρήστης με κάποιον τρόπο. [4]

1.2.3 Συστήματα 3^{ης} Γενιάς (UMTS)

Η τρίτη γενιά κινητών επικοινωνιών είχε να κάνει με την προσθήκη ψηφιακών δεδομένων (data), σαν βασικό πλέον χαρακτηριστικό και επιπρόσθετα στις υπηρεσίες φωνής. Οι υψηλοί ρυθμοί μετάδοσης επέτρεψαν την υποστήριξη πολυμεσικών εφαρμογών και την πρόσβαση στο διαδίκτυο, που εκείνη την περίοδο αναπτυσσόταν επίσης ραγδαία. Συγκεκριμένα η κίνηση δεδομένων κυριάρχησε όλο και περισσότερο έναντι της φωνής, καθώς η βιομηχανία της ψυχαγωγίας ψηφιοποιήθηκε και αυτή.

Η βασική τεχνολογία που αποτέλεσε τον κινητήριο τροχό για τα συστήματα 3^{ης} γενιάς είναι το WCDMA (Wideband Code Division Multiple Access), ενώ μια παραλλαγή που επίσης αναπτύχθηκε ήταν το CDMA2000. Οι δύο αυτές τεχνολογίες είναι παρόμοιες και βασίζονται στη διασπορά φάσματος. Η μέθοδος CDMA είναι ένα είδος ανάμιξης FDM και TDM, όπου κάθε χρήστης στέλνει στην ίδια μπάντα συχνοτήτων. Για τη σωστή λειτουργία της μεθόδου, είναι απαραίτητο οι ακολουθίες των κωδικών που προέρχονται από διαφορετικά κινητά τερματικά να είναι μεταξύ τους ορθογώνιες, κάτι που επιτυγχάνεται με τη χρήση ψευδοτυχαίων ακολουθιών. Αυτές έχουν χαμηλή μεταξύ τους διασυσχέτιση, με αποτέλεσμα να έχει ο δέκτης τη δυνατότητα να φιλτράρει ανεπιθύμητες μεταδόσεις. Επίσης και η αυτοσυσχέτισή τους είναι μικρή, επιτρέποντας στον δέκτη να κλειδώσει στο ξεκίνημα της επιθυμητής μετάδοσης. Συνολικά η αξιοποίηση των ψευδοτυχαίων ακολουθιών επιτρέπουν στον σταθμό βάσης να λαμβάνει και να διαχωρίζει επιτυχώς μηνύματα από μη συγχρονισμένα κινητά τερματικά, αρκεί να χρησιμοποιείται έλεγχος ισχύος ώστε να ελαχιστοποιούνται και οι παρεμβολές μεταξύ ανταγωνιζόμενων σημάτων.



Εικόνα 1.4 - Block διάγραμμα CDMA πομποδέκτη [3]

Τα κύρια πλεονεκτήματα της χρήσης CDMA σε σχέση με τις αντίστοιχες τεχνικές διαίρεσης χρόνου και συχνότητας είναι τα ακόλουθα [5]:

1. Η χρήση της CDMA μπορεί να βελτιώσει την χωρητικότητα με αξιοποίηση των περιόδων όπου κάποιοι πομποί δεν μεταδίδουν σήμα. Συνήθως στις συνομιλίες μιλάει μόνο ο ένας χρήστης, ενώ ο άλλος παραμένει σιωπηλός. Αυτοί οι περίοδοι παύσης δεν μπορούν να αξιοποιηθούν επαρκώς από τις άλλες τεχνικές πρόσβασης καθώς τα χρονικά διαστήματα είναι πολύ σύντομα. Αντιθέτως, στο CDMA οι παύσεις αυτές έχουν ως αποτέλεσμα την μείωση των παρεμβολών, επιτρέποντας την εξυπηρέτηση μεγαλύτερου αριθμού χρηστών, καθώς είναι βέβαια ότι για κάθε χρονική περίοδο κάποιοι από τους χρήστες που βρίσκονται στο σύστημα θα παραμένουν σιωπηλοί.
2. Στη CDMA η κάθε κυψέλη χρησιμοποιεί τις ίδιες συχνότητες, χωρίς να χρειάζεται πολυπλεξία στο πεδίο της συχνότητας, Αυτό φυσικά βελτιώνει τη χωρητικότητα του συστήματος, καθώς αυξάνεται το διαθέσιμο φάσμα για όλες τις κυψέλες. Επίσης δίνει τη δυνατότητα χρήσης πολλών κατευθυντικών κεραιών από κάθε σταθμό βάσης, και μέσω της κατευθυντικότητας αυτής να μειώνονται οι παρεμβολές μεταξύ διαφορετικών σημάτων, γεγονός ευεργετικό για ένα ασύρματο κανάλι.
3. Η χρήση της CDMA δίνει τη δυνατότητα της ομαλής μετάβασης (soft handoff) , όπου το κινητό μετακινείται στον νέο σταθμό βάσης πριν ολοκληρωθεί η διαγραφή του από τον παλιό, καθώς όλες οι συχνότητες χρησιμοποιούνται σε κάθε κυψέλη.

1.2.4 Συστήματα 4^{ης} Γενιάς (LTE)

Όπως είδαμε στις προηγούμενες ενότητες, ο κύριος στόχος των δικτύων 2^{ης} γενιάς ήταν η επιτυχής μετάβαση στις ψηφιακές επικοινωνίες με επίκεντρο τις υπηρεσίες φωνής και κάποιες βασικές υπηρεσίες δεδομένων, κυρίως μηνύματα κειμένου, ενώ για τα δίκτυα 3^{ης} γενιάς ήταν σημαντική η αύξηση του ρυθμού δεδομένων στον τελικό χρήστη ώστε να υποστηριχθεί η πρόσβαση στο διαδίκτυο και σε πιο απαιτητικές υπηρεσίες δεδομένων. Αντίστοιχα για τα δίκτυα 4^{ης} γενιάς οι στόχοι που τέθηκαν είχαν να κάνουν με την μετάβαση σε δίκτυα βασισμένα εξ ολοκλήρου στη μεταγωγή πακέτων , χρησιμοποιώντας ευέλικτα σχήματα διαχείρισης των ραδιοπόρων (RRM, Radio Resource Management), με μείωση της καθυστέρησης (latency) στην οποία είναι ιδιαίτερα ευαίσθητες real time εφαρμογές, όπως παιχνίδια στο διαδίκτυο και ζωντανές πολυμεσικές εφαρμογές, πλήρης υποστήριξη κινητικότητας του χρήστη και υψηλό επίπεδο ποιότητας υπηρεσιών (QoS, Quality of Service). Για την υποστήριξη των λειτουργικών απαιτήσεων των συστημάτων LTE, αναπτύχθηκαν εξελιγμένες τεχνολογίες ώστε να γίνεται αποδοτική χρήση του διαθέσιμου ραδιοφάσματος, μερικές από τις οποίες θα δούμε στη συνέχεια.


Όσον αφορά την πρόσβαση στον ραδιοδιάυλο, τα σχήματα που τελικά επιλέχθηκαν ήταν η OFDM (Orthogonal Division Frequency Multiplexing, Ορθογωνική Πολυπλεξία Διαιρέσεως Συχνότητας) και η αντίστοιχή της SC-FDM για την άνω ζεύξη. Μεταξύ των λόγων που επιλέχθηκαν ήταν: [7]

- Η ευρωστία που προσφέρουν σε συνθήκες διαλείψεων λόγω της πολυδιαδρομικής διάδοσης
- Υψηλή φασματική αποδοτικότητα
- Χαμηλή πολυπλοκότητα , και επομένως κόστος υλοποίησης
- Ευελιξία στην αξιοποίηση του διαθέσιμου εύρους ζώνης
- Υποστήριξη προηγμένων τεχνικών , όπως μετάδοσης MIMO (Multiple Input – Multiple Output), συχνο-επιλεκτικού προγραμματισμού του διαύλου, και διαχείρισης παρεμβολών

Η βασική ιδέα πίσω από το OFDM είναι η υποδιαίρεση της πληροφορίας που μεταδίδεται στο πεδίο της συχνότητας σε ένα μεγάλο αριθμό σημάτων στενής ζώνης τα οποία ονομάζονται και υποφέροντα (subcarriers). Τα ψηφιακά δεδομένα μεταδίδονται έτσι παράλληλα ως συνδυασμός πολλών σημάτων που μεταδίδονται το καθένα με αργό ρυθμό μετάδοσης, ενώ ο συνολικός ρυθμός μετάδοσης για την ολότητα του σήματος παραμένει σταθερός.

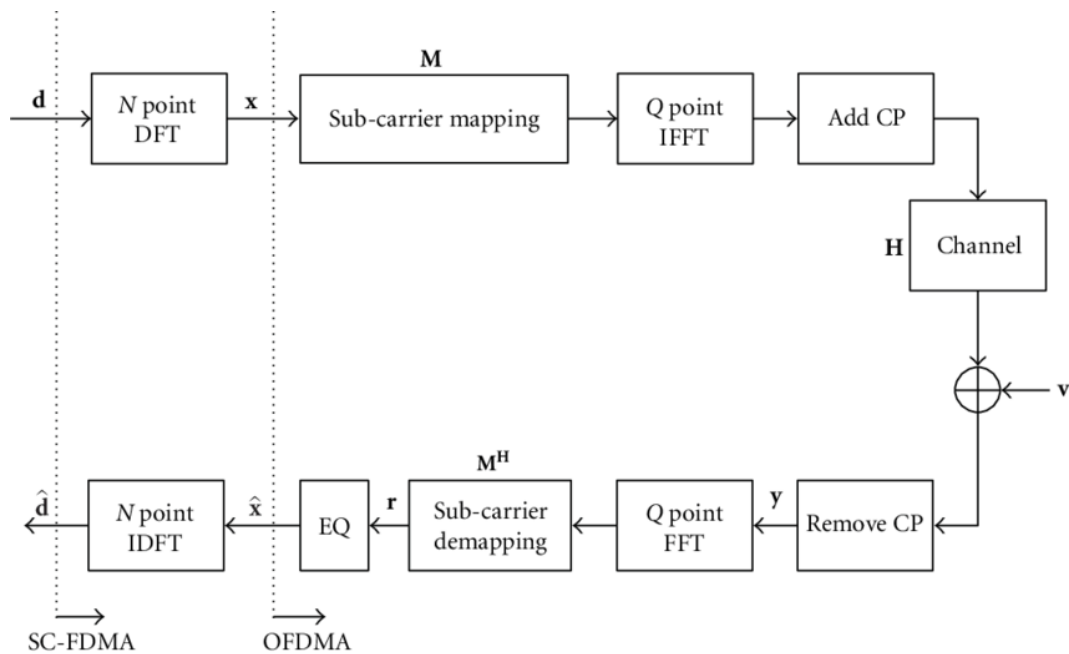
Λόγω του δυϊσμού χρόνου-συχνότητας, αυτό σημαίνει ότι το κάθε σύμβολο που αντιστοιχεί σε ένα υποφέρον, έχει πολύ μεγαλύτερη χρονική διάρκεια σε σχέση με την περίπτωση που το σήμα μεταδιδόταν ολόκληρο. Η μεγαλύτερη αυτή χρονική διάρκεια των συμβόλων έχει ως αποτέλεσμα την αποτελεσματική αντιμετώπιση των συχνο-επιλεκτικών διαλείψεων, που είναι ένα από τα κύρια προβλήματα στον ασύρματο ραδιοδιάυλο (και θα εξεταστεί λεπτομερώς στο επόμενο κεφάλαιο), καθώς ένας ραδιοδιάυλος με διαλείψεις επιλεκτικές ως προς τη συχνότητα, με την αύξηση της χρονικής διάρκειας των συμβόλων που μεταδίδονται μέσα σε αυτόν, μετατρέπεται σε κανάλι επίπεδων διαλείψεων, αφαιρώντας έτσι της αρνητικές επιπτώσεις (παρεμβολές λόγω πολυδιαδρομικής διάδοσης, παραμόρφωση του σήματος) που προκύπτουν σε αντίθετη περίπτωση. Η επανάκτηση του σήματος σε αποδεκτά επίπεδα γίνεται έτσι πολύ ευκολότερη, κάτι που οδηγεί στη μείωση του κόστους των δεκτών στα κινητά τηλέφωνα.

Για τη σωστή λειτουργία της τεχνικής OFDM, καθώς τα υποφέροντα είναι αλληλοεπικαλυπτόμενα , είναι κομβικής σημασίας να εξασφαλίζεται η μεταξύ τους ορθογωνιότητα. Για το σκοπό αυτό, θα πρέπει πρακτικά οι συχνότητες των υποφερόντων να είναι ακέραια πολλαπλάσια μιας αρχικής συχνότητας. Αυτή η απαίτηση όπως είναι φυσικό δημιουργεί εξαιρετική ευαισθησία σε σφάλματα συγχρονισμού. Μια αποδοτική υλοποίηση για το OFDM σύστημα μπορεί να γίνει με τη χρήση του FFT (Fast Fourier Transform, Ταχύς Μετασχηματισμός Φουριέρ).



Εικόνα 1.5 - Σύστημα Μετάδοσης OFDM [1]

Ένα μειονέκτημα της OFDM είναι οι μεγάλες διακυμάνσεις της στιγμιαίας εκπεμπόμενης ισχύος, με επακόλουθο τη μείωση της επίδοσης των ενισχυτών ισχύος και τελικά τη μεγαλύτερη κατανάλωση ενέργειας στους κινητούς δέκτες. Στην περίπτωση της άνω ζεύξης (uplink), δηλαδή της μετάδοσης από το κινητό προς τον σταθμό βάσης, το πρόβλημα αυτό είναι πρωταρχικής σημασίας. Για το λόγο αυτό στην άνω ζεύξη χρησιμοποιείται μια παραλλαγή της OFDM, η SC-FDM (Single-Carrier Frequency Division Multiplexing). Η βασική διαφορά είναι ότι προστίθεται μια προκωδικοποίηση βασισμένη στον DFT, η οποία έχει ως αποτέλεσμα τη μετατροπή του μεταδιδόμενου σήματος σε μοναδικού φέροντος (single carrier) και τελικά να μειώνονται οι διακυμάνσεις της εκπεμπόμενης ισχύος, ενώ ταυτόχρονα διατηρούνται τα περισσότερα πλεονεκτήματα της «καθαρής» OFDM μετάδοσης. [7]



Εικόνα 1.6 - Σύστημα μετάδοσης SC-FDMA με προσθήκη DFT, Πηγή [2]

Άλλη σημαντική τεχνολογία για την υποστήριξη των δικτύων 4^{ης} γενιάς είναι η χρήση πολλαπλών κεραιών στο πομπό αλλά και στον δέκτη, γνωστή και ως μετάδοση MIMO (Multiple Input – Multiple Output). Με τη χρήση MIMO μεθόδων επιτυγχάνεται σημαντική αύξηση του ρυθμού δεδομένων και της συνολικής χωρητικότητας του συστήματος. Επίσης, αυξάνουν την αξιοπιστία του συστήματος. Στην περίπτωση της διαφορικής εκπομπής μεταδίδεται πλεονάζουσα πληροφορία από διαφορετικές κεραιές, και έτσι δεν οδηγούμαστε σε αύξηση του πραγματικού ρυθμού μετάδοσης, αλλά κάνουμε πιο εύρωστο το κανάλι επικοινωνίας. Όμως στην χωρική πολυπλεξία (spatial multiplexing) μεταδίδονται σήματα ανεξάρτητα μεταξύ τους από διαφορετικές κεραιές, με δυνατότητα σημαντικής βελτίωσης του ρυθμού δεδομένων. Η βελτίωση αυτή σε κάποιες περιπτώσεις είναι ανάλογη με τον αριθμό των κεραιών εκπομπής. Το πρότυπο LTE παρέχει σχήματα μετάδοσης μέχρι 4 κεραιών εκπομπής για την κάτω ζεύξη (δηλαδή μετάδοση από τον σταθμό βάσης στο κινητό), ενώ το LTE – Advanced επιτρέπει μέχρι και 8 κεραιές εκπομπής στο σταθμό βάσης.

Η κωδικοποίηση Turbo είναι μια εξέλιξη των συνελικτικών σχημάτων κωδικοποίησης που είχαν χρησιμοποιηθεί και σε προηγούμενες γενιές. Ωστόσο, στο UMTS ήταν μια προαιρετική μέθοδος για την αύξηση της χωρητικότητας, ενώ στο LTE έχει καταστεί ως ο μόνος μηχανισμός κωδικοποίησης των δεδομένων του χρήστη. Οι Turbo κώδικες του LTE φέρουν σημαντικές βελτιώσεις, όπως για παράδειγμα η προσθήκη ενός ελέγχου CRC (Cyclic Redundancy Check) στην είσοδο του κωδικοποιητή. Όταν το CRC εντοπίζει την απουσία σφαλμάτων από τα δεδομένα προς αποκωδικοποίηση, τότε η διαδικασία της αποκωδικοποίησης γίνεται πολύ ταχύτερη με μικρότερο αριθμό αλγοριθμικών επαναλήψεων. Έτσι μειώνεται σημαντικά η υπολογιστική πολυπλοκότητα της όλης διαδικασίας, χωρίς να υπάρχει ουσιαστικά κάποια ποινή για την αξιοπιστία του συστήματος.

Τέλος, είναι σημαντικό να αναφερθούν και οι προσαρμοστικές μέθοδοι που είναι απαραίτητες για την επίτευξη των λειτουργικών στόχων των LTE συστημάτων. Ανάλογα με την ποιότητα του καναλιού, μπορούν να χρησιμοποιηθούν διαφορετικές μέθοδοι διαμόρφωσης και κωδικοποίησης, ενώ μπορεί να αλλάξει ακόμα και ο προγραμματισμός του διαύλου (scheduling). Με αυτές τις μεθόδους προσπαθούμε να εξυπηρετήσουμε όσο το δυνατόν περισσότερους χρήστες, χωρίς να μειωθεί η ποιότητα της ζεύξης του καθενός κάτω από ένα προκαθορισμένο κατώφλι, και με ευνοϊκές συνθήκες μπορούν να επιτευχθούν πολύ υψηλοί ρυθμοί δεδομένων με χρήση των αντίστοιχων μηχανισμών διαμόρφωσης και κωδικοποίησης που το επιτρέπουν. [7]

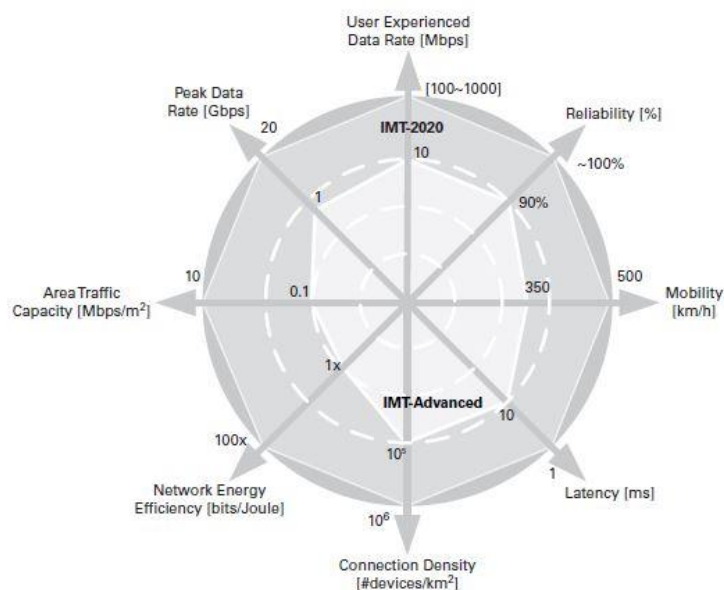
1.2.5 Συστήματα 5^{ης} και Επόμενης Γενιάς

Η εκρηκτική αύξηση των αναγκών για μεγαλύτερες ταχύτητες και ο όγκος της διακινούμενης πληροφορίας, είναι οι παράγοντες που κινούν την ανάπτυξη των δικτύων 5G στις μέρες μας. Επιπλέον, εκτός από τις ανθρωποκεντρικές εφαρμογές που έχουν κυριασρήσει στον τομέα των κινητών επικοινωνιών, πλέον έχει γίνει προφανής και η σημασία της επικοινωνίας μεταξύ μηχανών χωρίς την ανθρώπινη παρέμβαση.

Η άνοδος του όγκου δεδομένων που διακινούνται σε αυτές τις κατηγορίες οδηγεί σε μια ποικιλία από χαρακτηριστικά επικοινωνίας, που οδηγούν σε διαφορετικές προδιαγραφές και απαιτήσεις για διαφορετικού σκοπού συστήματα όσων αφορά το κόστος, την πολυπλοκότητα, την κατανάλωση ενέργειας, τον ρυθμό δεδομένων, την κινητικότητα των χρηστών/μηχανών, την αξιοπιστία και την καθυστέρηση απόκρισης (latency). Πιο συγκεκριμένα, απαιτείται η βελτίωση των δικτύων στις ακόλουθες κατηγορίες [10]:

- Μέγιστος ρυθμός δεδομένων για το χρήστη/συσκευή
- Εφικτός (ελάχιστος) ρυθμός δεδομένων για όλη την περιοχή κάλυψης
- Καθυστέρηση απόκρισης : ο χρόνος που απαιτείται για την μετάδοση πακέτου στον προορισμό του
- Μέγιστη κινητικότητα οχήματος για την οποία μπορεί να υποστηριχθεί μια δεδομένη ποιότητα υπηρεσιών (QoS, Quality of Service)
- Πυκνότητα συνδέσεων: ο αριθμός των συνδεδεμένων συσκευών για προκαθορισμένη περιοχή
- Ενεργειακή απόδοση: ο αριθμός των bit που μεταδίδονται ανά μονάδα ενεργειακής κατανάλωσης
- Αξιοπιστία: το ποσοστό των επιτυχημένων μεταδόσεων
- Χωρητικότητα κίνησης περιοχής: η συνολική διέλευση κίνησης για προκαθορισμένη γεωγραφική περιοχή
- Ασφάλεια δικτύου από άκρη σε άκρη (end-to-end): διασφάλιση ιδιωτικότητας για τους χρήστες του συστήματος

Στο σχήμα που ακολουθεί φαίνεται και η ζητούμενη βελτίωση σε σχέση με το IMT-Advanced, πρότυπο 4G, για το 5G πρότυπο IMT-2020. Είναι φανερό ότι οι απαιτήσεις που σχετίζονται με νέες εφαρμογές όπως το IoT(Internet of Things) οδηγούν σε νέες προκλήσεις σε όλο και περισσότερους τομείς.



Εικόνα 1.7 - Ζητούμενη Βελτίωση 5G, πηγή: [10]

1.2.5.1 Μικροκυψέλες(femtocells)

Ειδικότερα για την υποστήριξη υψηλότατων ρυθμών δεδομένων και τηλεπικοινωνιακής κίνησης γενικότερα, δεδομένων και των περιορισμών που υπάρχουν σχετικά με τη χρήση του αδειοδοτημένου φάσματος, ήταν φανερό ότι θα χρειαζόντουσαν νέες τεχνολογίες. Με αυτόν τον τρόπο οδηγηθήκαμε σε αύξηση της φασματικής απόδοσης και τη δυνατότητα υποστήριξης πυκνών ετερογενών δικτύων, πολλές φορές αποτελούμενα από αυτόνομους, συνεργαζόμενους μεταξύ τους κόμβους. Μία εξέλιξη που βοήθησε ιδιαίτερα στην επίτευξη αυτών των στόχων ήταν η χρήση μικρού μεγέθους κυψελών (femtocells).

Οι κυψέλες αυτές καλύπτουν πολύ μικρές περιοχές, συγκρίσιμες με την περιοχή κάλυψης των WiFi. Οι σταθμοί βάσης που χρησιμοποιούν έχουν χαμηλό κόστος υλικού και χαμηλή εκπεμπόμενη ισχύ. Σε σχέση όμως με τα WiFi δίκτυα, μπορούν να υποστηρίξουν περισσότερες από μία τεχνολογίες ραδιοπρόσβασης, χαρακτηριστικό σημαντικό για την υποστήριξη ετερογενών δικτύων (HetNets) αλλά και διαφορετικές φασματικές περιοχές. Λόγω της χαμηλής κατανάλωσης ισχύος, αυξάνουν δραματικά την ζωή μπαταρίας των κινητών τηλεφώνων, ενώ είναι χρήσιμες και σε πλαίσια εταιρικών γραφείων, αλλά και σε περιοχές της υπαίθρου, όπου η τηλεπικοινωνιακή υποδομή είναι συχνά απαρχειωμένη.


Παρά τα πλεονεκτήματα που παρουσιάζουν οι femtocells, παρουσιάζονται και αρκετές προκλήσεις σχετικά με την ανάπτυξη και ενσωμάτωσή τους στο δίκτυο. Οι κυριότερες από αυτές είναι [11]:

- Σύνδεσιμότητα με το δίκτυο κορμού (backhaul) : γενικά θεωρείται δυσκολότερη η σύνδεση με το δίκτυο κορμού, καθώς οι μικρές κυψέλες τοποθετούνται τυπικά σε δυσπρόσιτα σημεία ή περιοχές, αντί για τις οροφές ψηλών κτηρίων. Επίσης η χρήση της υπάρχουσας υποδομής για τα προηγούμενα κινητά δίκτυα είναι δύσκολη για τις μικρές κυψέλες. Η επιλογή των femtocells επομένως παρουσιάζει ζητήματα συμβατότητας με τις υπάρχουσες υποδομές, ενώ κάποιες από τις λύσεις σε αυτό το πρόβλημα όπως η χρήση λύσεων NLOS (Non Line of Sight), είναι ακριβές και οδηγούν σε μειωμένη χωρητικότητα.
- Αυτοματοποίηση : Με τα ετερογενή δίκτυα, οι πάροχοι προσπαθούν να βρουν νέες τεχνικές όσον αφορά την ανάπτυξη και διαχείριση του δικτύου τους. Το μοντέλο ανάπτυξης των femtocells έως τώρα ήταν ιδανικό για μικρότερα δίκτυα, ωστόσο δεν ενδείκνυται όσον αφορά την ενσωμάτωσή τους σε μεγαλύτερα δίκτυα εξωτερικών χώρων. Σε αυτήν την περίπτωση, καθώς η διαχείριση του δικτύου γίνεται πιο περίπλοκη με την προσθήκη των μικρών κυψελών, είναι απαραίτητη η αυτοματοποίηση της διαχείρισης, ώστε να κλιμακωθεί ανάλογα και η πυκνότητα του δικτύου.

1.2.5.2 Επικοινωνία μηχανή-προς-μηχανή(D2D)

Η άμεση επικοινωνία μεταξύ συσκευών (D2D, Device-to-Device) αναφέρεται στην επικοινωνία μεταξύ συσκευών χωρίς τη μεσολάβηση κεντρικών κόμβων υποδομής και είναι από τους σημαντικότερους στόχους για τα 5G δίκτυα. Με την D2D επικοινωνία υπάρχει η δυνατότητα αύξησης της φασματικής απόδοσης, μείωσης της καθυστέρησης απόκρισης και βελτιωμένης ενεργειακής απόδοσης. Τα οφέλη αυτά προκύπτουν από τις μικρές αποστάσεις μεταξύ των συσκευών που εμπλέκονται στην επικοινωνία, αυξημένη επαναχρησιμοποίηση στο πεδίο του χρόνου και της συχνότητας, καθώς και από τη χρήση κοινού καναλιού για τη μετάδοση και για τις δύο κατευθύνσεις της ζεύξης.

Πρωταρχική σημασία για τις D2D επικοινωνίες έχει η δυνατότητα για τοπική διαχείριση του διαύλου επικοινωνίας καθώς και ο διαχωρισμός της τοπικής κίνησης από το υπόλοιπο δίκτυο. Έτσι, μειώνεται ο φόρτος εργασίας για το δίκτυο κορμού (backhaul) και για τους κεντρικούς κόμβους που διαχειρίζονται την κίνηση. Μία σημαντική περίπτωση αξιοποίησης των D2D ζεύξεων είναι η δυνατότητα που έχουν οι χρήστες του δικτύου να βοηθήσουν στην επαναμετάδοση (relaying), κάτι που αφορά χρήστες τόσο σε εσωτερικούς όσο και σε εξωτερικούς χώρους.



Εικόνα 1.8 - Περιπτώσεις χρήσης D2D επικοινωνίας

Για τη διαχείριση των πόρων του ραδιοδιαύλου έχουν αναπτυχθεί διαφορετικές μέθοδοι, οι οποίες επιχειρούν να πετύχουν βελτιωμένη απόδοση σε σχέση με τα κυψελωτά συστήματα. Οι μέθοδοι αυτές χρησιμοποιούν ποικίλα εργαλεία για να πετύχουν αυτή τη βελτίωση, η οποία μπορεί να σχετίζεται με τη φασματική απόδοση, ελαχιστοποίηση ενέργειας, ή την επίδοση με βάση QoS (Quality of Service) περιορισμούς. Οι βασικές πτυχές της διαχείρισης ραδιοπόρων στις D2D επικοινωνίες είναι [10]:

- Επιλογή τρόπου λειτουργίας (MoS, Mode Selection): Παράγοντες που επηρεάζουν τον τρόπο λειτουργίας είναι οι αποστάσεις μεταξύ των

συνδεδεμένων συσκευών, οι απώλειες διαδρομής και σκίασης, οι συνθήκες αναφορικά με τις παρεμβολές και το συνολικό φορτίο στο δίκτυο. Η απόφαση μπορεί να ληφθεί είτε πριν την εγκαθίδρυση της ζεύξης, είτε έπειτα από αυτήν, αλλά μπορεί και να μεταβάλλεται ανάλογα με τις παρεμβολές στο κανάλι κατά τη διαδικασία εκχώρησης πόρων.

- Εκχώρηση πόρων (Resource Allocation) : Αποτελεί τη διαδικασία εκχώρησης πόρων όσον αφορά το διαθέσιμο φάσμα αλλά και τις αντίστοιχες χρονοθυρίδες. Υπάρχει ευελιξία όσον αφορά τους αλγορίθμους που χρησιμοποιούνται για αυτό το σκοπό, αναλόγως με το αν είναι κατανεμημένοι ή συγκεντρωτικοί, και με το βαθμό συντονισμού που απαιτείται μεταξύ των κυψελών (μίας ή περισσότερων).
- Έλεγχος Ισχύος (PC, Power Control): Σε αυτήν την περίπτωση επιχειρείται η μείωση των παρεμβολών , ώστε να μην μειώνεται η ποιότητα των υπηρεσιών του τελικού χρήστη.


2. ΒΑΣΙΚΕΣ ΑΡΧΕΣ ΑΣΥΡΜΑΤΩΝ ΚΑΙ ΚΙΝΗΤΩΝ ΕΠΙΚΟΙΝΩΝΙΩΝ

2.1 Συστήματα Κεραιών και Μοντέλα Διάδοσης

Το μέσο διάδοσης που χρησιμοποιούν τα συστήματα που μας ενδιαφέρουν είναι ο ασύρματος ραδιοδιάυλος. Όμως η φύση του δημιουργεί αρκετές προκλήσεις για την αξιόπιστη μετάδοση δεδομένων σε υψηλές ταχύτητες, που είναι και το ζητούμενο στις μέρες μας. Μερικά από τα εμπόδια είναι ο θόρυβος, η παρεμβολή γειτονικών καναλιών (ACI, Adjacent Channel Interference), ο τρόπος διάδοσης κατά την μετάδοση του ηλεκτρομαγνητικού κύματος με τα φαινόμενα ανάκλασης, σκέδασης, περίθλασης σε διαφορετικά εμπόδια που διακόπτουν την οπτική επαφή (LOS) πομπού και δέκτη, και πολλά άλλα. Για να αντιμετωπιστούν αυτά τα προβλήματα, έχουν αναπτυχθεί διαφορετικά μοντέλα που μπορούν να περιγράψουν με ικανοποιητική ακρίβεια, κατά περίπτωση, τη διάδοση του ηλεκτρομαγνητικού κύματος στο χώρο. Σε ένα τέτοιο μοντέλο θα στηριχθούμε και εμείς για την ανάλυση που θα κάνουμε, συγκεκριμένα το TR 38.901 (έκδοση 16) πρότυπο του 3GPP. Πριν προχωρήσουμε όμως σε συγκεκριμένα μοντέλα και πρότυπα, είναι χρήσιμο να δούμε κάποιες βασικές αρχές που τα διέπουν.

Για τη μετάδοση του ασύρματου σήματος πάνω από μία ζεύξη, είναι απαραίτητο να υπάρχει ο πομπός για την εκπομπή και ο δέκτης για τη λήψη του σήματος. Αυτή τη λειτουργία επιτελούν οι κεραιές. Σημαντικά χαρακτηριστικά των κεραιών είναι η κατευθυντικότητα και το διάγραμμα ακτινοβολίας τους, που καθορίζουν την διεύθυνση κατανομής της ισχύος του εκπεμπόμενου σήματος. Συγκεκριμένα το διάγραμμα ακτινοβολίας είναι η γραφική αναπαράσταση των ιδιοτήτων ακτινοβολίας της κεραιάς στον χώρο. Στις περισσότερες περιπτώσεις, το διάγραμμα ακτινοβολίας περιγράφει την ακτινοβολία στη μακρινή περιοχή και σχεδιάζεται ως συνάρτηση των συντεταγμένων ϕ και θ , στο σφαιρικό σύστημα συντεταγμένων, όπως φαίνεται και σε παρακάτω σχήμα.

Τα τμήματα από τα οποία αποτελείται το διάγραμμα ακτινοβολίας ονομάζονται και λοβοί ακτινοβολίας, που ουσιαστικά πρόκειται για κομμάτια που τα σύνορά τους ορίζονται από περιοχές με πολύ χαμηλή ένταση ακτινοβολίας. Ο κύριος λοβός είναι εκείνος που περιέχει την κατεύθυνση μέγιστης ακτινοβολίας, και σε κάποιες περιπτώσεις όπως κεραιές διαχωρισμού ακτίνας, μπορεί να υπάρχουν περισσότεροι από έναν κύριοι λοβοί, ενώ οι υπόλοιποι λοβοί με χαμηλότερη μέγιστη ακτινοβολία ονομάζονται δευτερεύοντες λοβοί. Υπάρχει ακόμα ο οπίσθιος λοβός, με αντίθετη κατεύθυνση του κύριου λοβού και οι πλευρικοί λοβοί, που βρίσκονται επίσης σε διαφορετική κατεύθυνση απ'τον κύριο. Γενικότερα οι δευτερεύοντες και ιδιαίτερα οι πλευρικοί λοβοί είναι συνήθως ανεπιθύμητοι και στόχος κατά τη σχεδίαση μιας κεραιάς είναι η ελαχιστοποίησή τους.



Εικόνα 2.9 - Διάγραμμα Ακτινοβολίας, Πηγή [12]

Ως ένταση ακτινοβολίας σε μια κατεύθυνση ορίζεται η ισχύς που ακτινοβολείται από την κεραία ανά μονάδα στερεάς γωνίας, και αποτελεί παράμετρο μακρινού πεδίου. Δίνεται από το γινόμενο της πυκότητας ακτινοβολίας με το τετράγωνο της απόστασης:

$$U = r^2 W_{rad}$$

Και μέσω του μεγέθους αυτού, μπορούμε πλέον να προχωρήσουμε στο κατευθυντικό κέρδος και την κατευθυντικότητα μιας κεραίας. Το κατευθυντικό κέρδος είναι απλώς η ένταση ακτινοβολίας της κεραίας προς την ένταση ακτινοβολίας του ισοτροπικού ακτινοβολητή

$$D_g = \frac{U(\varphi, \theta)}{U_o}$$

Ενώ η κατευθυντικότητα είναι η μέγιστη τιμή του κατευθυντικού κέρδους:

$$D_m = D_{g,max}$$

Τέλος, το κέρδος μιας κεραίας μας δείχνει πόσο αποδοτικά αυτή ακτινοβολεί, και δίνεται από $G_g = D_g \cdot e$, όπου το e είναι ο συντελεστής απώλειας της κεραίας και περιγράφει τις διάφορες εσωτερικές απώλειες της κεραίας. Ουσιαστικά επομένως, στον υπολογισμό του κέρδους υπεισέρχεται και η αποδοτικότητα της τροφοδότησης της κεραίας.

Χρησιμοποιώντας τις παραπάνω έννοιες και προσθέτοντας την ενεργό επιφάνεια, που δείχνει ικανότητα συλλογής H/M ισχύος μιας κεραίας λήψης,

μπορούμε τελικά να εκφράσουμε την εξίσωση Friis, που μας δείχνει την σχέση ισχύος εκπομπής και λήψης σε μια ασύρματη ζεύξη με οπτική επαφή (LOS):

$$\frac{P_t}{P_r} = G_t \cdot G_r \cdot e_{\text{ολ}} \cdot \left(\frac{\lambda}{4\pi d}\right)^2$$

Η εξίσωση αυτή μπορεί να εκφραστεί και σε dBm με τον εξής τρόπο:

$$P_r = P_t + 10 \log_{10}(G_t) + 20 \log_{10}(\lambda) - 20 \log_{10}(4\pi) - 20 \log_{10}(d)$$

Βάση αυτής της εξίσωσης σχηματίζεται και το απλούστερο μοντέλο διάδοσης που μπορεί να χρησιμοποιηθεί για μια αρχική διαστασιολόγηση απωλειών διάδοσης σε μια ζεύξη. Ο εκθέτης απωλειών γ εξαρτάται από το περιβάλλον διάδοσης και είναι $\gamma=2$ για διάδοση στον ελεύθερο χώρο, αλλά συνήθως λαμβάνει υψηλότερες τιμές για πιο πολύπλοκα περιβάλλοντα διάδοσης. Γενικότερα ο εκθέτης απωλειών αυξάνεται ανάλογα με τη συχνότητα λειτουργίας, ενώ μειώνεται με την αύξηση του ύψους των κεραιών. Η σχέση είναι η εξής:

$$P_R = P_t \cdot K \cdot \left(\frac{d_0}{d}\right)^\gamma$$

όπου το K είναι σταθερά της κεραιάς και d_0 είναι η απόσταση όπου ξεκινά η μακρινή περιοχή της κεραιάς.

Γενικότερα ωστόσο ο προσδιορισμός της συμπεριφοράς της μέσης λαμβανόμενης ισχύος είναι δύσκολος, καθώς για κάθε τύπο περιβάλλοντος διάδοσης υπάρχουν διαφορετικά φυσικά και τεχνητά εμπόδια και η εξάρτηση από την απόσταση μπορεί να λάβει ένα πολύ μεγάλο εύρος τιμών.

Ιδιαίτερο ενδιαφέρον παρουσιάζει η διάδοση μέσω πολλαπλών εμποδίων, που προσομοιάζει το φαινόμενο της περίθλασης από πολλαπλά κτήρια σε αστικό περιβάλλον. Για την επίλυση αυτού του προβλήματος χρησιμοποιούνται προσεγγιστικές μέθοδοι που έχουν ελεγχθεί τόσο με αναλυτικές τεχνικές, όσο και με πειραματικές μετρήσεις. Για την περιγραφή των εμποδίων χρησιμοποιούνται οι μηχανισμοί διάδοσης λόγω περίθλασης, που δεν μας ενδιαφέρουν επί του παρόντος. Την απώλεια λόγω περίθλασης από μεμονωμένα εμπόδια μπορούμε να την υπολογίσουμε με το ακόλουθο προσεγγιστικό μοντέλο (Epstein – Peterson):

$$L(u) \text{ dB} = \begin{cases} 20 \log_{10}[0.5 - 0.62u] & , -0.8 \leq u < 0 \\ 20 \log_{10}[0.5e^{-.95u}] & , 0 \leq u < 1 \\ 20 \log_{10} \left[0.4 - \sqrt{.1184 - (.38 - .1u)^2} \right] & , 1 \leq u < 2.4 \\ 20 \log_{10} \left[\frac{.225}{u} \right] & , u > 2.4 \end{cases}$$

Φυσικά το μοντέλο αυτό εξαρτάται κατά κύριο λόγο από τον υπολογισμό της παραμέτρου u , η οποία ονομάζεται παράμετρος περίθλασης Fresnel – Kirchhoff, και δίνεται από την ακόλουθη σχέση:

$$u = h \sqrt{\frac{2(d + d')}{\lambda dd'}}$$

όπου h είναι το ύψος του εμποδίου, d είναι η απόσταση πομπού- εμποδίου και d' είναι η απόσταση εμποδίου- δέκτη. Για πολλαπλά εμπόδια θα πρέπει να αθροιστούν οι απώλειες για κάθε εμπόδιο. Το μοντέλο αυτό όμως τείνει να υποεκτιμά τη συνολική απώλεια όταν υπάρχουν δύο ή περισσότερα εμπόδια σε μικρή απόσταση το ένα από το άλλο. Για αυτό το σκοπό χρησιμοποιούνται βελτιώσεις πάνω στη μέθοδο, μια απ' τις οποίες είναι η μέθοδος Deygout, η οποία εντοπίζει αρχικά την ακμή με τη μεγαλύτερη παράμετρο περίθλασης της ζεύξης, και στη συνέχεια για όλες τις ακμές που προηγούνται αυτής υπολογίζουμε τις απώλειες θεωρώντας ως πομπό την προηγούμενη ακμή και δέκτη την κύρια ακμή, ενώ για τις ακμές που έπονται της κύριας ακμής, θέτουμε ως δέκτη τον πραγματικό δέκτη. Περαιτέρω βελτιώσεις στην μέθοδο αυτή, όπως αυτή που προτείνεται από τη σύσταση P.526 της ITU-R, μπορούν να διορθώσουν την υπερεκτίμηση των απωλειών που παρουσιάζει αυτή για πολύ κοντινά εμπόδια [23].

2.1.1 Εμπειρικά μοντέλα απωλειών διάδοσης

Μεγαλύτερο ενδιαφέρον στην περίπτωσή μας παρουσιάζουν τα εμπειρικά μοντέλα απωλειών διάδοσης, καθώς ένα αντίστοιχο χρησιμοποιήθηκε και για τις ανάγκες της παρούσας εργασίας. Τα μοντέλα αυτά παράγονται από εμπειρικές μετρήσεις σε συγκεκριμένη απόσταση, εμβέλεια συχνοτήτων λειτουργίας, τύπο γεωγραφικής περιοχής, ύψη κεραιών κ.α. Παρόλ' αυτά, η εφαρμογή αυτών των μοντέλων δεν περιορίζεται μόνο στα περιβάλλοντα όπου λήφθηκαν οι μετρήσεις και πολλά ασύρματα συστήματα χρησιμοποιούν προσεγγιστικά μοντέλα σαν βάση για ανάλυση της επίδοσής τους. Να σημειώσουμε εδώ ότι σε αντίθεση με τα αναλυτικά μοντέλα, η απώλεια διαδρομών των εμπειρικών μοντέλων διάδοσης χρησιμοποιεί τη μέση εξασθένηση, ώστε να αφαιρούνται οι επιδράσεις από τα πολυδιαδρομικά φαινόμενα. Η μέση τιμή αυτή παράγεται από πολλαπλά σύνολα μετρήσεων σε διαφορετικά μήκη κύματος για σταθερές αποστάσεις.

Ένα πολύ σημαντικό μοντέλο, το οποίο αναπτύχθηκε για συχνότητες 1,5 ως 2 GHz για ευρωπαϊκά αστικά περιβάλλοντα είναι το COST 231 – Hata. Είναι ένα καθαρά εμπειρικό μοντέλο που χρησιμοποιεί παραμέτρους όπως η απόσταση, η συχνότητα λειτουργίας και το ύψος σταθμού βάσης και κινητού τερματικού. Αναπτύχθηκε με βάση προτύπη δουλειά των Okumura – Hata και βρίσκει εφαρμογή μόνο σε μακροκυβέλες. Στην πράξη χρησιμοποιείται για μια αρχική εκτίμηση και όχι για λεπτομερή σχεδίαση συστήματος. Έχει την ακόλουθη μορφή:

$$P_{L,urban}(d)dB = 46.3 + 33.9 \log_{10}(f_c) - 13.82 \log_{10}(h_t) - a(h_r) + (44.9 - 6.55 \log_{10}(h_t)) \log_{10}(d) + C_M$$

Όπου h_t και h_r είναι τα ύψη σταθμού βάσης και δέκτη, d είναι η μεταξύ τους απόσταση, f_c είναι η συχνότητα λειτουργίας και η σταθερά C_M παίρνει την τιμή 0dB για προάστια πόλεων ή μεσαίου μεγέθους πόλεις και 3dB για πυκνότερες αστικές περιοχές. Χρησιμοποιείται κυρίως για τις ακόλουθες εμβέλεις παραμέτρων:

$$\begin{aligned} 1.5 \text{ GHz} < f_c < 2\text{GHz} \\ 30\text{m} < h_t < 200\text{m} \\ 1\text{m} < h_r < 10\text{m} \\ 1\text{km} < d < 20\text{km} \end{aligned}$$

Μία τροποποίηση που βρίσκει εφαρμογή και σε μικροκυψέλες είναι η COST 231 Walfish – Ikegami. Το μοντέλο αυτό περιλαμβάνει εύρη τιμών αποστάσεων που ξεκινανε από τα 20 μέτρα μεταξύ σταθμού βάσης και κινητού τερματικού. Επίσης περιλαμβάνεται υπολογισμός απωλειών από πολλαπλά εμπόδια, ενώ υπάρχουν και τροποποιήσεις για χαμηλότερα ύψη σταθμών βάσης. Το μέσο σφάλμα του μοντέλου κυμαίνεται γύρω στα 3dB, αλλά είναι γενικά μεγαλύτερο για συστήματα με μικροκυψέλες.

Σε αυτό το σημείο σημειώνουμε ότι υπάρχουν μεγάλες διαφορές για τις απώλειες σε εσωτερικούς χώρους σε σχέση με τα μοντέλα που προαναφέρθηκαν. Οι απώλειες που οφείλονται σε εσωτερικούς τοίχους, δάπεδα, έπιπλα και άλλου τύπου εμπόδια τείνουν να υπερισχύουν, αλλά διαφέρουν σημαντικά ανάλογα με τα υλικά που χρησιμοποιούνται. Μία απλοϊκή περιγραφή των απωλειών δίνεται από το μοντέλο απλής κλίσης:

$$PL(d) = PL(d_0) + 10 \cdot n \cdot \log(d)$$

όπου d_0 η απόσταση αναφοράς και n ο συντελεστής απωλειών διάδοσης που εξαρτάται από το εκάστοτε περιβάλλον. Συνήθως βέβαια χρησιμοποιούνται πιο περίπλοκα μοντέλα, δεν θα ασχοληθούμε όμως περισσότερο επί του παρόντος.

2.1.2 Διαλείψεις Μεγάλης Κλίμακας και Σκίαση

Το μεταδιδόμενο σήμα στον ασύρματο διάυλο θα μετέλθει τυχαίων μεταβολών εξαιτίας αντικειμένων που βρίσκονται στη διαδρομή του σήματος, αντικείμενα που προκαλούν σκεδάσεις και ανακλάσεις και άλλα τυχαία φαινόμενα, τα οποία προκαλούν τυχαίες μεταβολές στην λαμβανόμενη ισχύ. Για την περιγραφή των τυχαίων αυτών μεταβολών χρησιμοποιείται ένα στατιστικό μοντέλο, σύμφωνα με το οποίο ο λόγος της εκπεμπόμενης προς τη λαμβανόμενη ισχύ ακολουθεί λογαριθμικοκανονική κατανομή. Ο μέσος όρος μπορεί να βρεθεί από αναλυτικά μοντέλα ή εμπειρικά δεδομένα από μετρήσεις σε πραγματικές συνθήκες. Αν χρησιμοποιήσουμε dB, τότε σε αυτήν την περίπτωση θα έχουμε μια Γκαουσιανή κατανομή, σύμφωνα με την:


$$p(\psi) = \frac{1}{\sqrt{2\pi}\sigma_\psi} e^{-\left[\frac{(\psi-\mu_\psi)^2}{2\sigma_\psi^2}\right]}$$

Συνήθως αυτή είναι και η μορφή που χρησιμοποιείται, καθώς οι μετρήσεις λαμβάνονται σε dB, ενώ έχει παρατηρηθεί ότι οι στατιστικοί μέσοι από μετρήσεις σε dB οδηγούν και σε μικρότερο σφάλμα εκτιμησης.

Ο συνδυασμός των απωλειών διαδρομής και σκίασης έχουν ιδιαίτερη σημασία και για τον υπολογισμό της πιθανότητας διακοπής P_{out} . Αυτή είναι η πιθανότητα να πέσει η λαμβανόμενη ισχύς κάτω από ένα κατώφλι, κάτω από το οποίο η ποιότητα της ζεύξης είναι απαράδεκτη, και μπορεί να προσεγγιστεί από την σχέση :

$$p(P_r(d) \leq P_{min}) = 1 - Q\left(\frac{P_{min} - (P_t + 10 \log_{10} K - 10\gamma \log_{10}\left(\frac{d}{d_0}\right))}{\sigma_{\psi_{dB}}}\right)$$

χρησιμοποιώντας το απλό μοντέλο απωλειών και της ιδιότητες της σκίασης που προαναφέρθηκαν.



Εικόνα 2.10 - Υπέρθεση διαλείψεων μικρής και μεγάλης κλίμακας και σκίασης, [9]

2.1.3 Διαλείψεις μικρής κλίμακας

Έως εδώ, ασχοληθήκαμε με τις απώλειες διάδοσης σε διαφορετικού τύπου περιβάλλοντα καθώς και με τις τυχαίες μεταβολές λόγω σκίασης. Ωστόσο, στον ασύρματο δίαυλο παρατηρούνται και ταχείες μεταβολές του σήματος, η επίδραση των οποίων προστίθεται στις απώλειες διάδοσης και τη σκίαση, με τον τρόπο που φαίνεται και στο παραπάνω σχήμα. Οι μεταβολές αυτές περιγράφονται με τον όρο: διαλείψεις μικρής κλίμακας και οφείλονται σε πολλαπλούς παράγοντες.

Η πολυδιαδρομική διάδοση είναι ίσως ο σημαντικότερος από αυτούς. Σε αυτήν την περίπτωση, διαδοχικές εκδοχές του εκπεμπόμενου σήματος καταφθάνουν στον δέκτη ακολουθώντας διαφορετικές διαδρομές και μηχανισμούς διάδοσης. Οι εκδοχές αυτές του σήματος καταφθάνουν σε διαφορετικές χρονικές στιγμές, παρουσιάζοντας επομένως διαφορετική χρονική καθυστέρηση, ενώ η υπέρθεση διαφορετικών συνιστωσών οδηγεί σε μεγάλες αλλαγές στη φάση του σήματος. Ένας ακόμα παράγοντας είναι η κινητικότητα του δέκτη, καθώς τότε υπάρχει συνεχής μεταβολή του ηλεκτρικού μήκους κάθε μονοπατιού/συνιστώσας και επομένως οι διαφορές φάσης $\Delta\phi$ μεταξύ των μονοπατιών αλλάζουν ανάλογα με τη θέση του δέκτη. Ακόμα και σε περίπτωση που ο χρήστης είναι ακίνητος, ενδεχομένως υπάρχει κίνηση άλλων ανθρώπων ή οχημάτων, που αποτελούν σκεδαστές με αποτέλεσμα να υφίστανται μεταβολές οι πολυδιαδρομικές συνιστώσες που διέρχονται αυτών.

Σε αυτό το σημείο είναι σημαντικό να επισημάνουμε τα 3 βασικά πεδία από τα οποία εξαρτάται ο ασύρματος δίαυλος: ο χρόνος (t), η συχνότητα (f) και ο χώρος (x). Ο δίαυλος παρουσιάζει μια επιλεκτικότητα ως προς και τα 3 αυτά πεδία, δηλαδή μπορεί να παρουσιάζει σημαντικές μεταβολές συναρτήσει αυτών. Μπορεί όμως για δεδομένα εύρη τιμών να παρουσιάζει συνοχή, δηλαδή να μην μεταβάλλει σημαντικά τα χαρακτηριστικά του [23].

Με τον όρο διασπορά καθυστέρησης (delay spread) εννοούμε την άφιξη πολλαπλών πολυδιαδρομικών συνιστωσών στον δέκτη με διαφορετική χρονική καθυστέρηση λόγω των διαφορετικών μονοπατιών που ακολουθούν, συγκεκριμένα ηλεκτρικών μονοπατιών. Σε αυτήν την περίπτωση λέμε ότι ο δίαυλος είναι επιλεκτικός ως προς τη συχνότητα, και μια μικρή μεταβολή στην καθυστέρηση διάδοσης μπορεί να επιφέρει σημαντική μεταβολή στη φάση μιας πολυδιαδρομικής συνιστώσας. Η υπέρθεση πολλών τέτοιων συνιστωσών έχει ως αποτέλεσμα την εμφάνιση διαλείψεων, ταχέων δηλαδή μεταβολών του σήματος λήψης. Η μεγαλύτερη χρονική διασπορά έχει ως αποτέλεσμα οι διάφορες συνιστώσες να φτάνουν στο δέκτη με μεγάλη χρονική διαφορά, με αποτέλεσμα την διασυμβολική παρεμβολή (ISI, Inter Symbol Interference). Ακολουθεί το πραγματικό μέρος του λαμβανόμενου σήματος, όπου βλέπουμε την αθροιστική συμβολή των διαφόρων πολυδιαδρομικών συνιστωσών, συμπεριλαμβανόμενης της καθυστέρησης των επιμέρους συνιστωσών και της μετατόπισης φάσης λόγω φαινομένου Doppler, που θα αναλυθεί στη συνέχεια:

$$r(t) = \Re \left\{ \sum_{n=0}^{N(t)} a_n(t) u(t - \tau_n(t)) e^{j(2\pi f_c(t - \tau_n(t)) + \phi_{Dn})} \right\}$$

όπου βλέπουμε και την επίδραση των διαφορετικών μονοπατιών με το $\tau_n(t)$, τις καθυστερήσεις που οφείλονται σε αυτά τα διαφορετικά μονοπάτια με την αντίστοιχη συμβολή στην ημιτονική συνιστώσα καθώς και της διαφοράς φάσης λόγω Doppler, ϕ_{Dn} . Σε αυτήν την περίπτωση αν η διαφορά καθυστέρησης μεταξύ δύο πολυδιαδρομικών συνιστωσών είναι κατά πολύ μεγαλύτερη από το αντίστροφο του εύρους ζώνης του σήματος, τότε αυτές δεν μπορούν να διακριθούν από τον δέκτη και

συγχωνεύονται σε μία συνιστώσα, οπότε το πλάτος και η φάση του σήματος είναι το άθροισμα των επιμέρους συνιστωσών.

2.1.3.1 Συχνοτική επιλεκτικότητα

Η κομβική παράμετρος που καθορίζει την επιλεκτικότητα του διαύλου ως προς τη συχνότητα είναι το εύρος ζώνης συνοχής, B_c , το οποίο είναι αντιστόφως ανάλογο μέγεθος προς την διασπορά καθυστέρησης (delay spread). Πρακτικά το εύρος ζώνης συνοχής είναι το φασματικό εύρος όπου οι διαφορετικές συνιστώσες είναι ισχυρά συσχετισμένες. Σε περίπτωση που το B_c είναι μικρότερο από το εύρος ζώνης του λαμβανόμενου σήματος, τότε θα υπάρχουν φασματικές συνιστώσες οι οποίες θα υφίστανται διαφορετική εξασθένηση, αν βρίσκονται σε αρκετά μεγάλη απόσταση μεταξύ τους. Τότε λέμε ότι ο δίαυλος είναι επιλεκτικός ως προς τη συχνότητα, και ισχύει ότι $BW \ll B_c$, όπου BW το φασματικό εύρος του σήματος. Από τη στιγμή που η εξασθένηση είναι διαφορετική κατά μήκος του φασματικού περιεχομένου, αυτό σημαίνει ότι θα υπάρχει τελικά φασματική παραμόρφωση και στο πεδίο του χρόνου το άπλωμα της χρονικής διάρκειας των συμβόλων θα οδηγήσει σε διασυμβολική παρεμβολή. Στην αντίθετη περίπτωση όπου το εύρος ζώνης του σήματος είναι στενότερο από το B_c τότε η εξασθένηση του σήματος θα είναι ομοιόμορφη για όλες τις συνιστώσες και το φάσμα του διατηρείται αναλλοίωτο ως προς το σχήμα που παρουσιάζει [24].

Η τιμή που παίρνει το εύρος ζώνης συνοχής εξαρτάται από τη συσχέτιση της απόκρισης του καναλιού σε δύο διαφορετικά σήματα, επομένως το εύρος ζώνης συνοχής αποτελεί ένα στατιστικό μέτρο του εύρους συχνοτήτων για το οποίο έχουμε επίπεδες διαλείψεις. Βλέπουμε λοιπόν ότι το εύρος ζώνης συνοχής πρέπει να συγκρίνεται κάθε φορά με το φάσμα του σήματος που πρόκειται να μεταδοθεί, ώστε να αποφασίσουμε για τα χαρακτηριστικά του διαύλου ως προς το εκάστοτε σήμα. Εμπειρικές σχέσεις για δοσμένες τιμές αυτοσυσχέτισης είναι οι:

- $B_c = \frac{1}{50\sigma}$, όπου σ είναι η διασπορά καθυστέρησης του διαύλου, για τιμή αυτοσυσχέτισης $c=0.9$
- $B_c = \frac{1}{5\sigma}$, για $c = 0.5$

Αντίστοιχα με τις σχέσεις που προαναφέρθηκαν μεταξύ εύρους ζώνης συνοχής και εύρους ζώνης του σήματος, μπορούμε να πούμε ότι ο δίαυλος είναι επιλεκτικός ως προς τη συχνότητα (frequency selective), όταν ισχύει $T_s < \sigma_\tau$, όπου T_s είναι η περίοδος συμβόλου του σήματος, ενώ αντιθέτως έχουμε επίπεδες διαλείψεις όταν ισχύει $T_s > \sigma_\tau$.

2.1.3.2 Χρονική Επιλεκτικότητα

Για να εξετάσουμε στη συνέχεια τη συμπεριφορά του διαύλου ως προς το χρόνο, θα πρέπει αρχικά να εισάγουμε την έννοια της μετατόπισης Doppler. Το φαινόμενο Doppler είναι υπεύθυνο για τη διασπορά στη συχνότητα και παρουσιάζεται συνήθως με τη σχετική κίνηση πομπού και δέκτη.

Η κίνηση ενός δέκτη με ταχύτητα u ως προς τον πομπό θα έχει ως αποτέλεσμα την δημιουργία μιας γωνίας θ μεταξύ της διεύθυνσης κίνησης και της γωνίας άφιξης του σήματος από τον πομπό στο δέκτη. Σε αυτήν την περίπτωση θα υπάρξει μετατόπιση της συχνότητας του λαμβανόμενου σήματος κατά


$$F_D = \frac{1}{2\pi} \frac{\Delta\phi}{\Delta t}$$

όπου $\Delta\phi$ είναι η μεταβολή φάσης στο λαμβανόμενο σήμα σε απειροστή μετακίνηση και Δt το αντίστοιχο χρονικό διάστημα. Τελικά η ολίσθηση συχνότητας Doppler μπορεί να δοθεί από

$$F_D = u \cdot \frac{\cos\theta}{\lambda}$$

σε αυτήν την περίπτωση λ είναι το μήκος κύματος του μεταδιδόμενου σήματος.

Να αναφέρουμε εδώ ότι σε περίπτωση που ο κινητός δέκτης κινείται προς τον πομπό τότε η μετατόπιση αυτή είναι θετική, ενώ αν απομακρύνεται από τον πομπό τότε η μετατόπιση συχνότητας Doppler θα είναι αρνητική.



Εικόνα 2.11 - Μετατόπιση Doppler [9]

Αν και η μετατόπιση Doppler είναι συνήθως μικρή, της τάξης των 1Hz – 1KHz, παρόλα αυτά οι διαφορές στη συχνότητα μεταξύ διαφορετικών συνιστωσών μπορούν να δημιουργήσουν σημαντικές μεταβολές στην περιβάλλουσα του σήματος, ουσιαστικά εισάγοντας μια FM διαμόρφωση στο σήμα. Η επακόλουθη διασπορά φάσματος δημιουργεί αποσυσχέτιση του σήματος, που σε γρήγορα μεταβαλλόμενους διαύλους που χρησιμοποιούν διαφορεικές τεχνικές με φάση αναφοράς αυτή του προηγούμενου συμβόλου, ενδεχομένως να αποτελέσει εμπόδιο στην μείωση του BER, δηλαδή αύξηση του SNR.

Όπως στο πεδίο της συχνότητας, έτσι και στο πεδίο του χρόνου υπάρχει ένα κρίσιμο μέγεθος για την κατηγοριοποίηση του διαύλου, ο χρόνος συνοχής T_c .

(coherence time). Ο χρόνος συνοχής είναι μέγεθος εν γένει αντιστρόφος ανάλογος με τη διασπορά Doppler f_D , η οποία αποτελεί μέτρο της φασματικής διαπλάτυνσης ενός σήματος λόγω της χρονικής μεταβολής στο ραδιοδίαυλο. Γενικά δίνεται από τη σχέση:

$$B_D = 2 \frac{u}{\lambda}$$

Σε περίπτωση που το εύρος ζώνης του σήματος είναι μικρότερο από τη διασπορά Doppler τότε η επίδραση του φαινομένου Doppler είναι σημαντική και έχουμε έναν ασύρματο δίαυλο γρήγορων διαλείψεων, με αισθητές παραμορφώσεις στις λαμβανόμενες κυματομορφές. Σε αντίθετη περίπτωση, όταν $T_c > T_s$, δηλαδή όταν η διάρκεια συμβόλου είναι μικρότερη από το χρόνο συνοχής του διαύλου, τότε έχουμε αργές διαλείψεις στο ραδιοδίαυλο, ο οποίος μπορεί να θεωρηθεί σταθερός κατά τη διάρκεια μετάδοσης ενός συμβόλου. Μια εμπειρική σχέση για το χρόνο συνοχής για τιμή αυτοσυσχέτισης μεταξύ διαφορετικών συνιστωσών $c=0.5$ είναι

$$T_c = \frac{9}{16\pi B}$$

ενώ μπορεί να χρησιμοποιηθεί και ο γεωμετρικός μέσος αυτού με τον αντίστροφο της διασποράς Doppler, $\frac{1}{B}$, με αποτέλεσμα να έχουμε συχνά στην πράξη:


$$T_c = \frac{0.423}{B}$$

Σημαντικό είναι ακόμη να σημειώσουμε ότι οι δύο αυτοί μηχανισμοί διαλείψεων είναι ανεξάρτητοι μεταξύ τους και έτσι πρέπει να αντιμετωπίζονται. Συχνά η βελτίωση στο ένα πεδίο μπορεί να συνεπάγεται την επιδείνωση στο άλλο, όπως π.χ. με την αύξηση του ρυθμού μετάδοσης συμβόλων ή την επιλογή παλμών μορφοποίησης μεγαλύτερου χρονικού εύρους[24].

2.2 Κυψελωτά συστήματα κινητών Επικοινωνιών

Η βασική ιδέα πίσω από τα κυψελωτά συστήματα επικοινωνίας είναι η εκμετάλλευση της μείωσης ισχύος με την αύξηση της απόστασης διάδοσης του H/M κύματος, ώστε να μπορούμε να επαναχρησιμοποιήσουμε την ίδια συχνότητα σε διαφορετικές περιοχές. Οι γεωγραφικές αυτές περιοχές ονομάζονται κυψέλες, και σε κάθε κυψέλη αντιστοιχεί ένας σταθμός βάσης (Base Station). Κάθε σταθμός βάσης χρησιμοποιεί συγκεκριμένα κανάλια, τα οποία δεν μπορούν να χρησιμοποιηθούν από τους γειτονικούς σταθμούς βάσης που συνορεύουν με αυτόν. Φυσικά ο κάθε σταθμός βάσης έχει τη δική του γεωγραφική περιοχή κάλυψης και επιδιώκουμε όσο γίνεται οι περιοχές κάλυψης να μην είναι επικαλυπτόμενες. Τα επαναχρησιμοποιούμενα κανάλια αποδίδονται σε κυψέλες με επαρκή απόσταση μεταξύ τους, οι οποίες ονομάζονται και ομοκαναλικές κυψέλες (Co-channel cells), και η μεταξύ τους απόσταση πρέπει να είναι αρκετά μεγάλη ώστε να μην παρουσιάζεται παρεμβολή η οποία να υποβαθμίζει

την ποιότητα των ζεύξεων για χρήστες που χρησιμοποιούν το ίδιο κανάλι από διαφορετική κυψέλη. Ο τύπος αυτός παρεμβολής μεταξύ χρηστών που χρησιμοποιούν το ίδιο κανάλι ονομάζεται ομοδιαυλική παρεμβολή (co-channel interference).



Εικόνα 2.12 - Ομάδες(Clusters) 7 και 3 κυψελών , Implementing Smart Antenna System using Genetic Algorithm and Artificial Immune System

Η πιο συνηθισμένη αναπαράσταση της περιοχής κάλυψης μιας κυψέλης είναι με εξαγωνικό σχήμα. Φυσικά η πραγματική κάλυψη δεν είναι πάντα ίδια και εξαρτάται από την κεραία εκπομπής , το φυσικό ανάγλυφο και άλλους παράγοντες. Συνήθως προκύπτει από μετρήσεις ή με χρήση μοντέλων διάδοσης, ενώ και η τοποθέτηση τους σταθμού βάσης δεν είναι πάντα στο γεωγραφικό κέντρο. Παρόλ'αυτά οι εξαγωνικές κυψέλες βοηθούν στην απλοποίηση των υπολογισμών, προσεγγίζοντας την κυκλική περιοχή κάλυψης σε επίπεδο περιβάλλον διάδοσης χωρίς εμπόδια, ενώ τα άκρα του εξαγώνου μπορούν να θεωρηθούν τα σύνορα μεταξύ των διαφορετικών κυψελών. Ο σημαντικότερος όμως λόγος είναι ότι το εξαγωνικό πλέγμα είναι αυτό που μεγιστοποιεί την ποσότητα του χώρου που μπορεί να καταλαμβάνεται από εφαιπτόμενους κύκλους , με ποσοστό που φτάνει το 90.69%. Εδώ είναι σημαντικό να αναφέρουμε ότι μια σημαντική παράμετρος του εξαγωνικού πλέγματος είναι η ακτίνα κάλυψης (coverage radius) R , η οποία δείχνει την απόσταση του κέντρου της κυψέλης από τις γωνίες του εξαγωνικού πλέγματος, ενώ η ακτίνα πλήρωσης ρ του ομόκεντρου κύκλου είναι η απόσταση του κέντρου από το μέσο των ακμών. Οι δύο αυτές ακτίνες σχετίζονται με τη σχέση:

$$R = 2\rho \sqrt{3}$$

Όπως αναφέρθηκε προηγουμένως, η βασική αρχή για τη σχεδίαση ενός κυψελωτού συστήματος είναι η επαναχρησιμοποίηση συχνότητας σε κυψέλες με επαρκή απόσταση μεταξύ τους. Μια ομάδα N κυψελών που χρησιμοποιεί αθροιστικά

όλα τα διαθέσιμα κανάλια ονομάζεται ομάδα κυψελών (cluster). Η απόσταση μεταξύ δύο ομοδιαυλικών κυψελών εξαρτάται φυσικά από τον αριθμό (N) των κυψελών ανα cluster και δίνεται από την εξίσωση:


$$D = R\sqrt{3N}$$

Από αυτή τη σχέση ουσιαστικά έχουμε το λόγο ομοδιαυλικής επαναχρησιμοποίησης, $\frac{D}{R} = \sqrt{3N}$. Ο λόγος αυτός είναι ιδιαίτερα σημαντικός, καθώς όσο αυξάνεται ο αριθμός N των κυψελών στην ομάδα, αυξάνεται και η απόσταση μεταξύ των ομοδιαυλικών κυψελών, με επακόλουθο τη μείωση της ομοδιαυλικής παρεμβολής. Από την άλλη μεριά όμως η μείωση του λόγου αυτού μπορεί να αυξήσει τη χωρητικότητα του όλου συστήματος και να μειώσει τελικά το κόστος. Επομένως υπάρχει ένας συμβιβασμός μεταξύ αυτών των 2 στόχων κατά τη σχεδίαση ενός συστήματος.

Η τομεοποίηση (sectorization) κυψελών είναι μια ευρέως διαδεδομένη μέθοδος που χρησιμοποιείται για την αύξηση της φασματικής απόδοσης και την μείωση των παρεμβολών των κυψελωτών συστημάτων. Η κυψέλη χωρίζεται συνήθως σε 3 τομείς των 120° ή σε 6 τομείς των 60° κάτι που επιτυγχάνεται με την τοποθέτηση κατευθυντικών κεραιών στο σταθμό βάσης, με τρόπο τέτοιο ώστε η εκπεμπόμενη ακτινοβολία να εστιάζει μόνο στη γωνία που θέλουμε, ενώ οι υπόλοιποι λοβοί μηδενίζονται. Η μέθοδος αυτή είναι ιδιαίτερα αποτελεσματική όταν ο σταθμός βάσης βρίσκεται σε υψηλό σημείο και χωρίς εμπόδια σε κοντινή απόσταση. Αν υπάρχουν πολλαπλά εμπόδια, τότε τα φαινόμενα της περίθλασης και της ανάκλασης θα δημιουργούσαν δευτερεύοντα κύματα τα οποία θα μεταδίδονταν και σε γειτονικούς τομείς, δημιουργώντας παρεμβολές μεταξύ των τομέων. Ακόμα όμως και στην ιδανική περίπτωση, εμφανίζεται ενδο-τομεακή παρεμβολή (ISI, Inter-Sector Interference).

Η μείωση των παρεμβολών είναι προφανής, καθώς ο κάθε τομέας πλέον θα έχει παρεμβολές μόνο από τομείς που έχουν την ίδια κατεύθυνση. Γενικότερα, η μείωση της ομοκαναλικής παρεμβολής είναι ανάλογη με τον αριθμό των τομέων που χρησιμοποιούνται, συνήθως $N=3$ για τομείς των 120° . Άλλα πλεονεκτήματα της τομεοποίησης είναι η μείωση του συντελεστή επαναχρησιμοποίησης, και επομένως η αύξηση της φασματικής απόδοσης και τελικά της χωρητικότητας του συστήματος.

Μια ακόμα τεχνική για τη μείωση των παρεμβολών στα κυψελωτά συστήματα είναι η χρήση έξυπνων κεραιών, με χρήση αλγορίθμων επεξεργασίας σήματος στο χώρο και στο χρόνο. Οι έξυπνες κεραιές μπορούν με τη χρήση στενού εύρους λοβών να παρέχουν υψηλά κέρδη στο σήμα που προορίζεται για το δέκτη, όπως και να μηδενίσουν τους λοβούς σε γωνίες όπου δημιουργούνται παρεμβολές. Φυσικά οι έξυπνες κεραιές μπορούν να χρησιμοποιηθούν και για την αύξηση του κέρδους πολυπλεξίας και συνεπώς την επίτευξη μεγαλύτερων ρυθμών δεδομένων ή κέρδους διαφορισμού.



Εικόνα 2.13 - Τομεοποίηση 120 μοιρών, πηγή: [8]

Τέλος, χρήσιμο είναι να αναφερθούμε και στην πρόιμη ακύρωση παρεμβολών. Εκμεταλλευόμενοι το γεγονός ότι στην περίπτωση της κάτω ζεύξης, ο σταθμός βάσης γνωρίζει τις παρεμβολές μεταξύ των χρηστών, καθώς και των παρεμβολών που δημιουργεί σε γειτονικές κυψέλες, η γνώση αυτή μπορεί να αξιοποιηθεί ώστε η παρεμβολή να αφαιρεθεί από τα σήματα που λαμβάνουν τα κινητά. Αυτή η πρόιμη αφαίρεση των παρεμβολών μπορεί να οδηγήσει σε αύξηση χωρητικότητας έως και μια τάξη μεγέθους σε κυψελωτά συστήματα με μεγάλο αριθμό κεραιών σταθμών βάσεων. [9].


3. ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ ΚΑΙ ΒΑΘΙΑ ΜΑΘΗΣΗ

3.1 Η Μηχανική Μάθηση στα πλαίσια της τεχνητής νοημοσύνης

Πολλοί διαφορετικοί ορισμοί έχουν δοθεί περί του τι είναι η Τεχνητή Νοημοσύνη (AI, Artificial Intelligence). Σύμφωνα με τον John McCarthy [13], έναν από τους ιστορικά πρωτοπόρους στο πεδίο αυτό, η τεχνητή νοημοσύνη είναι η επιστήμη και μηχανική της δημιουργίας έξυπνων μηχανών, και πιο συγκεκριμένα ευφύων υπολογιστικών προγραμμάτων. Σχετίζεται με την χρήση του υπολογιστή για την κατανόηση και αναπαραγωγή της ανθρώπινης ευφυίας αλλά οι μέθοδοι που χρησιμοποιεί δεν είναι απαραίτητως βιολογικά κατανοήσιμες. Φυσικά κάπου εδώ μπορεί να ανοίξει και η συζήτηση για το τι πραγματικά είναι η ευφυία, αλλά δεν θα καταπιαστούμε περαιτέρω επί του παρόντος. Αρκεί να αναφέρουμε ότι η κατηγοριοποίηση σχετικά με το τι αποτελεί νοημοσύνη δεν είναι σαφώς οριοθετημένη, καθώς κατανοούμε κάποιους αλλά όχι όλους του μηχανισμούς της νοημοσύνης. Σε κάποιες περιπτώσεις η τεχνητή νοημοσύνη χρησιμοποιείται σαν προσομοίωση της ανθρώπινης νοημοσύνης για ανθρωπογενείς δραστηριότητες, όμως αυτός δεν είναι πάντοτε ο τρόπος που χρησιμοποιείται.

Πρωταρχική μελέτη πάνω στις δυνατότητες της τεχνητής νοημοσύνης πραγματοποιήθηκε από τον Alan Turing ήδη κατά τη διάρκεια του Β' Παγκοσμίου Πολέμου, και το 1948 εισήγαγε μερικές από τις κεντρικές έννοιες της τεχνητής νοημοσύνης που χρησιμοποιήθηκαν αργότερα, σε μία έκθεση που ονόμασε "Intelligent Machinery"[14]. Παρότι δεν δημοσιεύτηκε, μία από τις ιδέες αυτές ήταν η εκπαίδευση ενός δικτύου από νευρώνες για την εκτέλεση εξειδικευμένων καθηκόντων, ουσιαστικά ένας προάγγελος των πολύ δημοφιλών σήμερα Νευρωνικών Δικτύων (NN, Neural Networks), με τα οποία θα τα καταπιαστούμε προσεχώς.

Μερικά από τα ορόσημα κατά την ανάπτυξη AI συστημάτων κατά τον προηγούμενο αιώνα αποτέλεσαν προγράμματα που αρχικά μπορούσαν να παίζουν το παιχνίδι «ντάμες» με ικανοποιητική ταχύτητα και αποτελεσματικότητα ήδη το 1952, όπου σταδιακά προστέθηκαν χαρακτηριστικά τα οποία επέτρεπαν το πρόγραμμα να μαθαίνει από την εμπειρία που συνέλεγε όσο περισσότερο συμμετείχε σε παιχνίδια. Το πρώτο τεχνητό νευρωνικό δίκτυο NN έτρεξε το 1954 από τους Belmont Farley και Wesley Clark του MIT, αν και η μνήμη που χρησιμοποιούσε το αντίστοιχο πρόγραμμα ήταν περιορισμένη, περιορίζοντας το δίκτυο στον αριθμό των 128 νευρώνων. Παρά τους περιορισμούς, είχε την δυνατότητα για αναγνώριση απλών προτύπων, ενώ παρατηρήθηκε ότι η καταστροφή ακόμη και έως 10% των νευρώνων του δικτύου δεν επηρέαζε αποφασιστικά την επίδοση κατά την εξαγωγή αποτελεσμάτων. Στα νευρωνικά δίκτυα αργότερα εμβάθυνε και ο Frank Rosenblatt, ο οποίος τα αποκάλεσε Perceptrons και έδωσε ιδιαίτερη σημασία στη σύνδεση μεταξύ των νευρώνων, ενώ επέκτεινε τα δίκτυα ώστε να αποτελούνται από πολλαπλά στρώματα νευρώνων, γι' αυτό και σήμερα η ονομασία για τα δίκτυα πολλαπλών στρωμάτων είναι multi-layer Perceptrons (MLPs).




Εικόνα 3.14 - Νευρωνικό Δίκτυο με πολλαπλή διαστρωμάτωση

Η ανάπτυξη της τεχνητής νοημοσύνης ωστόσο υπήρξε ραγδαία κυρίως από τη δεκαετία του 1990 και έπειτα, σε συνδυασμό με την άνθηση του διαδικτύου και των επιστημών της πληροφορικής. Συγκεκριμένα, η δυνατότητα συλλογής μεγάλου όγκου δεδομένων και πληροφοριών, όπως και η τεράστια αύξηση της διαθέσιμης υπολογιστικής ισχύος (ενδεικτικά, το πρόγραμμα Eliza που ήταν το πρώτο με δυνατότητα διεξαγωγής βασικού διαλόγου χρησιμοποιούσε μνήμη 50kB, ενώ το μοντέλο γλώσσας που χρησιμοποιεί το ChatGPT εκπαιδεύτηκε με 45TB κειμένου), είχαν ως αποτέλεσμα την επανεξέταση της εφαρμογής μεθόδων τεχνητής νοημοσύνης για την επίλυση σύνθετων προβλημάτων με σημαντική τελικά επιτυχία.

Στο AI πολλές φορές η νοημοσύνη έχει προγραμματιστεί με ρητό τρόπο από τον προγραμματιστή, συχνά σαν ένα σύνολο από if-else εντολές. Παρόλα αυτά σε πολλές περιπτώσεις αυτό που χρειαζόμαστε είναι η δυνατότητα της μηχανής να μπορεί να ενεργεί και να φτάνει μόνη της σε λύση, χωρίς να χρειάζεται να έχουν προγραμματιστούν ρητά όλα τα βήματα που θα ακολουθήσει. Συνήθως αυτό γίνεται μέσω της σταδιακής μάθησης της μηχανής με συνεχείς επαναλήψεις. Σε αυτήν την περίπτωση βρισκόμαστε στην κατηγορία της μηχανικής μάθησης (ML, Machine Learning), στην οποία και θα επικεντρωθούμε στη συνέχεια. Η Μηχανική Μάθηση επομένως μπορεί να προσδιοριστεί ως η διαδικασία της παραγωγής νοημοσύνης σε ένα σύστημα ή μηχανή χωρίς ρητό προγραμματισμό της διαδικασίας αυτής (Andrew NG, καθηγητής Stanford)[15].

Μια ακόμη κατηγοριοποίηση στα πλαίσια της Μηχανικής Μάθησης είναι η Βαθιά Μάθηση (DL, Deep Learning). Αν και οι όροι αυτοί συχνά χρησιμοποιούνται χωρίς καμία διαφοροποίηση, πρακτικά ο διαχωρισμός μεταξύ τους προκύπτει από τον τρόπο με τον οποίο διεξάγεται η μάθηση στην DL περίπτωση. Τότε η διαδικασία της εξαγωγής χαρακτηριστικών (feature extraction) αυτοματοποιείται σε μεγάλο βαθμό, μειώνοντας την ανάγκη ανθρώπινης παρέμβασης κατά τη διαδικασία της μάθησης. Αντιθέτως, σε διαφορετικές περιπτώσεις ML, η διαδικασία της μάθησης εξαρτάται σε μεγαλύτερο βαθμό από την ανθρώπινη παρέμβαση, και συχνά απαιτούνται καλύτερα

δομημένα δεδομένα εκπαίδευσης. Το πλεονέκτημα του DL είναι ότι έχει μεγαλύτερη δυνατότητα να βελτιώνει την επίδοση του συστήματος με την αύξηση των διαθέσιμων δεδομένων εισόδου (input data), αλλά ο μεγάλος όγκος δεδομένων αποτελεί προαπαιτούμενο για τη βελτίωση αυτή, και φυσικά η απόκτηση δεδομένων, τόσο σε όγκο όσο και σε ποιότητα, είναι πολλές φορές δύσκολη ή και αδύνατη.



Εικόνα 3.15 - Διάγραμμα Venn για τη σχέση μεταξύ AI-ML-DL, πηγή: [15]

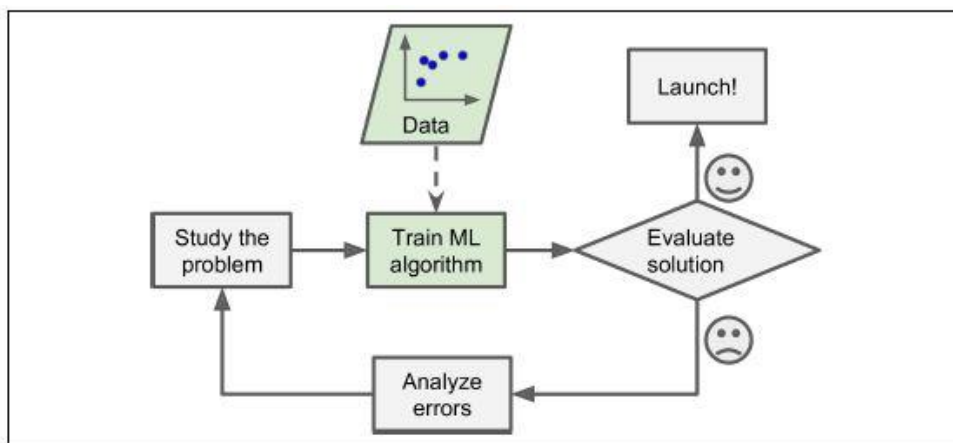
Μερικούς από τους τομείς στους οποίους έχουν εφαρμοστεί μέθοδοι ML και DL με αξιοσημείωτα αποτελέσματα είναι:

- στην Υπολογιστική όραση, με τεράστια άνθηση την τελευταία δεκαετία, στον βαθμό που οι μέθοδοι μάθησης θεωρούνται πλέον αναπόσπαστο τμήμα της επιστήμης της όρασης υπολογιστών.
- Στην ιατρική επιστήμη, και ειδικότερα στον τομέα των διαγνώσεων. Εκεί οι αλγόριθμοι μάθησης εκμεταλλεύονται ένα πλήθος από ιατρικά δεδομένα όπως οι εικόνες ακτίνων-X, υπερήχων, ηλεκτροκαρδιογραφημάτων και πολλών άλλων, ώστε να εξαχθούν συμπεράσματα.
- Στην αναγνώριση φωνής, όπου κατάλληλα εκπαιδευμένες μηχανές μπορούν να αναγνωρίζουν την ομιλία και να την «μεταφράζουν» σε γραπτό λόγο ή και σε υπολογιστικές εντολές. Οι εφαρμογές αυτής της δυνατότητας είναι απεριόριστες, από τον απομακρυσμένο έλεγχο μηχανών σε βιομηχανικό περιβάλλον, την υποβοήθηση ατόμων με κινησιακές δυσκολίες αλλά και την διευκόλυνση και ψυχαγωγία του ευρέως καταναλωτικού κοινού.
- Εξόρυξη δεδομένων και ανακάλυψη γνώσης, καθώς τα μαθησιακά μοντέλα έχουν πλέον πρόσβαση, με τη βοήθεια και του διαδικτύου, σε τεράστιο όγκο δεδομένων. Η αξία της πληροφορίας στην εποχή μας είναι ανυπολόγιστη, και συνεπώς και η δυνατότητα αξιοποίησης μεγάλου όγκου πληροφορίας έχει καταστεί ιδιαίτερος σημαντική, ενώ φυσικά οι υπολογιστικοί πόροι που

απαιτούνται είναι ευρέως διαθέσιμοι σε αντίθεση με την αξιοποίηση Μεγάλων Δεδομένων (Big Data) από τον άνθρωπο, η οποία θα ήταν απαγορευτικά χρονοβόρα.


3.2 Βασικές έννοιες και αρχές Μηχανικής Μάθησης

Ας ξεκινήσουμε τώρα να βλέπουμε μερικές βασικές έννοιες της μηχανικής μάθησης. Όπως αναφέραμε και προηγουμένως, η μηχανική μάθηση προϋποθέτει την ικανότητα αυτόνομης μάθησης (self-learning) από τον ίδιο τον υπολογιστή. Πώς επιτυγχάνεται όμως αυτή η διαδικασία; Θα πρέπει να δοθεί αρχικά στον υπολογιστή η κατάλληλη είσοδος, που ονομάζεται δεδομένα εισόδου (training data), τα οποία μπορεί να περιλαμβάνουν κάποια ετικέτα, που υποδεικνύει σε ποια κατηγορία ανήκουν, αν και αυτό δεν είναι υποχρεωτικό και εξαρτάται από τον τύπο μάθησης που θέλουμε να χρησιμοποιήσουμε, αλλά και από το αν η πληροφορία αυτή είναι διαθέσιμη. Έχοντας τα δεδομένα εισόδου, εμείς θέλουμε να χρησιμοποιήσουμε ένα κατάλληλο πρόγραμμα (ή αλγόριθμο) μάθησης, μέσω του οποίου θα εξάγουμε κάποια συμπεράσματα. Αυτό θα συμβεί με κατάλληλη επιλογή του αλγορίθμου, ο οποίος θα χρειαστεί να τρέξει αρκετές επαναλήψεις, έως να μας δώσει κάποιο τελικό συμπέρασμα, το οποίο μπορούμε εμείς στη συνέχεια να αξιολογήσουμε.



Εικόνα 3.16 - Γενικευμένη Ροή Συστήματος Μηχανικής Μάθησης, [16]

Για την εξαγωγή συμπεράσματος, ο αλγόριθμος θα χρησιμοποιήσει μετρήσιμες ποσότητες που σχετίζονται φυσικά με τα δεδομένα εισόδου και ονομάζονται χαρακτηριστικά (features) της διαδικασίας της μάθησης. Τα χαρακτηριστικά μπορεί να είναι αριθμητικά ή και ρητά (categorical). Υπάρχουν αλγόριθμοι που μπορούν να αξιοποιήσουν και τους 2 τύπους χαρακτηριστικών, όπως για παράδειγμα τα δέντρα αποφάσεων (decision trees), σε άλλες περιπτώσεις όμως όπως στην γραμμική παλινδρόμηση, πρέπει να χρησιμοποιούνται μόνο αριθμητικά χαρακτηριστικά. Τα αριθμητικά χαρακτηριστικά σχηματίζουν διανύσματα (feature vectors) και το σύνολο αυτών των διανυσμάτων για ένα πρόβλημα αποτελεί τον χώρο των χαρακτηριστικών (feature space).



Εικόνα 3.17 - Χώρος Χαρακτηριστικών 3 διαστάσεων [17]


Σε πολλές περιπτώσεις, τα χαρακτηριστικά που είναι διαθέσιμα μπορεί να πλεονάζουν, κάτι το οποίο μπορεί να προκαλέσει προβλήματα στην διαδικασία της μάθησης. Για την ακρίβεια η διαδικασία της εκπαίδευσης επιβραδύνεται σημαντικά, αλλά μπορεί να δυσχεραίνεται και η δυνατότητα εύρεσης μιας καλής λύσης για το πρόβλημα. Αυτό είναι γνωστό και ως η κατάρα της διαστασιμότητας (curse of dimensionality). Για αυτό το λόγο, ιδιαίτερα σημαντική διαδικασία πριν το τρέξιμο ενός αλγορίθμου είναι η επιλογή ή και εξαγωγή χαρακτηριστικών με κατάλληλες μεθόδους, όπως η PCA (Principal Component Analysis), ώστε να μειωθεί η διαστασιμότητα του χώρου χαρακτηριστικών.

3.3 Κατηγοριοποίηση Μηχανικής Μάθησης

Τα συστήματα Μηχανικής Μάθησης μπορούν να ταξινομηθούν αναλόγως με το αν υπάρχει ανθρώπινη επίβλεψη κατά τη διαδικασία της μάθησης. Υπάρχουν όμως και άλλα κριτήρια, όπως για παράδειγμα η ικανότητα, ή μη, ανίχνευσης μοτίβων στα δεδομένα εκπαίδευσης και η δημιουργία ενός προβλεπτικού μοντέλου για αυτήν την ενέργεια. Ας δούμε αρχικά την ταξινόμηση ανάλογα με την ανθρώπινη επίβλεψη.

Στην περίπτωση που το σύνολο των δεδομένων εκπαίδευσης είναι διαθέσιμο και το μοντέλο μηχανικής μάθησης χτίζεται εκμεταλλευόμενο πρωτύτρη γνωστή πληροφορία (a priori), τότε η μέθοδος μάθησης ονομάζεται **επιβλεπόμενη** (supervised learning). Σε αυτήν την περίπτωση, οι επιθυμητές κατηγορίες ταξινόμησης (στο εξής θα αναφέρονται και ως **κλάσεις** ή ετικέτες (labels) του προβλήματος) είναι γνωστές εκ

των πρότερων, κάτι το οποίο βοηθάει στην εξαγωγή του τελικού αποτελέσματος. Εδώ να αναφέρουμε ότι και η επιβλεπόμενη μάθηση με τη σειρά της μπορεί να διαχωριστεί σε 2 υποκατηγορίες: τα προβλήματα **ταξινόμησης** (classification), όπου ο αλγόριθμος λαμβάνει ως είσοδο ήδη ταξινομημένα δεδομένα, και μέσω της εκπαίδευσης θα πρέπει να μπορεί να ταξινομεί σωστά καινούρια δεδομένα τα οποία δεν γνωρίζει, και τα προβλήματα **παλινδρόμησης** (regression), όπου ο αλγόριθμος προσπαθεί να προσεγγίσει μια αριθμητική τιμή, δοσμένων φυσικά των χαρακτηριστικών του προβλήματος, που σε αυτήν την περίπτωση ονομάζονται και προβλεπτές (predictors). Σε αυτήν την περίπτωση φυσικά δεν υπάρχουν διακριτές κλάσεις, καθώς οι τιμές κάθε διανύσματος χαρακτηριστικών είναι συνεχείς. Ωστόσο, σε κάποιες περιπτώσεις, η μία μέθοδος μπορεί να χρησιμοποιηθεί για να πετύχει τους σκοπούς της άλλης, όπως στη λογιστική παλινδρόμηση (Logistic Regression), που χρησιμοποιείται για ταξινόμηση, καθώς αποφέρει μια τιμή που αντιστοιχεί στην πιθανότητα να ανήκει τελικά σε κάποια κλάση.




Εικόνα 3.18 - Γραμμικός ταξινομητής για πρόβλημα 2 κλάσεων, [17]

Στην κατηγορία της επιβλεπόμενης μάθησης ανήκουν μερικοί από τους δημοφιλέστερους αλγόριθμους μάθησης, όπως ο αλγόριθμος του κοντινότερου γείτονα (Nearest Neighbor), η γραμμική αλλά και η λογιστική παλινδρόμηση, οι μηχανές διανυσματικής υποστήριξης (SVMs), τα δέντρα αποφάσεων και τα δάση που σχηματίζονται από αυτά (Decision Trees / Random Forests), και φυσικά τα Νευρωνικά Δίκτυα (στις περισσότερες περιπτώσεις), με τα οποία θα ασχοληθούμε ιδιαίτερω.

Στην περίπτωση της μη-επιβλεπόμενης μάθησης (unsupervised), τα δεδομένα εκπαίδευσης δεν περιέχουν την πληροφορία σχετικά με την κλάση στην οποία ανήκουν. Ουσιαστικά το πρόβλημα πλέον είναι αρχικά να βρεθούν οι κατάλληλες ομαδοποιήσεις (clustering) για το σύνολο των δεδομένων που έχουμε διαθέσιμα, ώστε στη συνέχεια να μπορούμε να ταξινομήσουμε καινούρια δεδομένα. Για το σκοπό αυτό χρησιμοποιούνται κατάλληλοι αλγόριθμοι ομαδοποίησης, οι οποίοι αποκαλύπτουν τις ομάδες στις οποίες συσσωρεύονται τα διανύσματα χαρακτηριστικών του προβλήματός μας. Όταν ολοκληρωθεί η διαδικασία αυτή, μπορούμε να προσδιορίσουμε τον τύπο των ομάδων που έχει δημιουργήσει ο αλγόριθμος. Βασικό ζήτημα στην μάθηση χωρίς επίβλεψη είναι ο ορισμός της ομοιότητας μεταξύ διαφορετικών διανυσμάτων

χαρακτηριστικών και η επιλογή κατάλληλου μέτρου για αυτήν, καθώς και η επιλογή κατάλληλου αλγορίθμου που να ανταποκρίνεται στα μέτρα ομοιότητας που θέλουμε να χρησιμοποιήσουμε [17].

Να επισημανθεί εδώ ότι στην περίπτωση της μη επιβλεπόμενης μάθησης, έχουμε πάλι διαφορετικές κατηγορίες αλγορίθμων. Οι αλγόριθμοι ομαδοποίησης είναι αυτοί που αναλαμβάνουν το έργο του προσδιορισμού των δειγμάτων τα οποία παρουσιάζουν ομοιότητες και η δημιουργία ομάδων από τέτοια δείγματα. Κλασικό παράδειγμα τέτοιας περίπτωσης είναι ο αλγόριθμος K-Means, ο οποίος έχει χρησιμοποιηθεί ήδη εδώ και πολλές δεκαετίες για εργασίες ομαδοποίησης και έχουν αναπτυχθεί πολλές παραλλαγές για εξειδικευμένα προβλήματα. Άλλες κατηγορίες αλγορίθμων είναι οι αλγόριθμοι ανίχνευσης ανωμαλιών (anomaly detection), οι αλγόριθμοι απεικόνισης (visualization) που δημιουργούν αναπαραστάσεις των δεδομένων σε 2 και 3 διαστάσεις, οι οποίες είναι εύκολα κατανοήσιμες από τον άνθρωπο και οι αλγόριθμοι μείωσης της διαστασιμότητας που αναφέρθηκαν και προηγουμένως, με τους οποίους απλοποιούνται τα δεδομένα χωρίς όμως να χάνεται σημαντική πληροφορία, για παράδειγμα με τη συγχώνευση διαφορετικών χαρακτηριστικών τα οποία παρουσιάζουν μεγάλη συσχέτιση μεταξύ τους. Με τον τρόπο αυτό μπορεί να γίνει ανακατασκευή του χώρου χαρακτηριστικών, ώστε να είναι πιο εύκολα επεξεργάσιμος από τον αναλυτή που τον χρησιμοποιεί.



Εικόνα 3.19 - Ομαδοποίηση δεδομένων με χρήση αλγορίθμου clustering, [18]

Άλλες κατηγορίες μάθησης στις οποίες δεν κρίνεται σκόπιμο να εστιάσουμε επί του παρόντος είναι η ημι-επιβλεπόμενη μάθηση (semi-supervised learning), όπου μόνο μέρος των δεδομένων εκπαίδευσης περιλαμβάνει την πληροφορία της κλάσης στην οποία ανήκει, και η ενισχυτική μάθηση (reinforcement learning), όπου το υπόδειγμα μάθησης είναι αρκετά διαφορετικό. Περιληπτικά, το σύστημα μάθησης, που ονομάζεται και πράκτορας, παρατηρεί το περιβάλλον, και επιλέγει ενέργειες για τις οποίες μπορεί να λάβει ανταμοιβές ή ποινές. Μέσω αυτής της διαδικασίας

επιτυγχάνεται η μάθηση, η οποία ουσιαστικά έγκειται στις αποφάσεις που θέλουμε να λαμβάνει το σύστημα σε κάθε δοσμένη περίπτωση.

3.4 Αλγόριθμοι Μηχανικής Μάθησης

3.4.1 Αλγόριθμοι Κοντινότερου Γείτονα (kNN)


Ο κανόνας του πλησιέστερου γείτονα, ή για την ακρίβεια των k πλησιέστερων γειτόνων(kNN), είναι μία από τις απλούστερες αλλά και πιο εύκολα διαισθητικές μεθόδους που χρησιμοποιούνται στα πλαίσια της μηχανικής μάθησης. Η διαδικασία που ακολουθείται, για χάρη συντομίας, μπορεί να περιληφθεί ως εξής: έχοντας ένα άγνωστο διάνυσμα χαρακτηριστικών \mathbf{x} , και ένα μέτρο απόστασης, τότε [16] :

1. Για κάθε διάνυσμα εκπαίδευσης βρίσκονται οι k κοντινότεροι γείτονες, ανεξαρτήτως της κλάσης που ανήκουν. Το k επιλέγεται συνήθως να είναι περιττός αριθμός, ειδικά σε δυαδικά προβλήματα ταξινόμησης.
2. Από αυτά τα k δείγματα (instances), προσδιορίζουμε τον αριθμό των διανυσμάτων που ανήκουν σε κάθε πιθανή κλάση του προβλήματος.
3. Τελικά για το διάνυσμα εκπαίδευσης που εξετάζουμε, επιλέγουμε την κλάση η οποία πλειοψηφεί στα k δείγματα που εξετάστηκαν.


Υπάρχουν πολλά μέτρα απόστασης που μπορούν να χρησιμοποιηθούν για την εύρεση των πλησιέστερων γειτόνων, με το πιο συνηθισμένο να είναι η ευκλείδεια απόσταση. Η πιο απλή περίπτωση φυσικά είναι η περίπτωση όπου $k=1$, δηλαδή η εκφυλισμένη περίπτωση κατά την οποία πολύ απλά ταξινομούμε το διάνυσμά μας στην ίδια κλάση στην οποία ανήκει το κοντινότερο δείγμα εκπαίδευσης. Μπορεί να είναι απλοϊκή μέθοδος, αλλά όταν έχουμε επαρκή αριθμό διανυσμάτων εκπαίδευσης, μπορεί να έχει καλή επίδοση, ακόμα και σε σχέση με αρκετά πολυπλοκότερους αλγορίθμους. Αυτό μπορεί να φανεί και θεωρητικά, καθώς το μέγιστο σφάλμα για πολύ μεγάλο αριθμό διανυσμάτων εκπαίδευσης, είναι μόλις διπλάσιο του βέλτιστου (ελάχιστου) Bayesian σφάλματος [16],[18]. Για μεγαλύτερα k , οι επιδόσεις του kNN προσεγγίζουν τις αντίστοιχες ενός κλασικού Bayesian ταξινομητή.

Φυσικά, με την απλοϊκότητα της συγκεκριμένης μεθόδου, υπεισέρχονται και σημαντικά μειονεκτήματα. Αρχικά η πολυπλοκότητα για την αναζήτηση των k κοντινότερων γειτόνων για κάθε διάνυσμα προς ταξινόμηση είναι υψηλή, και φυσικά αυξάνεται με απαγορευτικούς ρυθμούς για μεγαλύτερα k . Η αναζήτηση με ωμό τρόπο (brute-force) απαιτεί πολυπλοκότητα της τάξης $O(kN)$, το οποίο είναι βέβαια προβληματικό για χώρους χαρακτηριστικών μεγάλων διαστάσεων. Έχουν αναπτυχθεί ειδικοί τρόποι αναζήτησης για την ελάφρυνση του υπολογιστικού φορτίου, όπως ο αλγόριθμος Nearest Neighbor-editing, ο οποίος απαλείφει τα δείγματα τα οποία δεν συνεισφέρουν στο σχηματισμό των ορίων μεταξύ διαφορετικών κλάσεων, ελαχιστοποιώντας έτσι τις διαστάσεις του χώρου χαρακτηριστικών [18]. Άλλο μειονέκτημα είναι οι χαμηλές επιδόσεις όταν ο αριθμός των δειγμάτων δεν είναι

επαρκώς μεγάλος, κάτι που μπορεί να αντιμετωπιστεί μερικώς με τη χρήση μετρικών αποστάσεων που έχουν βελτιστοποιηθεί για το εκάστοτε σύνολο δεδομένων εισόδου.



Εικόνα 3.20 - Σφάλμα του k NN σε σχέση με το σφάλμα Bayesian ταξινόμητη, [18]



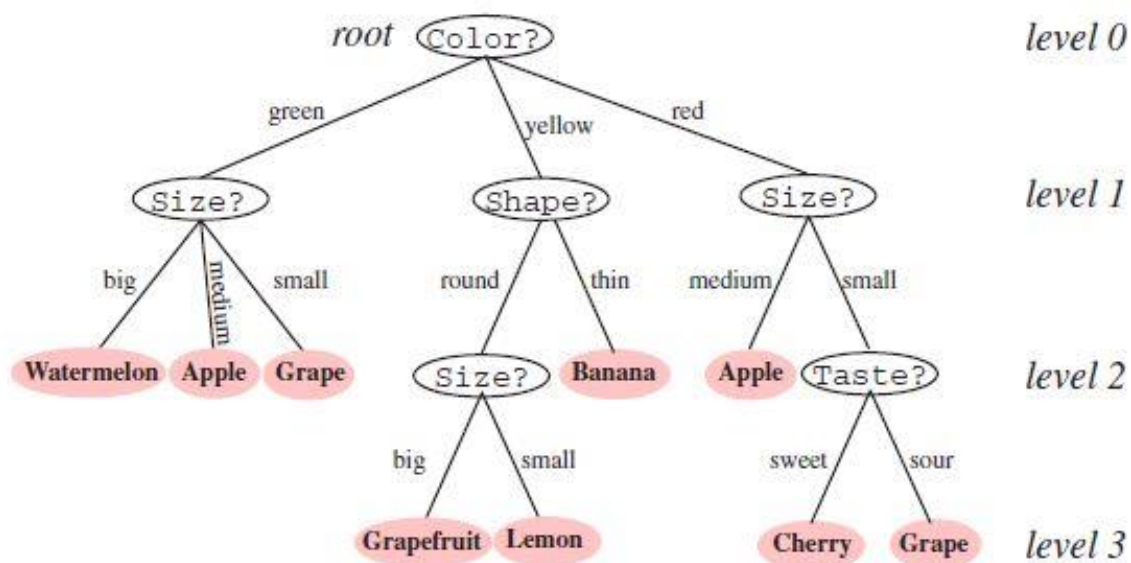
Εικόνα 3.21 - Παράδειγμα ταξινόμησης με 2 χαρακτηριστικά και 2 κλάσεις για $k=5$, [18]

3.4.2 Αλγόριθμοι Δέντρων Αποφάσεων

Οι αλγόριθμοι δέντρων αποφάσεων (Decision Trees) αποτελούν την κυρίαρχη μέθοδο που χρησιμοποιείται όταν τα δεδομένα δεν είναι αριθμητικά αλλά ονομαστικά, όπου οι τιμές τους δηλαδή δεν είναι αριθμητικές, αλλά είναι περιγραφικές, χωρίς να υπάρχει απαραίτητα κάποια ομοιότητα ή σειρά ταξινόμησης μεταξύ τους. Έτσι σε αυτήν την περίπτωση οι δομικοί λίθοι για την περιγραφή του προβλήματος και την

καταγραφή των δεδομένων δεν είναι διανύσματα αριθμών , αλλά λίστες χαρακτηριστικών.

Τα δέντρα αποφάσεων μπορούν να χρησιμοποιηθούν τόσο για ταξινόμηση κλάσεων όσο και για παλινδρόμηση (regression) σε κάποια επιθυμητή τιμή, και για την περιγραφή τους χρησιμοποιείται συνήθως ο γενικότερος όρος CART (Classification and Regression Trees). Πρόκειται για μη γραμμικούς ταξινομητές που ουσιαστικά αποτελούν συστήματα αποφάσεων πολλαπλών επιπέδων, όπου σε κάθε κόμβο απόφασης απορρίπτεται μία ή περισσότερες κλάσεις, ώσπου τελικά να καταλήξουμε σε συγκεκριμένη κατηγορία (ή σε συγκεκριμένη τιμή, ή και εύρος τιμών, στην περίπτωση της παλινδρόμησης). Έτσι, ο χώρος χαρακτηριστικών χωρίζεται με ακολουθιακό τρόπο σε περιοχές που αντιστοιχούν στις κατηγορίες του προβλήματος.



Εικόνα 3.22 - Δυαδικό δέντρο ταξινόμησης φρούτων , [18]

Για κάθε διάνυσμα που εισέρχεται ως είσοδος στο δέντρο , λαμβάνεται μια σειρά από αποφάσεις ακολουθιακά, συνήθως μία σε κάθε κόμβο ενός κατάλληλα κατασκευασμένου δέντρου. Οι αποφάσεις αυτές εφαρμόζονται σε μεμονωμένα χαρακτηριστικά, συνήθως ελέγχοντας αν ξεπερνάνε κάποιο κατώφλι, το οποίο προσαρμόζεται κατά την εκπαίδευση του μοντέλου του δέντρου. Όταν αυτές οι αποφάσεις είναι δυαδικές, τότε έχουμε δυαδικά δέντρα αποφάσεων, όμως πολλές φορές μπορεί κάποιοι κόμβοι να διακλαδώνονται σε περισσότερα από δύο παιδιά τους. Η κάθε τέτοια απόφαση ονομάζεται και διαχωρισμός του δέντρου, καθώς αντιστοιχεί στην δημιουργία ενός νέου υποσυνόλου δεδομένων. Ο αριθμός των διαχωρισμών ανά κόμβο εξαρτάται από τον τύπο της απόφασης που θα ληφθεί εκεί, και ονομάζεται και παράγοντας διακλάδωσης (branching factor). Επειδή όμως επειδή κάθε απόφαση μπορεί να αναπαρασταθεί από ένα σύνολο δυαδικών αποφάσεων, για την αναπαράσταση των CART χρησιμοποιείται σχεδόν αποκλειστικά η δυαδική περίπτωση.

Ένα ακόμα ζήτημα κατά την κατασκευή του CART είναι η απόφαση του πότε θα σταματήσουμε τον διαχωρισμό των κόμβων. Ένας απλός τρόπος αντιμετώπισης

είναι η συνεχής εκπαίδευση του δέντρου με ένα υποσύνολο δεδομένων, και ο συνεχισμός των διαχωρισμών μέχρι να ελαχιστοποιηθεί το σφάλμα ταξινόμησης στα δεδομένα επιβεβαίωσης (validation data). Ωστόσο, μπορούμε να πετύχουμε καλύτερα αποτελέσματα αν κάνουμε κάθε φορά έλεγχο της καθαρότητας του δέντρου, η οποία αν και έχει πολλούς διαφορετικούς ορισμούς, αποτελεί ουσιαστικά ένα μέτρο της απλότητας των αποφάσεων που λαμβάνονται σε κάθε κόμβο. Με αυτόν τον τρόπο μπορούμε να έχουμε κόμβους-φύλλα (leaves, οι κόμβοι στους οποίους καταλήγουν τα δέντρα και δεν έχουν επομένως παιδιά) σε διαφορετικά επίπεδα του δέντρου, με καλύτερη προσαρμογή στα δεδομένα εκπαίδευσης. Ωστόσο, η επιλογή κατάλληλου κατωφλίου για κάθε κόμβο μπορεί να καταστεί πολύ δύσκολη, καθώς η σχέση της τιμής του κατωφλίου με την τελική επίδοση δεν είναι προφανής. Στην πράξη επιλέγεται συχνά ένας μέγιστος αριθμός δειγμάτων που υπόκειται σε κάθε κόμβο, κάτι που βοηθάει και στην εξισορρόπηση του δέντρου (tree balancing).

Να αναφερθεί ότι μια φυσική επέκταση των ταξινομητών δέντρων, είναι οι ταξινομητές τυχαίου δάσους (Random Forest Classifier). Για τον σχηματισμό του ταξινομητή σε αυτήν την περίπτωση χρησιμοποιείται ένα σύνολο διαφορετικών εκπαιδευμένων δέντρων με διαφορετικά μέτρα καθαρότητας, ισορροπίας, βάθους και άλλων παραμέτρων. Στην περίπτωση της ταξινόμησης, επιλέγεται η κατηγορία κάθε δείγματος σύμφωνα με την αρχή της πλειοψηφίας μεταξύ των δεντρικών υποταξινομητών. Συνήθως με αυτόν τον τρόπο η ταξινόμηση μπορεί να πετύχει καλύτερα αποτελέσματα από κάθε επιμέρους δέντρο, με το μειονέκτημα όμως ότι χάνεται η δυνατότητα αναλυτικής περιγραφής των αποτελεσμάτων που διαισθητικά υπάρχει στην περίπτωση των δέντρων, καθώς πλέον δεν υπάρχει πρόσβαση στις επιμέρους αποφάσεις που έχουν ληφθεί σε κάθε κόμβο, πληροφορία η οποία μπορεί να καταστεί πολύ χρήσιμη κατά το «κούρδισμα» (tuning) του αλγορίθμου εκπαίδευσης.

3.5 Νευρωνικά Δίκτυα και Βαθιά Μάθηση


Τα Νευρωνικά Δίκτυα (NN, Neural Networks) που αναφέρθηκαν και σε προηγούμενη ενότητα, αποτελούν το θεμέλιο λίθο των δημοφιλέστερων και αποτελεσματικότερων αλγορίθμων μηχανικής μάθησης στις μέρες μας. Η έμπνευση προήλθε από την παρατήρηση του τρόπου που λειτουργούν οι βιολογικοί νευρώνες στον άνθρωπο αλλά και σε άλλους οργανισμούς. Οι πρώιμες αρχιτεκτονικές νευρωνικών δικτύων ήδη από τη δεκαετία του 1940 βασίστηκαν σε παρατηρήσεις των νευρικών συστημάτων ζωντανών οργανισμών, αλλά φυσικά από τότε έχει υπάρξει σημαντική πρόοδος, τόσο στην κατασκευή όσο και την κατανόηση παρόμοιων δικτύων. Μερικά από τα πλεονεκτήματα που έχουν παρουσιάσει τα τελευταία χρόνια συγκριτικά με άλλες μεθόδους είναι [17] :

- Η θεαματική αύξηση των διαθέσιμων δεδομένων προς εκπαίδευση, κάτι που εκμεταλλεύονται τα νευρωνικά δίκτυα σε πολύ μεγαλύτερο βαθμό σε σχέση με άλλες τεχνικές μάθησης.
- Η συνεχιζόμενη βελτίωση της υπολογιστικής ισχύος, που επιτρέπει την εκπαίδευση εκτενών νευρωνικών δικτύων σε εύλογο χρονικό διάστημα. Μέρους

αυτής της αύξησης έχει προέλθει και από την εκμετάλλευση μονάδων επεξεργασίας γραφικών (GPU).

- Η συνεχής βελτίωση των ίδιων των αλγορίθμων που χρησιμοποιούνται εσωτερικά των δικτύων, όπου μικρές τροποποιήσεις έχουν συνεισφέρει σε τεράστιες βελτιώσεις όσον αφορά την επίδοση και το χρόνο εκπαίδευσης ενός μοντέλου.

Η έμπνευση για τα νευρωνικά δίκτυα έχει προέλθει όπως είπαμε από πραγματικά βιολογικά νευρωνικά συστήματα, και η δομική μονάδα των νευρωνικών δικτύων, που ονομάζεται και νευρώνας, παρουσιάζει πολλές ομοιότητες. Η λογική του είναι σχετικά απλή. Κάθε νευρώνας δέχεται πολλαπλά σήματα-εισόδους, τα οποία σταθμίζονται με τα κατάλληλα βάρη (weights). Μετά την εφαρμογή των βαρών, επιτελείται πάνω στα εισερχόμενα σήματα μια λειτουργία ενεργοποίησης (activation function), η οποία ουσιαστικά αποτελεί την εφαρμογή μιας μαθηματικής συνάρτησης $F(x)$, και το αποτέλεσμα διοχετεύεται στην έξοδο. Ακολουθεί ένα παράδειγμα με την προσθήκη πόλωσης στην είσοδο του νευρώνα:



Εικόνα 3.23 - Σχηματική Αναπαράσταση Νευρώνα

Για την συνάρτηση ενεργοποίησης υπάρχει μεγάλη ποικιλία επιλογών που χρησιμοποιούνται, θα αναφέρουμε εδώ τις δύο συνηθέστερες:


- Η συνάρτηση κατωφλίου, που ουσιαστικά είναι η γνωστή μας βηματική συνάρτηση ή συνάρτηση Heaviside, και εκφράζεται ως εξής:

$$F(x) = \begin{cases} 1, & x > 0 \\ 0, & x < 0 \end{cases}$$

- Η σιγμοειδής συνάρτηση (sigmoid), η οποία ονομάζεται έτσι καθώς η γραφική της παράσταση μοιάζει με το αγγλικό s (άλλη ονομασία είναι η

λογιστική συνάρτηση (logistic)) . Η σιγμοειδής συνήθως περιλαμβάνει και μια παράμετρο κλίσης a , και προσεγγίζει τη βηματική συνάρτηση όταν η παράμετρος αυτή τείνει στο άπειρο. Σημαντική διαφορά μεταξύ των δύο είναι η διαφορισιμότητα, που ισχύει μόνο για τη σιγμοειδή.

$$F(x) = \frac{1}{1+e^{-ax}}$$



Εικόνα 3.24 - Σιγμοειδής συνάρτηση για αύξουσες τιμές παραμέτρου κλίσης

Εδώ λοιπόν μπορούμε πλέον να εισάγουμε την έννοια του Perceptron πολλών επιπέδων (MLPC, Multi-Layer Perceptron). Στην περίπτωση του ενός επιπέδου νευρώνων, τότε υπάρχει η δυνατότητα για ταξινόμηση μόνο μεταξύ γραμμικά διαχωρίσιμων κλάσεων. Σε διαφορετική περίπτωση, όπως στο διάσημο στον τομέα πρόβλημα XOR, είναι απαραίτητη η προσθήκη περισσότερων διαστρωματώσεων, και έτσι προκύπτει η ανάγκη για τη χρήση του MLPC. Κύρια χαρακτηριστικά του MLPC είναι :

1. Η συνάρτηση ενεργοποίησης που χρησιμοποιείται πρέπει να είναι μη γραμμική και ταυτόχρονα διαφορίσιμη, ώστε να μπορεί να ακολουθεί μικρές μεταβολές κατά τη διαδικασία της εκπαίδευσης (και όχι μόνο).
2. Μεταξύ των στρωμάτων εισόδου και εξόδου υπάρχουν πολλαπλά στρώματα τα οποία είναι κρυμμένα για τους κόμβους που βρίσκονται σε είσοδο και έξοδο (hidden layers)

- Υπάρχει μεγάλος αριθμός συνδέσεων μεταξύ των νευρώνων διαφορετικών επιπέδων , ενώ ο βαθμός της συνδεσιμότητας εξαρτάται από τα βάρη που εισέρχονται σε κάθε νευρώνα.

Παρότι με τις συνθήκες που αναφέρθηκαν μπορούμε να κατασκευάζουμε πολύ αποτελεσματικά δίκτυα για ταξινόμηση και παλινδρόμηση, δεν έχουμε γνώση σχετικά με την εσωτερική συμπεριφορά του δικτύου. Η θεωρητική ανάλυση καθίσταται πρακτικά αδύνατη επομένως, εξαιτίας του μεγάλου αριθμού συνδέσεων και της μη γραμμικότητας που έχουμε εμείς εισάγει σε ολόκληρο το δίκτυο.

Για την διαδικασία της εκπαίδευσης χρησιμοποιείται ο αλγόριθμος οπισθοδρόμησης (back propagation), σύμφωνα με τον οποίο ακολουθείται η εξής διαδικασία: Κατά την προς τα εμπρός εξέλιξη, τα βάρη των νευρώνων παραμένουν σταθερά και το σήμα εισόδου κατευθύνεται μέχρι την έξοδο. Επομένως οι αλλαγές παραμένουν μόνο στην ενεργοποίηση και στους νευρώνες εξόδου του δικτύου. Στη 2^η όμως φάση, συγκρίνεται το σήμα εισόδου με την επιθυμητή απόκριση, παράγοντας ένα σήμα σφάλματος. Εκείνο τώρα διαδίδεται από την έξοδο προς την είσοδο του δικτύου, επίπεδο προς επίπεδο, και γίνονται αλλαγές στα βάρη του δικτύου. Οι αλλαγές αυτές των κρυφών επιπέδων είναι πολύ πιο δύσκολα υπολογίσιμες σε σχέση με τις αλλαγές της εξόδου.

Αξίζει ακόμη να σημειωθεί ο ρόλος των νευρώνων που ανήκουν στα κρυμμένα επίπεδα, καθώς αυτοί λειτουργούν ως ανιχνευτές χαρακτηριστικών, καθώς κατά τη διάρκεια των επαναλήψεων της διαδικασίας του back propagation, είναι εκείνοι που ανακαλύπτουν τα σημαντικότερα χαρακτηριστικά, με έναν μη γραμμικό μετασχηματισμό, δημιουργώντας έναν νέο χώρο χαρακτηριστικών, ενώ αγνοούν σε μεγάλο βαθμό τα δεδομένα εκείνα της εισόδου που δεν επηρεάζουν αποφασιστικά τη διαδικασία της ταξινόμησης.

3.6 Συνελικτικά Νευρωνικά Δίκτυα

Μία ιδιαίτερα σημαντική κατηγορία νευρωνικών δικτύων στην περιοχή του DL αποτελούν τα Συνελικτικά Νευρωνικά Δίκτυα (CNNs, Convolutional Neural Networks). Τα CNNs είναι μια κατηγορία νευρωνικών δικτύων που αξιοποιούν πληροφορίες από δεδομένα 2 ή περισσότερων διαστάσεων με χρήση συνελίξεων , και χρησιμοποιούνται κατά κόρον στον τομέα της όρασης υπολογιστών, όπου έχουν ήδη αντικαταστήσει πολλές μεθόδους που χρησιμοποιούνταν παλιότερα για την εκτέλεση εργασιών όπως η ανίχνευση αντικειμένων. Η έμπνευση για την ανάπτυξή τους αρχικά προήλθε από την μελέτη της λειτουργίας του ανθρώπινου οπτικού φλοιού και του τρόπου που αλληλεπιδρά με τον ανθρώπινο εγκέφαλο για την αξιοποίηση της οπτικής πληροφορίας.


Μερικές ιδιότητες που κάνουν τα CNNs ξεχωριστά είναι:

- Ιεραρχική αρχιτεκτονική: Η δομή των CNNs είναι ιεραρχική, και τα χαρακτηριστικά που εξάγονται στα αρχικά στρώματα είναι απλούστερα, με την πολυπλοκότητά τους να αυξάνεται σταδιακά κατά μήκος του δικτύου.

- Τοπική συνδεσιμότητα: Οι νευρώνες κάθε επιπέδου συνδέονται μόνο με μια περιορισμένη περιοχή του επιπέδου εισόδου, σε αντίθεση με την πλήρη συνδεσιμότητα των FCNs. Επικάλυψη μεταξύ των πεδίων εισόδου παρουσιάζεται κυρίως για γειτονικούς νευρώνες,
- Μη-γραμμικότητα: Αυτό επιτυγχάνεται στα CNNs με τη χρήση μη γραμμικών συναρτήσεων ενεργοποίησης μετά από κάθε συνέλιξη, όπως η σιγμοειδής και η συνάρτηση υπερβολικής εφαπτομένης (*tanh*).
- Κοινόχρηστα βάρη: τα φίλτρα που χρησιμοποιούνται, αναπαράγονται σε όλη την έκταση του επιπέδου εισόδου, με κοινή παραμετροποίηση. Αυτό σημαίνει ότι οι αποκρίσεις των νευρώνων δεν παρουσιάζουν ευαισθησία σε μετατοπίσεις των χαρακτηριστικών εισόδου.

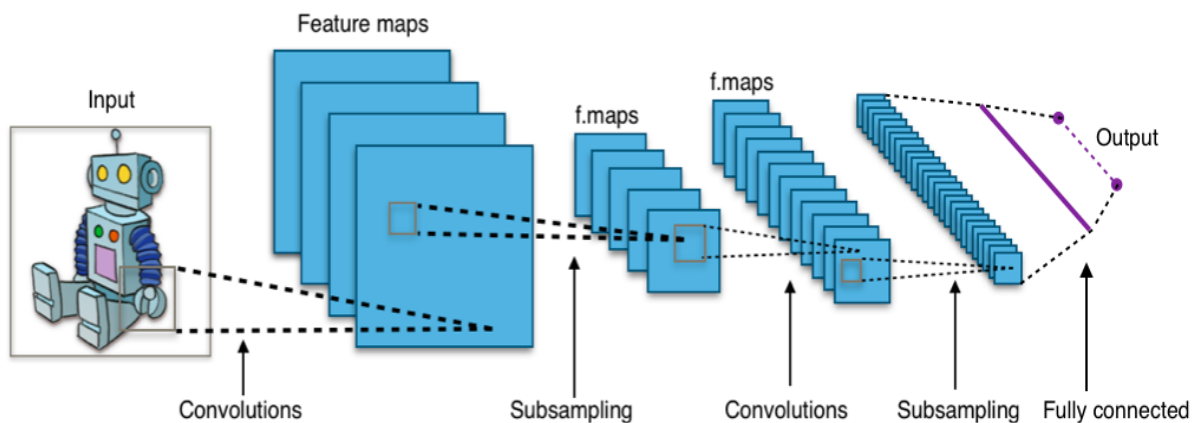
Η αρχιτεκτονική των CNNs χαρακτηρίζεται από δύο ιδιαίτερα είδη στρωμάτων, τα Convolutional Layers και τα Pooling Layers, τα οποία και υλοποιούν τις βασικές λειτουργίες των CNNs. Ας τα δούμε όμως ξεχωριστά:

- Τα **συνελικτικά στρώματα (convolutional layers)**, που αποτελούν και την καρδιά των CNNs. Στα συνελικτικά στρώματα, οι νευρώνες συνδέονται μόνο με συγκεκριμένους νευρώνες του προηγούμενου στρώματος, με τους οποίους υπάρχει μια σχετική τοπική αντιστοίχιση. Αυτό επιτρέπει στο πρώτο (κρυμμένο) στρώμα του δικτύου να επικεντρωθεί σε χαρακτηριστικά χαμηλότερου επιπέδου, τα οποία σε επόμενα στάδια συμπύκνωσης, με αποτέλεσμα την δημιουργία πιο πολύπλοκων χαρακτηριστικών. Η κύρια διαδικασία που επιτελούν, όπως φανερώνει και η ονομασία τους, είναι η συνέλιξη μέσω μιας συνάρτησης κυλιόμενου παραθύρου, η οποία ονομάζεται και **φίλτρο** ή **πυρήνας** της συνέλιξης. Τα φίλτρα, που ουσιαστικά είναι δισδιάστατοι πίνακες βαρών, μετατοπίζονται κατά μήκος της δισδιάστατης αναπαράστασης στην είσοδο, απεικονίζοντας όλη τη διαθέσιμη πληροφορία τοπικά κατά μήκος και πλάτος του στρώματος με τη δημιουργία νέων χαρακτηριστικών.
- Τα **στρώματα συνένωσης (pooling layers)**, τα οποία είναι υπεύθυνα για τη μείωση της διαστασιμότητας του δικτύου, την οποία επιτυγχάνουν μέσω υποδειγματοληψίας του προηγούμενου στρώματος, το οποίο συνήθως είναι ένα συνελικτικό στρώμα. Η σύνδεση των νευρώνων με το προηγούμενο στρώμα είναι και πάλι μόνο σε τοπικό επίπεδο, κατά μήκος και πλάτος του προηγούμενου στρώματος. Σκοπός είναι η διατήρηση της χρήσιμης πληροφορίας με παράλληλη μείωση του όγκου των χαρακτηριστικών, με αποτέλεσμα υψηλότερες επιδόσεις αλλά και βελτιωμένη ικανότητα γενίκευσης. Η πιο συχνή περίπτωση είναι το Max Pooling, με το οποίο διατηρείται η μέγιστη τιμή εντός ενός παραθύρου συνέλιξης.



Εικόνα 3.25 Απεικόνιση φίλτρου συνέλιξης

Συνήθως μετά τα αρχικά στάδια χρησιμοποίησης συνελκτικών και συνενωτικών στρώματων, χρησιμοποιούνται πλήρως συνδεδεμένα στρώματα (FCNs), τα οποία επιτελούν την εργασία της ταξινόμησης, εκμεταλλευόμενα τα χαρακτηριστικά που έχουν παραχθεί προηγουμένως. Σε αυτό το στάδιο ενσωματώνονται τα χαρακτηριστικά από όλους τους νευρώνες του προηγούμενου επιπέδου, δίνοντας την δυνατότητα στο δίκτυο να χρησιμοποιήσει όλα τα χαρακτηριστικά ταυτοχρόνως κατά την λήψη αποφάσεων κατά τη διάρκεια της ταξινόμησης.



Εικόνα 3.26 Τυπική αρχιτεκτονική CNN δικτύου


4. ΧΡΗΣΗ ΤΕΧΝΙΚΩΝ ΜΗΧΑΝΙΚΗΣ ΚΑΙ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΓΙΑ ΑΝΑΘΕΣΗ ΡΑΔΙΟΠΟΡΩΝ ΣΕ 5G ΚΥΨΕΛΩΤΟ ΔΙΚΤΥΟ

4.1 Χαρακτηριστικά προσομοιωμένου 5G Δικτύου

Σε αυτήν την ενότητα θα παρουσιάσουμε το προσομοιωμένο δίκτυο που χρησιμοποιήθηκε στα πλαίσια της εργασίας, ώστε στη συνέχεια να γίνει η ανάθεση ραδιοπόρων (συγκεκριμένα, η ανάθεση καναλιών με τη μορφή PRBs (Physical Resource Block), όρος που θα εξηγηθεί στη συνέχεια). Για την ανάθεση αυτή χρησιμοποιήθηκαν διαφορετικοί αλγόριθμοι ML, καθώς και διαφορετικοί μέθοδοι για την προετοιμασία των δεδομένων του δικτύου.

Από τοπολογικής άποψης, το δίκτυο χρησιμοποιεί την κυψέλη ως δομική μονάδα, και αποτελείται από στρώματα εξαγωνικών κυψελών, τα οποία έχουν κοινή κυψέλη ως το κέντρο τους. Τα στρώματα αυτά ονομάζονται tiers, και φυσικά όσο περισσότερα χρησιμοποιούνται, τόσο διευρύνεται η γεωγραφική έκταση του δικτύου και επομένως και ο αριθμός των χρηστών που μπορεί να εξυπηρετήσει. Στις κυψέλες εφαρμόζεται τομεοποίηση 120 μοιρών, με αποτέλεσμα να χρησιμοποιούνται 3 σταθμοί βάσης αντίστοιχης κατευθυντικότητας ανά κυψέλη. Με την τομεοποίηση, όπως αναφέρθηκε και σε προηγούμενη ενότητα, επιτυγχάνουμε μείωση των αριθμού των σταθμών βάσης που προκαλούν παρεμβολές, και τελικά επιτυγχάνουμε αύξηση του ρυθμού δεδομένων, αναλόγως φυσικά των συμβιβασμών (trade-offs) που επιλέγουμε για το δίκτυό μας. Να αναφερθεί ότι στη δική μας περίπτωση χρησιμοποιήθηκε αποκλειστικά τοπολογία με 2 tiers (συνολικά 19 κυψέλες/57 τομείς), η οποία και παρατίθεται στη συνέχεια.

Για τους σκοπούς της εργασίας αυτής, ιδιαίτερη σημασία κατέχει η διαδικασία ανάθεσης καναλιών στους χρήστες που εισέρχονται στο σύστημα. Βασική δομική μονάδα που χρησιμοποιείται για την ανάθεση πόρων είναι το **PRB (Physical Resource Block)**, όπου κάθε PRB αποτελείται από 12 υποφέροντα, ενώ ο μέγιστος αριθμός PRBs που χρησιμοποιείται είναι στο σύστημα είναι 132. Σημαντική παράμετρος του συστήματος είναι ο αριθμός των υποφερόντων που αποδίδονται για κάθε χρήστη, ο οποίος μπορεί να είναι σταθερός, μπορεί όμως να είναι και μεταβαλλόμενος, κάτι που προσομοιάζει καλύτερα την κίνηση σε ένα πραγματικό δίκτυο, καθώς οι χρήστες χρειάζονται φάσμα αναλογικά με το πόσο απαιτητική είναι η χρήση που κάνουν (π.χ. υπηρεσίες φωνής καταναλώνουν σαφώς λιγότερα δεδομένα σε σχέση με υπηρεσίες video streaming). Ο αριθμός των PRBs που αποδίδονται εξαρτάται όμως και από την χωρητικότητα χρηστών που θέλουμε για το σύστημα, όπου η αύξηση του ενός μεγέθους σημαίνει αναπόφευκτα και μείωση του άλλου, οδηγώντας σε έναν ακόμα συμβιβασμό.



Εικόνα 4.27 Κυψελωτό 2-tier δίκτυο με 3 τομείς ανά κυψέλη

Σημαντικές ακόμη παράμετροι για το σύστημά μας είναι : ο αριθμός των κεραιών σε πομπό και δέκτη (δηλαδή σταθμό βάσης και κινητό), καθώς με την αύξηση αυτών βελτιώνουμε τους ρυθμούς μετάδοσης με αξιοποίηση τεχνικών MIMO, με αυξανόμενο ωστόσο κόστος συστήματος, το οποίο δεν θα μας απασχολήσει εδώ, και η μέγιστη ισχύς από τον κάθε σταθμό βάσης, θέτοντας ένα άνω όριο, πάνω από το οποίο δεν μπορεί κανένα σταθμός βάσης του δικτύου να εκπέμψει. Τέλος, η ανάθεση των PRBs στους χρήστες που εισέρχονται στο σύστημα μπορεί να γίνεται τόσο με τυχαίο τρόπο, όσο και με βάση το μέγιστο SNIR.

Όσον αφορά το μοντέλο απωλειών που χρησιμοποιούμε, αυτό βασίζεται στο πρότυπο ETSI TR 138.901 v14.3.0 της 3GPP, όπου εμείς εστιάζουμε στην περίπτωση αστικών περιοχών με τη χρήση μακροκυψελών. Σε αυτό ορίζονται εύρη τιμών για τα ύψη των κεραιών βάσης (εμείς για απλότητα θεωρούμε ότι οι χρήστες έχουν γεωγραφική υπόσταση μόνο κατά τις x και y διαστάσεις και δεν υπεισέρχεται το ύψος των κινητών τερματικών στους υπολογισμούς), η τυπική απόκλιση της σκίασης, καθώς και οι απώλειες διάδοσης για περιπτώσεις οπτικής και μη επαφής (LOS/NLOS). Παραθέτουμε ακολούθως το σχετικό απόσπασμα για την περίπτωση που έχει χρησιμοποιηθεί:

Να σημειώσουμε εδώ ότι οι χρήστες εισάγονται στο σύστημα με ομοιόμορφη κατανομή στο x-y επίπεδο, εδώ δεν λαμβάνεται υπόψη το ύψος των κινητών τερματικών, χωρίς να βλάπτεται η δυνατότητα γενίκευσης στις 3 διαστάσεις. Επίσης οι χρήστες θεωρούνται στατικοί και επομένως δεν μας απασχολεί η κίνησή τους. Τέλος, έχει τεθεί ένα άνω όριο 160 dB για τις απώλειες διαδρομής μεταξύ σταθμού βάσης και χρήστη και σε περίπτωση υπέρβασης του οποίου ο χρήστης απορρίπτεται,

καθώς η απαιτούμενη ισχύς για την σύνδεση του χρήστη θα δημιουργούσε ισχυρές παρεμβολές στο δίκτυο.

| | | | | |
|-----|------|--|----------------------------|--|
| UMa | LOS | $PL_{\text{UMa-LOS}} = \begin{cases} PL_1 & 10\text{m} \leq d_{2D} \leq d'_{\text{BP}} \\ PL_2 & d'_{\text{BP}} \leq d_{2D} \leq 5\text{km} \cdot \text{see note 1} \end{cases}$ $PL_1 = 28.0 + 221\log_{10}(d_{3D}) + 20\log_{10}(f_c)$ $PL_2 = 28.0 + 40\log_{10}(d_{3D}) + 20\log_{10}(f_c) - 9\log_{10}((d'_{\text{BP}})^2 + (h_{\text{BS}} - h_{\text{UT}})^2)$ | $\sigma_{\text{SF}} = 4$ | $1.5\text{m} \leq h_{\text{UT}} \leq 22.5\text{m}$ $h_{\text{BS}} = 25\text{m}$ |
| | NLOS | $PL_{\text{UMa-NLOS}} = \max(PL_{\text{UMa-LOS}}, PL'_{\text{UMa-NLOS}})$ <p style="text-align: center;">for $10\text{m} \leq d_{2D} \leq 5\text{km}$</p> $PL'_{\text{UMa-NLOS}} = 13.54 + 39.08\log_{10}(d_{3D}) + 20\log_{10}(f_c) - 0.6(h_{\text{UT}} - 1.5)$ | $\sigma_{\text{SF}} = 6$ | $1.5\text{m} \leq h_{\text{UT}} \leq 22.5\text{m}$ $h_{\text{BS}} = 25\text{m}$ Explanations: see note 3 |
| | | Optional PL = $32.4 + 20\log_{10}(f_c) + 30\log_{10}(d_{3D})$ | $\sigma_{\text{SF}} = 7.8$ | |

Εικόνα 4.28 Σενάριο για αστικές μακροκυψέλες από το TR38.901

Το σημαντικότερο κομμάτι στα πλαίσια αυτής της εργασίας είναι η ανάθεση πόρων, PRBs στη συγκεκριμένη περίπτωση, στους χρήστες του δικτύου. Η εκχώρηση γίνεται με χρήση της τεχνικής OFDMA η οποία και αναπτύχθηκε σε προηγούμενη ενότητα. Να αναφέρουμε ότι η απόσταση μεταξύ των υποφερόντων ισούται με 6MHz και η ανάθεση μπορεί να γίνει είτε με τυχαίο τρόπο είτε με επιλογή βάση μεγιστοποίησης του SNIR. Είναι προϋπόθεση για την εκχώρηση να υπάρχουν διαθέσιμα κανάλια από κατάλληλο σταθμό βάσης, και σε αντίθετη περίπτωση ο χρήστης θα απορριφθεί. Η διαδικασία εκχώρησης συνεχίζεται μέχρι να αποδοθούν όλα τα διαθέσιμα PRBs από όλους του σταθμούς βάσης του δικτύου, όταν και τερματίζεται η προσομοίωση.

4.2 Ορισμός προβλήματος στα πλαίσια μηχανικής μάθησης

Στη συνέχεια , είναι σημαντικό να ορίσουμε τις παραμέτρους του προβλήματος της ανάθεσης των ραδιοπόρων/PRBs, με όρους μηχανικής μάθησης. Τα δείγματα για το πρόβλημά μας αντιστοιχούν στους χρήστες, οι οποίοι έχουν εισέλθει επιτυχώς στο κυψελωτό δίκτυο, και επομένως τους έχουν ανατεθεί πόροι. Αντιθέτως οι χρήστες που έχουν απορριφθεί, συνήθως λόγω έλλειψης κατάλληλων πόρων κατά τη στιγμή που προσπάθησαν να συνδεθούν, δεν περιλαμβάνονται στα δείγματα εκπαίδευσης του προβλήματός μας.

Ο αριθμός των χρηστών που μπορεί να απορροφήσει το κυψελωτό δίκτυο 2 επιπέδων που δημιουργήσαμε, εξαρτάται από τον αριθμό των καναλιών (δηλαδή το φάσμα) που ανατίθενται σε κάθε χρήστη. Τα δύο αυτά μεγέθη είναι αντιστρόφως ανάλογα, καθώς όσο μεγαλύτερος είναι ο λόγος PRB ανά χρήστη, τόσο μικρότερος αριθμός χρηστών θα μπορέσει να εξυπηρετηθεί από το δίκτυο, που φυσικά έχει πεπερασμένους πόρους. Για τις ανάγκες της εργασίας, ο αριθμός $n = \frac{PRB}{user}$ κυμαίνεται από 3 έως 12, κάτι το οποίο σημαίνει ότι στο δίκτυο συνδέονται από 600 έως 2500 περίπου χρήστες, όταν αυτό είναι πλήρες (έχουν δηλαδή ήδη ανατεθεί όλοι οι διαθέσιμοι πόροι). Όμως για προβλήματα τύπου ML (και ιδιαίτερα DL), χρειαζόμαστε συχνά πολύ μεγαλύτερα σύνολα δεδομένων εκπαίδευσης. Για αυτό το λόγο χρησιμοποιήσαμε την τεχνική Monte Carlo, ώστε να αυξήσουμε τον όγκο των δεδομένων εκπαίδευσης στον επιθυμητό βαθμό, δηλαδή 20 – 100 χιλιάδες χρήστες. Για κάθε επανάληψη της προσομοίωσης του δικτύου, παράγονται διαφορετικές τιμές, κάτι που συνεισφέρει στην δημιουργία ενός ποικιλόμορφου συνόλου δεδομένων, κάτι που προσομοιάζει ικανοποιητικά την αβεβαιότητα που συναντάμε και σε ένα πραγματικό ασύρματο τηλεπικοινωνιακό σύστημα. Τα σύνολα δεδομένων (dataset) τα οποία θα αναφέρουμε στη συνέχεια βρίσκονται στο εύρος που αναφέραμε, μεταξύ 20 και 100 χιλιάδων χρηστών.

Ας προχωρήσουμε τώρα στην καρδιά του προβλήματος ταξινόμησης, το οποίο θα κληθεί να αντιμετωπίσει ο αλγόριθμος που θα χρησιμοποιήσουμε στη συνέχεια. Τα αντικείμενα προς ταξινόμηση (ή **παρατηρήσεις** (observations)) είναι οι πόροι που ανατίθενται σε κάθε χρήστη, όπου για λόγους απλότητας θεωρούμε ότι κάθε PRB αντιστοιχεί σε ένα υποφέρον (subcarrier) κανάλι μετάδοσης. Οι **κατηγορίες** (ή κλάσεις) ταξινόμησης αποτελούνται από τα διαθέσιμα υποφέροντα/PRBs στο δίκτυο, τα οποία και είναι συνολικά 132 για κάθε σταθμό βάσης. Επομένως, το ζητούμενο είναι η σωστή ταξινόμηση των υποφερόντων που έχουν δοθεί στο χρήστη από το σταθμό βάσης. Οι αλγόριθμοι που θα χρησιμοποιήσουμε στη συνέχεια για αυτό το σκοπό ονομάζονται και **ταξινομητές**.

Στο σημείο αυτό είναι χρήσιμο να διαχωρίσουμε τους τύπους ταξινόμησης, ανάλογα με τον αριθμό των κλάσεων του προβλήματος, τον αριθμό κλάσεων στις οποίες μπορεί να ανήκουν οι παρατηρήσεις του προβλήματος, καθώς και τον αριθμό των διαφορετικών ταξινομήσεων που μπορεί να εξυπηρετούνται από έναν αλγόριθμο ταξινόμησης:

- Δυαδική ταξινόμηση (**binary classification**) έχουμε όταν ο αριθμός των κλάσεων είναι δύο, και ουσιαστικά οδηγούμαστε σε μια διχοτόμηση του χώρου χαρακτηριστικών, ανεξαρτήτως των διαστάσεων του χώρου.
- Ταξινόμηση πολύ-κατάταξης (**multi-class classification**) έχουμε στις περιπτώσεις όπου μπορούν να επιλεγούν περισσότερες από 2 κατηγορίες για τα δεδομένα εισόδου.

Φυσικά όπως αναφέρθηκε και σε προηγούμενη ενότητα, στον κάθε χρήστη θα ανατίθενται περισσότερα από ένα υποφέροντα, επομένως βρισκόμαστε στη δεύτερη περίπτωση. Να σημειωθεί ότι στην πράξη, ένα multiclass πρόβλημα μπορεί να θεωρηθεί ως ένας συνδυασμός πολλών δυαδικών προβλημάτων, ένα για κάθε κατηγορία.

Μία ακόμα περίπτωση αποτελεί η ταξινόμηση πολλαπλών ετικετών (**multi-label classification**). Στις προηγούμενες περιπτώσεις θεωρείται ότι το κάθε παράδειγμα ανήκει μόνο σε μία κατηγορία, είτε αυτές είναι 2 (περίπτωση binary) είτε είναι περισσότερες (περίπτωση multiclass). Στην multilabel ταξινόμηση όμως, το κάθε δείγμα εισόδου μπορεί να ταξινομηθεί σε περισσότερες από μία κατηγορίες.

Με βάση τις έννοιες που έχουμε εισάγει παραπάνω, μπορούμε σε αυτό το σημείο να προσδιορίσουμε και την δική μας περίπτωση ταξινόμησης. Εφόσον οι κλάσεις αντιστοιχούν στο αριθμό των διαθέσιμων PRBs, δηλαδή 132, το πρόβλημά μας υπάγεται στην περίπτωση του multilabel classification. Επίσης, όπως αναφέρθηκε, σε κάθε χρήστη θα αποδίδουμε περισσότερα από 1 κανάλια, επομένως μιλάμε και για multilabel classification.

4.3 Επιλογή χαρακτηριστικών και προεπεξεργασία δεδομένων


Σε αυτό το σημείο, είναι σημαντικό να αναφερθούμε και στην έννοια των χαρακτηριστικών (**features**) του προβλήματος. Τα χαρακτηριστικά αποτελούν ιδιότητες του προβλήματος, οι οποίες συνήθως είτε είναι αριθμητικές, είτε κατηγορικές, όπου στην δεύτερη περίπτωση μπορούμε να τις μετατρέψουμε σε αριθμητικές ακολουθώντας κατάλληλες διαδικασίες, οι οποίες δεν μας ενδιαφέρουν για τους σκοπούς της εργασίας. Το σύνολο των χαρακτηριστικών που χρησιμοποιούμε ως είσοδο σε έναν αλγόριθμο μηχανικής μάθησης ονομάζεται και διάνυσμα χαρακτηριστικών (**feature vector**), ενώ η επιλογή των χαρακτηριστικών, καθώς και οι διάφοροι μετασχηματισμοί που μπορούν να γίνουν πάνω σε αυτά, έχουν σημαντική επίδραση στη συνολική επίδοση του συστήματος.

Τα χαρακτηριστικά που χρησιμοποιήθηκαν στη δική μας περίπτωση ως διάνυσμα χαρακτηριστικών είναι:

- Η τοποθεσία των χρηστών που εισέρχονται στο δίκτυο, με σημείο αναφοράς το κέντρο της κεντρική κυψέλης, ορισμένη στο x - y επίπεδο. Η συντεταγμένη z δεν υπεισέρχεται στους υπολογισμούς, ενώ οι μεταβλητές x και y κυμαίνονται στο εύρος τιμών: $[-2.5 \text{ km}, 2.5 \text{ km}]$.
- Ο τομέας που εξυπηρετεί τον χρήστη, που παίρνει ακέραιες τιμές στο εύρος $[1,57]$ (εφόσον έχουμε σύστημα 19 σταθμών βάσης και 3 τομέων ανά σταθμό βάσης).
- Ο αριθμός των PRBs που ανατίθενται στον χρήστη, ο οποίος μεταβάλλεται για κάθε διαφορετικό dataset. Είναι φυσικά ακέραιος αριθμός, και υπάρχουν dataset με σταθερό αριθμό PRB για κάθε χρήστη, αλλά και με μεταβλητό αριθμό PRBs. Η δεύτερη περίπτωση είναι και πιο ρεαλιστική, αφού ο κάθε χρήστης χρησιμοποιεί υπηρεσίες με διαφορετικές απαιτήσεις όσον αφορά το εύρος ζώνης.
- Ο πίνακας (συνολικών) απωλειών διαδρομής από κάθε τομέα προς τον χρήστη. Σε αυτήν την περίπτωση έχουμε ένα διάνυσμα με μήκος ίσο με τον συνολικό αριθμό των τομέων, δηλαδή 57. Οι απώλειες διαδρομής (PL) υπολογίζονται σύμφωνα με το UMa NLOS σενάριο που παρουσιάστηκε, και σημειώνεται ότι

σε περίπτωση που οι απώλειες διαδρομής μεταξύ τερματικού και σταθμού βάσης υπερβαίνουν τα 160 dB, τότε ο χρήστης απορρίπτεται από το σύστημα. Από αυτόν τον αρχικό υπολογισμό, καταλήγουμε στις συνολικές απώλειες διαδρομής, στις οποίες συνεισφέρουν 3 ακόμα παράγοντες: ένας παράγοντας σχετικής εξασθένησης A , ο οποίος εξαρτάται από τη σχετική θέση του χρήστη και της γωνίας ακτινοβολήσης του σταθμού βάσης, και τα κατευθυντικά κέρδη των κεραιών σταθμού βάσης και τερματικού, τα οποία στην περίπτωσή μας είναι σταθερά και αντιστοιχούν σε 4 και 18 dB, αντιστοίχως. Ο τελικός υπολογισμός δίνεται από την ακόλουθη σχέση, ενώ παρατίθεται και ένα γράφημα με ενδεικτικές τιμές για δείγμα 400 χρηστών:

$$TL \text{ (dB)} = PL + A - G_b - G_m$$



Εικόνα 4.29 Απώλειες σε dB για ένα δείγμα 400 χρηστών

- Ο πίνακας MIMO, ο οποίος αποτελείται από τα κέρδη διαύλων. Στη δική μας περίπτωση έχουμε υποθέση 2 κεραιές εκπομπής και 2 κεραιές λήψης, επομένως ο πίνακας κερδών θα έχει για κάθε χρήστη διαστάσεις $2 \times 2 \times N$, όπου N είναι ο αριθμός των PRB που ανατίθενται σε κάθε χρήστη. Σε συστήματα όπου ο αριθμός αυτός μεταβάλλεται, επιλέγουμε τον μεγαλύτερο αριθμό που μπορεί να ανατεθεί, και για τους χρήστες που χρησιμοποιούν λιγότερα PRBs από αυτό

τον αριθμό, χρησιμοποιούμε παραγέμισμα με μηδενικά (zero padding), ώστε η διάσταση N να παραμένει σταθερή για όλους τους χρήστες. Οι τιμές του πίνακα είναι μιγαδικές, και μπορεί να γίνει αναπαράσταση είτε πραγματικού-μιγαδικού μέρους, είτε γωνίας-φάσης, καθώς οι τιμές εισόδου στο νευρωνικό δίκτυο θα πρέπει να είναι πραγματικοί και όχι φανταστικοί αριθμοί.

Αυτές είναι συνολικά οι κατηγορίες των χαρακτηριστικών που χρησιμοποιήθηκαν για την παραγωγή των Dataset που χρησιμοποιούμε σαν είσοδο στους αλγορίθμους μηχανικής μάθησης. Ο όγκος των Dataset, δηλαδή ο αριθμός των χρηστών, κυμαίνεται στο διάστημα $[20 \cdot 10^3, 100 \cdot 10^3]$, ενώ τα αποτελέσματα δεν επηρεάζονται ουσιαστικά από τον αριθμό των χρηστών, καθώς οι τιμές αυτές είναι επαρκείς για την εξαγωγή κατάλληλων συμπερασμάτων. Δοκιμές με μεγαλύτερο αριθμό χρηστών δεν οδήγησαν σε σημαντικές διαφοροποιήσεις.

Τα Dataset αυτά έχουν παραχθεί μέσω της επιστημονικής γλώσσας προγραμματισμού Matlab, στην οποία και είναι υλοποιημένο το κυψελωτό μας δίκτυο. Οι διαδικασίες που ακολουθούν όμως από αυτό το σημείο και στο εξής, συμπεριλαμβανομένης της προεπεξεργασίας δεδομένων, της υλοποίησης των αλγορίθμων και της εξαγωγής αποτελεσμάτων, έχουν υλοποιηθεί με βάση τη γλώσσα προγραμματισμού Python. Η Python είναι μια γλώσσα γενικού σκοπού, η οποία μάλιστα δεν είναι γρήγορη όσον αφορά την εκτέλεση των προγραμμάτων της. Ωστόσο, έχει καθιερωθεί ευρέως η χρήση της στον τομέα της Μηχανικής Μάθησης, χάρη στην απλότητα και την ευελιξία που παρέχει, την δυνατότητα για γρήγορη δημιουργία και έλεγχο (testing) προγραμμάτων, καθώς και στην κοινότητα που έχει δημιουργηθεί, με αποτέλεσμα οι βιβλιοθήκες και τα πλαίσια (frameworks) που βασίζονται στην Python να ενημερώνονται τακτικά και με συνέπεια, ακολουθώντας τις πιο πρόσφατες εξελίξεις στον τομέα.

Αξίζει να αναφέρουμε σε αυτό το σημείο τις βιβλιοθήκες της Python που χρησιμοποιήθηκαν στα πλαίσια της εργασίας. Αρχικά, σημαντικότερη ίσως είναι η Numpy, καθώς παρέχει λειτουργικότητα που αξιοποιείται από όλα τα επόμενα εργαλεία, στο κομμάτι της βελτιστοποίησης των επιστημονικών υπολογισμών, πολύ σημαντικό για πράξεις γραμμικής άλγεβρας και πινάκων. Παρέχει επίσης μεγάλο πλήθος συναρτήσεων για τη δημιουργία, το χειρισμό και την επεξεργασία κάθε είδους δομών δεδομένων. Η βιβλιοθήκη scikit-learn είναι επίσης ιδιαίτερα σημαντική, καθώς παρέχει υλοποιήσεις για τους περισσότερους ευρέως γνωστούς αλγορίθμους Μηχανικής Μάθησης, με σημαντικές δυνατότητες τόσο κατά την παραμετροποίηση, αλλά και κατά την εξαγωγή αποτελεσμάτων, καθώς και την οπτικοποίηση δεδομένων εισόδου και εξόδου. Τέλος, αξιοποιήθηκαν οι βιβλιοθήκες Tensorflow και Keras, οι οποίες παρουσιάζουν συμβατότητα (compatibility) με τις δομές δεδομένων της Numpy, και παρέχουν σημαντικές δυνατότητες για της κατασκευή νευρωνικών δικτύων, συμπεριλαμβανομένων των συνελκτικών νευρωνικών δικτύων (CNNs, Convolutional Neural Networks). Ο Keras αποτελεί ουσιαστικά μια φιλική προς το χρήστη, υψηλού επιπέδου διεπαφή για τον Tensorflow.

Το πρώτο στάδιο είναι η μετατροπή του Dataset από αρχείο τύπου .mat, το οποίο παίρνουμε από το Matlab, σε δομή array, η οποία χρησιμοποιείται από τις βιβλιοθήκες της Python. Η δομή αυτή παρέχει ευελιξία ως προς τη διαστασιοποίηση του πίνακα, ενώ έχει αναπτυχθεί μεγάλο πλήθος διαθέσιμων συναρτήσεων για κάθε

είδους χειρισμό αυτών των δομών. Ένας επίπεδος πίνακας που περιλαμβάνει όλα τα χαρακτηριστικά που αναφέραμε προηγουμένως θα έχει το εξής μήκος:

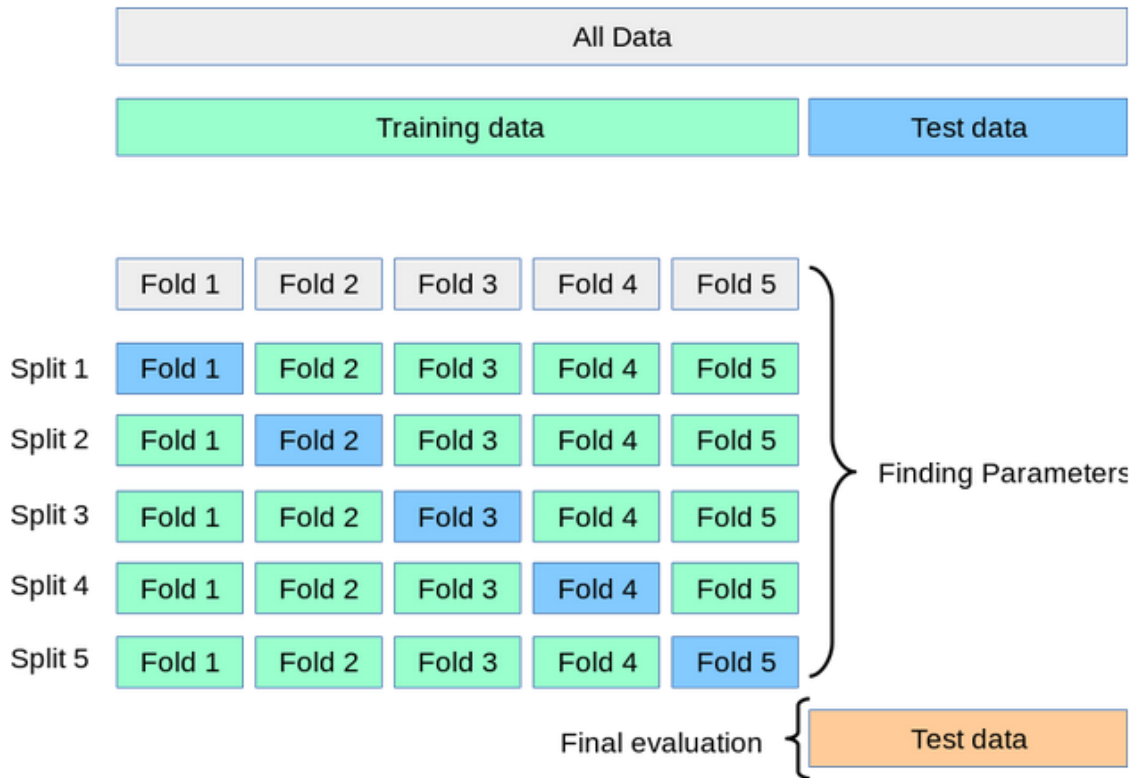
$$\begin{aligned} \text{Length} &= 2 + 1 + 1 + 57 + 2 \times 2 \times 2 \times n, \\ &= 61 + 8 \times n \end{aligned}$$

, όπου n ο μέγιστος αριθμός PRBs που ανατίθενται σε κάποιον χρήστη.

Στην προηγούμενη εξίσωση οι 3 όροι διαπλασιασμού προκύπτουν: από τους 2×2 πίνακες κερδών MIMO για κάθε PRB, και ο τελευταίος από τη διάσπαση κάθε μιγαδικού κέρδους, είτε σε πραγματικό-φανταστικό μέρος είτε σε μέτρο-φάση. Οι αναπαραστάσεις αυτές δεν θα αναφερθούν από εδώ και στο εξής, καθώς η χρήση τους οδηγεί σε πανομοιότυπα αποτελέσματα.

Επόμενο στάδιο προετοιμασίας των δεδομένων μας είναι ο διαχωρισμός σε σύνολα εκπαίδευσης (training data) και ελέγχου (test data). Ο διαχωρισμός αυτός είναι απαραίτητος για την εξαγωγή ορθών αποτελεσμάτων, καθώς πρέπει τα δεδομένα εκπαίδευσης να είναι ανεξάρτητα από τα δεδομένα ελέγχου, που στην περίπτωση μας σημαίνει να μην επαναλαμβάνονται. Σε περίπτωση που υπήρχε διπλοτυπία, τότε ο αλγόριθμος θα έβρισκε αυτόματα τις σωστές ετικέτες συγκρίνοντας τα διπλότυπα δείγματα, χωρίς όμως αυτό να βοηθάει στη βελτίωση της επίδοσης του αλγορίθμου όταν αυτός συναντήσει καινούρια σύνολα δεδομένων, που είναι και το ζητούμενο. Να σημειωθεί ότι ο διαχωρισμός αυτός γίνεται αυτόματα κατά την εκπαίδευση, από τις κλάσεις των βιβλιοθηκών του Keras που χρησιμοποιούνται για νευρωνικά δίκτυα. Η διασταυρωμένη επαλήθευση (cross-validation) είναι η προτιμώμενη μέθοδος, που αποτελεί ουσιαστικά την επαναλαμβανόμενη επιλογή training/data set για κάθε επανάληψη εκτέλεσης του νευρωνικού δικτύου στο σύνολό του, κατά το σχηματισμό του μοντέλου. Ακολουθεί στο σχηματικό ένα παράδειγμα της διαδικασίας, όπου ο διαχωρισμός είναι 80-20, δηλαδή το 80% των δεδομένων αποτελούν σε κάθε βήμα το σύνολο δεδομένων εκπαίδευσης, ενώ το 20% είναι το σύνολο των δεδομένων ελέγχου πάνω στο οποίο εξετάζεται η επίδοση του αλγορίθμου. Κάθε φορά τα σύνολα είναι αμοιβαίως αποκλειόμενα μεταξύ τους, εξασφαλίζοντας την επιθυμητή ανεξαρτησία σε κάθε βήμα.

Επόμενο βήμα είναι η κανονικοποίηση των δεδομένων εκπαίδευσης, που αναφέρεται στα αγγλικά με δύο διαφορετικούς όρους που έχουν διαφορετική σημασία: normalization και standardization. Σκοπός της κανονικοποίησης είναι η κατανομή των τιμών των διανυσμάτων χαρακτηριστικών με ομοιόμορφο τρόπο σε επιθυμητή κλίμακα, αντιμετωπίζοντας έτσι τις αρνητικές επιπτώσεις που μπορούν να έχουν δεδομένα με διαφορετικές πολώσεις (bias). Η κανονικοποίηση δεν έχει την ίδια αξία για κάθε αλγόριθμο μάθησης: είναι απαραίτητη σε μεθόδους που χρησιμοποιούν αποστάσεις σημείων για την ταξινόμηση, όπως ο kNN, αλλά δεν χρειάζεται σε περιπτώσεις όπως π.χ. τα δέντρα αποφάσεων, όπου ο διαχωρισμός κάθε κόμβου βασίζεται μόνο σε ένα χαρακτηριστικό και όχι σε ολόκληρο το διάνυσμα. Επίσης, αποφεύγουμε το φαινόμενο, χαρακτηριστικά με μεγαλύτερες τιμές να έχουν μεγαλύτερη επίδραση στο τελικό αποτέλεσμα, παρότι αυτό δεν αντικατοπτρίζει απαραίτητα τη σπουδαιότητά τους.



Εικόνα 4.30 Εναλλαγή των test folds για την επίτευξη του cross-validation

Η μέθοδος του normalization τοποθετεί τα χαρακτηριστικά σε μια εμβέλεια της επιλογής μας. Η πιο συνηθισμένη είναι στο εύρος $[0, 1]$, αλλά το εύρος αυτό μπορεί να μεταβάλλεται ανάλογα με τις ανάγκες του προβλήματος. Το κάθε χαρακτηριστικό μεταβάλλεται σύμφωνα με τη σχέση:

$$\dot{X} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Ενώ στην περίπτωση του standardization, έχουμε κανονικοποίηση ώστε τα κανονικοποιημένα δεδομένα να ακολουθούν την κανονική κατανομή, δηλαδή με μηδενική μέση τιμή και μοναδιαία διασπορά, σύμφωνα με τη σχέση:

$$\dot{X} = \frac{X - \mu_X}{\sigma_X}$$

Μετά από δοκιμές με διαφορετικούς συνδυασμούς αλγορίθμων και μεθόδων κανονικοποίησης, καταλήξαμε στη χρήση της κανονικής κατανομής για την κανονικοποίηση των δεδομένων, και αυτή η μέθοδος θα χρησιμοποιείται στο εξής, εκτός αν αναφερθεί κάτι διαφορετικό.

Στο κεφάλαιο 3 αναφερθήκαμε στην τεχνική **PCA** (Principal Component Analysis, Ανάλυση Κυρίαρχων Συνιστωσών), ως μία σημαντική μέθοδο για τη μείωση της διαστασιμότητας. Επανερχόμαστε σε αυτό το σημείο για να επισημάνουμε ότι μια επιπλέον λειτουργία που επιτελεί είναι και η γέννηση νέων χαρακτηριστικών, κατά την εφαρμογή της πάνω στο διάνυσμα χαρακτηριστικών. Η μέθοδος PCA αποτελεί

έναν γραμμικό μετασχηματισμό που προβάλλει τα αρχικά διανύσματα χαρακτηριστικών σε νέα διανύσματα μειωμένων διαστάσεων.

Η μέθοδος αυτή, εκτός από τη μείωση της διαστασιμότητας μέσω της δημιουργίας νέων ανεξάρτητων (για την ακρίβεια, ασυσχέτιστων) μεταξύ τους χαρακτηριστικών, παρουσιάζει ορισμένες χρήσιμες ιδιότητες, όπως η ελαχιστοποίηση του μέσου τετραγωνικού σφάλματος κατά την προσέγγιση με ένα νέων διάνυσμα χαρακτηριστικών μειωμένων διαστάσεων, και τελικά μια πολύ καλή διαχωριστικότητα των κλάσεων στον νέο, μικρότερον διαστάσεων, χώρο χαρακτηριστικών, αν και αυτή δεν είναι απαραίτητα βέλτιστη. Υπάρχουν και τροποποιήσεις της μεθόδου, όπως η μέθοδος Kernel PCA, που παράγει μη γραμμικά διανύσματα στον μειωμένο υπόχωρο, ωστόσο στην περίπτωσή μας χρησιμοποιήθηκε η κλασική μέθοδος για τους αλγόριθμους όπου θεωρήθηκε απαραίτητη η μείωση της διαστασιμότητας.

4.4 Αλγόριθμοι Μηχανικής Μάθησης

Στην ενότητα αυτή θα εξετάσουμε τους αλγόριθμους που χρησιμοποιήθηκαν τελικά για την παραγωγή μοντέλων και αποτελεσμάτων. Να σημειωθεί εδώ ότι εξετάστηκαν και άλλες μέθοδοι, ωστόσο η διαφοροποίηση στα αποτελέσματα δεν κρίθηκε επαρκής ώστε να συμπεριληφθούν.

4.4.1 Αλγόριθμος Κοντινότερου Γείτονα

Η πρώτη περίπτωση αλγορίθμου που χρησιμοποιήθηκε είναι οι αλγόριθμοι κοντινότερου γείτονα. Όπως αναφέραμε και στο κεφάλαιο 3, ο βασικός τρόπος λειτουργίας του kNN είναι ιδιαίτερα απλός : με τον υπολογισμό των k πλησιέστερων, δηλαδή «γειτονικών» δειγμάτων, βρίσκουμε την κατηγορία που πλειοψηφεί και την αναθέτουμε στο δείγμα που εξετάζουμε. Η μετρική της απόστασης που χρησιμοποιούμε είναι η Ευκλείδεια (L_2 νόρμα), μετά από πειραματισμό και με άλλες επιλογές, όπως η απόσταση Manhattan (L_1 νόρμα) και Mahalanobis. Ο αριθμός k θα θεωρείται ότι είναι 3 στη συνέχεια, εκτός αν αναφέρεται ρητά κάποια διαφορετική επιλογή.

Είναι σημαντικό να αναφέρουμε ότι στην περίπτωση του kNN έχει χρησιμοποιηθεί αρχικά η μέθοδος PCA, για τη μείωση της πολυπλοκότητας, η οποία είναι πολύ υψηλή για τη συγκεκριμένη κατηγορία αλγορίθμων. Με την PCA, μειώνουμε τη διαστασιμότητα, καταλήγοντας σε υπόχωρο διάστασης $N=68$.

Επίσης, πρέπει να διευκρινιστεί σε αυτό το σημείο ο τρόπος εφαρμογής του αλγορίθμου για την multi-label ταξινόμηση που επιχειρούμε. Ο χώρος των κλάσεων είναι ιδιαίτερα μεγάλος (132, όσα είναι και τα PRBs), και επιλέγουμε σε κάθε περίπτωση περισσότερες από μία κλάσεις. Για να το αντιμετωπίσουμε αυτό, θα μπορούσαμε να υλοποιήσουμε τον kNN ώστε να επιλέγει περισσότερες από μία κλάσεις για κάθε δείγμα. Αυτή η προσέγγιση όμως θα οδηγούσε σε επιλογή πολύ μεγάλου k , καθώς υπάρχουν Dataset όπου οι χρήστες λαμβάνουν μέχρι και 15 PRBs. Επομένως, το πρόβλημά μας διασπάται σε 132 δυαδικά προβλήματα, όπου η ανάθεση ή μη του κάθε PRB εξετάζεται ξεχωριστά και ανεξάρτητα από τα υπόλοιπα. Στο τέλος μπορούμε να δούμε ποια PRBs έχουν επιλεγεί για κάθε χρήστη σύμφωνα με τη

μέθοδο, ωστόσο δεν μπορούμε να περιορίσουμε τον αριθμό που έχει επιλεγεί, κάτι που αποτελεί ένα μειονέκτημα της συγκεκριμένης μεθόδου.

4.4.2 Αλγόριθμος δάσους από δέντρα CART

Επόμενη μέθοδος που αξιοποιούμε είναι τα δέντρα παλινδρόμησης και ταξινόμησης (CART), που αναφέρθηκαν στο κεφάλαιο 3. Όπως εξηγήθηκε, ο αλγόριθμος CART δημιουργεί κόμβους οι οποίοι διαχωρίζουν τα δείγματα σε διαφορετικές κλάσεις, ανάλογα με τις ιδιότητές τους. Στην πιο γενική περίπτωση των δέντρων έχουμε έναν συμψηφισμό διαφορετικών δέντρων ταξινόμησης που έχουν δημιουργηθεί, ώστε τελικά να ανεβαίνει η επίδοση της τελικής ταξινόμησης.

Για το δέντρα που χρησιμοποιούμε, επιλέγουμε ο αριθμός των χαρακτηριστικών βάση των οποίων γίνεται ο διαχωρισμός στους κόμβους να ισούται με 13, ως πλησιέστερη τετραγωνική ρίζα του συνολικού πλήθους των χαρακτηριστικών μας, κάτι που αποτελεί μια τυπική επιλογή. Ο αριθμός των δειγμάτων που απαιτούνται για τον διαχωρισμό σε έναν κόμβο επιλέγεται να είναι 4, μια συντηρητική επιλογή ώστε να αποφεύγεται το overfitting, αλλά και να υπάρχει επαρκής πληροφορία σύμφωνα με την οποία θα γίνει ο διαχωρισμός. Ταυτόχρονα, εισάγουμε και μεγαλύτερα βάρη στη μειοψηφούσα κλάση, δηλαδή το 1 που αντιστοιχεί στην απόδοση του PRB στον χρήστη, ώστε το δέντρο που θα προκύψει να είναι ισορροπημένο και να αποφεύγεται πιθανή μεροληψία (bias) υπέρ της κλάσης που πλειοψηφεί, δηλαδή το 0 που αντιστοιχεί σε μη απόδοση PRB. Να σημειωθεί ότι στην περίπτωση εφαρμογής PCA για την μείωση του χώρου χαρακτηριστικών, τότε δεν χρειάζεται να μειώσουμε ιδιαίτερα τον αριθμό των χαρακτηριστικών που χρησιμοποιούνται για τον διαχωρισμό.

Τελικά για την κατασκευή του δάσους που χρησιμοποιούμε για την ταξινόμηση, αξιοποιούνται τα επιμέρους δέντρα με αξιοποίηση του μέσου όρου (averaging) των αποτελεσμάτων τους. Δημιουργούμε το δάσος από 10 ή 20 δέντρα, καθώς μεγαλύτερος αριθμός δέντρων δεν οδηγεί σε ουσιαστική βελτίωση των αποτελεσμάτων, ενώ ο χρόνος εκτέλεσης αυξάνεται γραμμικά μεν, αλλά είναι ήδη πολύ μεγάλος ακόμα και για μικρό αριθμό ταξινομητών.

4.4.3 Συνελικτικό Νευρωνικό Δίκτυο (CNN)

Τελευταία και σημαντικότερη μέθοδος που χρησιμοποιούμε στα πλαίσια της εργασίας αυτής είναι η χρήση νευρωνικών δικτύων, και πιο συγκεκριμένα ενός συνελικτικού νευρωνικού δικτύου (Convolutional Neural Network, CNN). Η δημιουργία του δικτύου έγινε με χρήση των βιβλιοθηκών Keras που χρησιμοποιεί Tensorflow σαν framework. Οι βιβλιοθήκες του Keras παρέχουν μεγάλο εύρος λειτουργικότητας, χωρίς να είναι απαραίτητη η υλοποίηση του δικτύου από το μηδέν, ώστε να έχει τη δυνατότητα αυτός που τον χρησιμοποιεί να εστιάζει στις λεπτομέρειες της υλοποίησης και την παραμετροποίηση του δικτύου. Ας δούμε βασικές έννοιες για την παραμετροποίηση του συνελικτικού δικτύου:

- `Batch_size`: είναι ο αριθμός των δειγμάτων εισόδου (χρηστών) που το μοντέλο χρησιμοποιεί κάθε φορά για την ενημέρωση των βαρών σε κάθε νευρώνα. Στην

περίπτωση μας, προτιμάμε την τιμή 64, μετά από δοκιμές με διαφορετικές τιμές. Αυτό σημαίνει ότι το δίκτυο λαμβάνει κάθε φορά 64 δείγματα, τα μεταδίδει μέσα από το δίκτυο και ενημερώνει τις τιμές των βαρών. Η διαδικασία αυτή επαναλαμβάνεται με τα επόμενα 64 δείγματα, μέχρι να χρησιμοποιηθούν όλα τα δείγματα των δεδομένων εκπαίδευσης.

- **Epoch:** Η παραπάνω διαδικασία μπορεί να επαναληφθεί πολλές φορές, ώστε κάθε φορά να βελτιώνεται η επίδοση. Κάθε επανάληψη της διαδικασίας για όλα τα δεδομένα εκπαίδευσης, αποτελεί ένα epoch. Στην παρούσα εργασία χρησιμοποιήθηκαν τιμές στο διάστημα [50,150], και όπως θα δούμε, από ένα σημείο και μετά, μεγαλύτερες τιμές μπορεί να οδηγήσουν το μοντέλο να προσαρμοστεί στα δεδομένα εισόδου πολύ καλά, χωρίς να βελτιώνεται η επίδοσή του σε νέα δεδομένα που δεν έχει δει (overfitting).
- **Validation_split:** όπως αναφέρουμε και στην ενότητα 3, πρέπει να κρατήσουμε και ένα μέρος του dataset για επαλήθευση των αποτελεσμάτων. Το σύνολο επαλήθευσης (validation_set) είναι αυτό που μας ενδιαφέρει όσον αφορά τα αποτελέσματα, καθώς το μοντέλο δεν έχει πρόσβαση σε αυτό κατά την εκπαίδευσή του, και αποτελεί επομένως άγνωστο σύνολο δεδομένων και κατάλληλο για αξιολόγηση του μοντέλου. Το ποσοστό διαχωρισμού που χρησιμοποιήθηκε είναι 80-20 (80% δεδομένα εκπαίδευσης και 20% δεδομένα επαλήθευσης). Να σημειωθεί ότι σε κάθε epoch, γίνεται ανακατανομή των δεδομένων στα 2 υποσύνολα, επιτυγχάνοντας έτσι το cross-validation.
- **Class_weight:** καθώς στα δεδομένα μας, η πιθανότητα απόδοσης PRBs μικρότερη κατά μία τάξη μεγέθους από την αντίθετη περίπτωση (μη απόδοσης), αναθέτουμε ένα ανάλογο βάρος στα δείγματα με ετικέτα 1, ώστε να ληφθούν περισσότερο υπόψη κατά τη διαδικασία της εκπαίδευσης του μοντέλου.
- **Loss:** αυτή είναι η μετρική που χρησιμοποιείται από το μοντέλο για να γνωρίζει με ποιον τρόπο πρέπει να ενημερώσει τα βάρη ώστε να βελτιώσει την επίδοσή του. Εμείς χρησιμοποιούμε την focal_loss, η οποία είναι ιδανική για περιπτώσεις ανισορροπίας μεταξύ των διαφορετικών κλάσεων, όπως είναι η δική μας. Αυτό το πετυχαίνει δίνοντας μεγαλύτερους συντελεστές στα σπανιότερα δείγματα, και κάνοντας έτσι ευκολότερη την ανίχνευσή τους σε μελλοντικές επαναλήψεις [19]. Με αυτή την μετρική απωλειών ενσωματώνουμε τον υπολογισμό των βαρών για κάθε κατηγορία, που αναφέρθηκε παραπάνω.
- **Optimizer:** εδώ επιλέγουμε τη μέθοδο Adam, που αποτελεί μια τροποποίηση της κλασικής μεθόδου διαβάθμισης κλίσης (gradient descent), που χρησιμοποιεί όμως προσαρμοστική εκτίμηση για τους όρους 1^{ης} και 2^{ης} τάξης, βελτιώνοντας έτσι τη διαδικασία μάθησης και κάνοντάς την πιο αποδοτική από άποψη χρησιμοποίησης χρόνου και (υπολογιστικής) μνήμης.

- `learning_rate` : αποτελεί την ταχύτητα εκμάθησης για το μοντέλο. Υπερβολικά μεγάλες τιμές μπορεί να μην επιτρέψουν τη σύγκλιση του μοντέλου σε επιθυμητές τιμές και καταστάσεις για τους νευρώνες, ενώ αντίθετα αν η τιμή είναι πολύ μικρή τότε η σύγκλιση θα είναι πολύ αργή. Εμείς χρησιμοποιήσαμε τιμή 10^{-3} , ως πιο κατάλληλη για την επίτευξη σύγκλισης με ικανοποιητικούς ρυθμούς.


Το βασικό μπλοκ για το συνελκτικό δίκτυο αποτελείται από ένα συνελκτικό layer και ένα layer Max-pooling. Τοποθετούμε ακολουθιακά 2 τέτοια μπλοκ, και στο τέλος χρησιμοποιούμε ένα Flattening layer, που χρησιμοποιούμε για την μετατροπή των δεδομένων σε διάνυσμα 2 διαστάσεων. Το μέγεθος των παραθύρων συνέλιξης που χρησιμοποιούμε είναι 3×3 και στα δύο συνελκτικά layers, με βάθος 16 και 32 φίλτρων αντίστοιχα, ενώ τα παράθυρα στα στρώματα συμπίεσης Max-Pooling είναι 2×2 , με μετακίνηση μία θέση κάθε φορά. Για την εξομάλυνση μετά το μπλοκ των συνελίξεων χρησιμοποιούμε δύο επίπεδα στρώματα Dense, με 200 και 132 νευρώνες αντίστοιχα, μεταξύ των οποίων τοποθετούμε ένα στρώμα Dropout, που ουσιαστικά μειώνει τον αριθμό των νευρώνων του προηγούμενου επιπέδου κατά 50%, πολλοί από τους οποίους πλεονάζουν, καθώς έχουν παρόμοια βάρη. Να αναφερθεί εδώ, ότι πρέπει οπωσδήποτε σε ένα πρόβλημα multi-label όπως είναι το δικό μας, να χρησιμοποιηθεί η συνάρτηση ενεργοποίησης sigmoid πριν την έξοδο, ώστε το άθροισμα πιθανοτήτων όλων των κλάσεων για κάθε δείγμα να ισούται με τη μονάδα.

5. ΑΠΟΤΕΛΕΣΜΑΤΑ ΠΡΟΣΟΜΟΙΩΣΕΩΝ


Στην ενότητα αυτή παρουσιάζουμε τα αποτελέσματα των προσομοιώσεων που έχουν εκτελεστεί με χρήση εκπαιδευμένων ML μοντέλων, τα οποία εκπαιδεύτηκαν αρχικά πάνω στα Dataset που δημιουργήσαμε και στη συνέχεια έκαναν την ανάθεση των υποφερόντων. Συγκρίνουμε τα αποτελέσματα που έχουν παραχθεί για διαφορετικούς αλγορίθμους μάθησης, διαφορετικά σύνολα δεδομένων και διαφορετική παραμετροποίηση. Επίσης ελέγχουμε σε ποιες περιπτώσεις έχουμε καλύτερα αποτελέσματα σε αναλογία με τον τρόπο που γίνεται η ανάθεση καναλιών, καθώς και σε σχέση με την a priori γνώση ή μη του αριθμού των καναλιών που ανατίθενται, στις περιπτώσεις όπου κρίνουμε ότι η γνώση αυτή μπορεί να είναι ωφέλιμη.

Σχετικά με την παραμετροποίηση, είναι σημαντικό να αναφερθεί ότι ο αριθμός των παραμέτρων για κάθε αλγόριθμο, και ιδιαίτερα για τα CNN, είναι πολύ μεγάλος, κάτι που περιπλέκει την σύγκριση των αποτελεσμάτων για διαφορετικούς συνδυασμούς. Ωστόσο, μετά από πολλές δοκιμές, καταλήξαμε στο συμπέρασμα ότι κάποιες παράμετροι δεν επηρεάζουν καθοριστικά τα αποτελέσματα εφόσον παραμείνουν εντός συγκεκριμένων εμβλειών. Επομένως, χάρην ευκολίας της παρουσίασης των αποτελεσμάτων, αυτές οι παράμετροι θα θεωρηθούν στη συνέχεια σταθερές. Το ίδιο ισχύει και για την αρχιτεκτονική του δικτύου CNN. Την αρχιτεκτονική αυτή, καθώς και τις εμβλείες που επιλέξαμε για διαφορετικές παραμέτρους που θεωρήσαμε σταθερές, έχουμε αναφέρει και στην προηγούμενη ενότητα.

Σημαντικό είναι να δούμε αρχικά την περίπτωση του overfitting. Όπως αναφέρθηκε και στην ενότητα 3, το overfitting συμβαίνει όταν το μοντέλο προσαρμόζεται υπερβολικά στα δεδομένα εκπαίδευσης, με συνέπεια τα αποτελέσματα ταξινόμησης να είναι εξαιρετικά σε αυτά τα δεδομένα που ήδη έχει δει, αλλά να μην γενικεύονται και σε καινούρια δεδομένα (δεδομένα επαλήθευσης ή δεδομένα ελέγχου). Αυτό το φαινόμενο παρατηρείται και στο μοντέλο CNN που χρησιμοποιούμε, στην περίπτωση που δεν δώσουμε βάρη για τα δείγματα που αντιστοιχούν σε ανάθεση και μη-ανάθεση καναλιού. Αυτό φαίνεται και στα παρακάτω διαγράμματα, όπου έχουν χρησιμοποιηθεί 150 epochs. Βλέπουμε ότι η ταξινόμηση από ένα σημείο και μετά βελτιώνεται μονάχα για τα δεδομένα εκπαίδευσης, αφού πλέον τα έχει «αποστηθίσει», χωρίς αυτό ωστόσο να συμβαίνει και για τα δεδομένα ελέγχου, τα οποία δεν έχει δει. Αυτό συμβαίνει τόσο για το accuracy όσο και για το F1-Score, που μας ενδιαφέρει και περισσότερο.




Εικόνα 5.31 Overfitting με βάση την εξέλιξη του Accuracy




Εικόνα 5.32 Overfitting με βάση την εξέλιξη του F1-Score

Το ίδιο φαινόμενο είναι ωστόσο λιγότερο έντονο, αν μεγαλώσουμε τα βάρη για δείγματα που αντιστοιχούν σε ανάθεση καναλιών. Αυτό το πετυχαίνουμε αλλάζοντας τις τιμές των παραμέτρων α και β , της συνάρτησης απωλειών που έχουμε χρησιμοποιήσει, focal_loss . Στην περίπτωση αυτή έχουμε $\beta=1$ και $\alpha=0.9$.



Εικόνα 5.33 Μείωση του overfitting με χρήση $a=0.9$ βάσει του Accuracy



Εικόνα 5.34 Μείωση του overfitting με χρήση $a=0.9$ βάσει του $F1$ -Score

Παρατηρούμε λοιπόν ότι οι αποκλίσεις μεταξύ δεδομένων και ελέγχου είναι πολύ μικρότερες, αν αυξήσουμε τα βάρη των δειγμάτων με ανατιθέμενα κανάλια. Να σημειωθεί ότι τα ίδια συμπεράσματα εξάγονται και με τη μείωση των διαστάσεων των χαρακτηριστικών μέσω PCA στην πρώτη περίπτωση, δηλαδή το overfitting δεν απομειώνεται, κάτι που είναι αναμενόμενο, καθώς το δίκτυο CNN καλύπτει το overfitting με τα επίπεδα Dropout που αναφέρθηκαν στην προηγούμενη ενότητα, καθώς και με το regularization που ενσωματώνεται σε αυτά.


5.1 Συγκριτικά αποτελέσματα αλγορίθμων

Σε αυτό το σημείο θα δούμε τα αποτελέσματα των διαφορετικών αλγορίθμων που εξετάστηκαν. Οι αλγόριθμοι που συγκρίνονται είναι: ο αλγόριθμος kNN, με $k=3$, ο αλγόριθμος CART, ο αλγόριθμος Random Forest, που χρησιμοποιεί 10 δέντρα CART και το συνελκτικό νευρωνικό δίκτυο που παρουσιάστηκε στην προηγούμενη ενότητα. Αρχικά θα ελέγξουμε την περίπτωση όπου δεν υπάρχει γνώση του αριθμού των αποδιδόμενων καναλιών, κατά την εξαγωγή των αποτελεσμάτων. Κάνουμε παράλληλα και σύγκριση αποτελεσμάτων για 3 διαφορετικά dataset:


- Το πρώτο dataset αφορά δίκτυο όπου αποδίδεται σταθερός αριθμός 6 PRBs σε κάθε χρήστη που εισέρχεται και γίνεται αποδεκτός. Ο αριθμός 6 επιλέχθηκε ως διαιρέτης των συνολικών 132 PRBs των σταθμών βάσης, για λόγους ευκολίας.

- Το δεύτερο dataset αφορά μεταβλητό αριθμό PRBs, τα οποία αποδίδονται με τρόπο ακολουθιακό στους χρήστες, επομένως κάθε χρήστης χρησιμοποιεί πάντα γειτονικά κανάλια.
- Το τρίτο dataset αφορά και πάλι μεταβλητό αριθμό PRBs, όπου όμως η απόδοση δεν γίνεται ακολουθιακά, επομένως τα κανάλια που λαμβάνει ο κάθε χρήστης δεν ανήκουν απαραίτητα σε γειτονικές συχνότητες.

Παρουσιάζουμε ξεχωριστά τα αποτελέσματα, τόσο για το accuracy όσο και για το F1-Score.




Εικόνα 5.35 Συγκριτικά αποτελέσματα Accuracy για διαφορετικούς αλγόριθμους




Εικόνα 5.36 Συγκριτικά αποτελέσματα *F1-Score* για διαφορετικούς αλγόριθμους

Εδώ βλέπουμε ότι το accuracy παραμένει υψηλό, σε αντίθεση με τα χαμηλά επίπεδα του *F1-Score*, πράγμα που οφείλεται σε πολύ χαμηλά ποσοστά ανάθεσης καναλιών. Πράγματι, η υψηλή ακρίβεια προκύπτει από τα ορθώς μη-ανατιθέμενα κανάλια (TP, true positive), κάτι που φυσικά δεν συμβαίνει με το *F1-Score*, το οποίο παραμένει χαμηλό ακριβείας λόγω του χαμηλού ποσοστού ανάθεσης των καναλιών που θα έπρεπε να έχουν δοθεί (FN, False Negatives). Το *F1-Score* βλέπουμε ότι είναι υψηλότερο για την περίπτωση τυχαίας ανάθεσης, για τους 3 αλγόριθμους (CNN, CART, Forest) εκτός από τον kNN. Το accuracy μειώνεται για τις περιπτώσεις μεταβλητού αριθμού PRBs και για τις 4 περιπτώσεις, κάτι που οφείλεται σε αύξηση των λανθασμένων αποδόσεων, εκτός από τις 3 περιπτώσεις που προαναφέρθηκαν.

Στη συνέχεια πραγματοποιούμε την ίδια σύγκριση για την περίπτωση όπου ο αριθμός των καναλιών που αποδίδονται ανά χρήστη είναι διαθέσιμος σαν a-priori γνώση στο κανάλι. Η περίπτωση αυτή είναι πιο ρεαλιστική για ένα κυψελωτό δίκτυο ακόμα και υπό συνθήκες πραγματικού χρόνου, τόσο φυσικά στην περίπτωση σταθερού αριθμού αποδιδόμενων PRBs, όσο και στην περίπτωση μεταβλητού αριθμού, καθώς ο αριθμός αυτός προσαρμόζεται στις ανάγκες του χρήστη και έχει γίνει γνωστός πριν την διαδικασία ανάθεσης.



Εικόνα 5.37 Σύγκριση αλγορίθμων στο Accuracy, με *a priori* γνώση




Εικόνα 5.38 Σύγκριση αλγορίθμων στο F1-Score, με *a priori* γνώση

Βλέπουμε ότι τώρα έχουμε βελτιώσει σημαντικά τον αριθμό των ορθών αποδόσεων (TPs), κάτι που είναι αναμενόμενο, καθώς έχουμε πλέον αυξήσει την prior πληροφορία βάσει της οποίας κάνουμε την επιλογή μας. Εδώ παρατηρούμε ότι η μείωση του accuracy στις περιπτώσεις μεταβλητών PRBs/χρήστη, δηλαδή τις μωβ και μπλε στήλες, συνοδεύεται από αύξηση του F1-Score, δηλαδή αύξηση των ορθών αποδόσεων, κάτι που είναι και επιθυμητό. Βέβαια με την αύξηση των TPs, η μείωση

του accuracy προέρχεται από την αύξηση των FP (False Positive), κανάλια δηλαδή τα οποία κακώς έχουν αποδοθεί.


5.2 Αποτελέσματα σύγκρισης παραμετροποίησης συνάρτησης απωλειών (focal loss)

Ένα ακόμη πεδίο όπου παρουσιάζει ενδιαφέρον όσον αφορά τα αποτελέσματα που προκύπτουν, είναι η σύγκριση διαφορετικών παραμετροποιήσεων της συνάρτησης απωλειών. Όπως ήδη αναφέραμε, με τις παραμέτρους a και g μπορούμε να δίνουμε μεγαλύτερη έμφαση στα δείγματα που αντιστοιχούν σε ανάθεση καναλιών με τιμή 1 και τα οποία μειοψηφούν. Η αναλογία δειγμάτων που αντιστοιχούν σε ανάθεση προς μη ανάθεση είναι περίπου $\frac{1}{11}$ για το σύνολο δεδομένων μεταβλητού αριθμού PRBs/χρήστη. Έτσι αναμένουμε ότι μια καλή τιμή για την παράμετρο a είναι περίπου 0.9. Επομένως, κοντά σε αυτήν την περιοχή τιμών δοκιμάσαμε διαφορετικούς συνδυασμούς για τις παραμέτρους a και g , διατηρώντας το γινόμενο τους κοντά στο 1.




Εικόνα 5.39 Αποτελέσματα CNN για διαφορετική παραμετροποίηση συνάρτησης απωλειών

Αρχικά βλέπουμε την σύγκριση για αυξανόμενες τιμές του a , χωρίς a priori γνώση του αριθμού των καναλιών που ανατίθενται ανά χρήστη, όπου αρχικά εξετάζουμε την περίπτωση όπου δεν χρησιμοποιούνται διαφορετικά βάρη για τα δείγματα 0 και 1. Παρατηρούμε ότι το F1-Score αυξάνεται με την αύξηση του a , κάτι που είναι αναμενόμενο εφόσον δίνεται μεγαλύτερη έμφαση στα δείγματα που αντιστοιχούν σε ανάθεση καναλιού (True Positives). Ταυτόχρονα ωστόσο μειώνεται το συνολικό Accuracy, καθώς υπεισέρχονται και ανεπιθύμητες αναθέσεις (False Positives) στα τελικά αποτελέσματα.



Εικόνα 5.40 Αποτελέσματα CNN για διαφορετική παραμετροποίηση συνάρτησης απωλειών με *prior* γνώση

Στην συνέχεια βλέπουμε την ίδια συμπεριφορά με την αύξηση του a , στην περίπτωση αυτή όμως έχουμε *prior* γνώση για τον αριθμό των καναλιών ανάθεση σε κάθε χρήστη. Η βελτίωση του F1-Score σε αυτήν την περίπτωση είναι μικρότερη με την αύξηση του a , δεν υπάρχει όμως η αντίστοιχη μείωση του accuracy, που σημαίνει ότι αποφεύγεται σε μεγαλύτερο βαθμό η λανθασμένη ανάθεση καναλιών (False Positives). Αυτός επομένως είναι και ο συμβιβασμός που προκύπτει από την *prior* γνώση των αναθέσεων για τους χρήστες.



Εικόνα 5.41 Αποτελέσματα με επιλογή ML ακολουθίας PRBs

Τέλος, παρατίθεται και η σύγκριση των αποτελεσμάτων όταν έχουμε ανάθεση με εντοπισμό της ακολουθίας μέγιστης πιθανοφάνειας (ML, Maximum Likelihood), κάτι που φυσικά προϋποθέτει και πάλι prior γνώση του αριθμού καναλιών στον χρήστη. Σε αυτήν την περίπτωση βλέπουμε ότι οι αποκλίσεις είναι πολύ μικρότερες με την μεταβολή του a . Παραθέτουμε και τους πίνακες τιμών για τις 3 περιπτώσεις (φυσικά αυτές είναι οι τιμές που έχουν προκύψει στο τέλος της όλης διαδικασίας για την περίπτωση των δεδομένων επαλήθευσης).

Πίνακας 1 : Αποτελέσματα χωρίς prior γνώση αριθμού PRBs/χρήστη

| | $a=0.5, g=2$ | $a=0.87, g = 1.5$ | $a=0.88, g=1.2$ | $a=0.9, g = 1$ |
|----------|--------------|-------------------|-----------------|----------------|
| Accuracy | 0.92 | 0.89 | 0.86 | 0.61 |
| F1-Score | 0.11 | 0.14 | 0.17 | 0.21 |

Πίνακας 2: Αποτελέσματα με prior γνώση αριθμού PRBs/χρήστη


| | $a=0.5, g=2$ | $a=0.9, g=1$ | $a=0.87, g = 1.5$ | $a=0.88, g=1.2$ |
|----------|--------------|--------------|-------------------|-----------------|
| Accuracy | 0.85 | 0.86 | 0.85 | 0.85 |
| F1-Score | 0.16 | 0.18 | 0.13 | 0.15 |

Πίνακας 3 : Αποτελέσματα με επιλογή ML ακολουθίας


| | $a=0.5, g=2$ | $a=0.9, g=1$ | $a=0.87, g = 1.5$ | $a=0.88, g=1.2$ |
|----------|--------------|--------------|-------------------|-----------------|
| Accuracy | 0.85 | 0.85 | 0.85 | 0.86 |
| F1-Score | 0.13 | 0.16 | 0.14 | 0.15 |

5.3 Σύγκριση αποτελεσμάτων ανά αριθμό αποδιδόμενων PRBs

Τέλος, ένας τρόπος να λάβουμε μια καλύτερη ενόραση σχετικά με τις αναθέσεις που προκύπτουν με βάση το CNN μοντέλο, μπορούμε να προχωρήσουμε σε διάσπαση του dataset σε επιμέρους σύνολα, όπου το καθένα περιλαμβάνει χρήστες που λαμβάνουν τον ίδιο αριθμό αναθέσεων. Επομένως προκύπτουν 6 επί μέρους σύνολα δεδομένων για τα οποία παρουσιάζουμε μια σύγκριση όσον αφορά τα accuracy και F1-Score.



Εικόνα 5.42 Σύγκριση αποτελεσμάτων Accuracy για υποσύνολα χρηστών με διαφορετικό αριθμό PRBs



Εικόνα 5.43 Σύγκριση αποτελεσμάτων F1-Score για υποσύνολα χρηστών με διαφορετικό αριθμό PRBs

Εδώ βλέπουμε λοιπόν ότι στις περιπτώσεις ανάθεσης 5, 10 ή 15 PRBs υπάρχει μια άύξηση στο F1-Score όσο ανατίθενται περισσότερα PRBs, κάτι που ενδεχομένως έχει να κάνει με τον μεγαλύτερο αριθμό και επομένως ποικιλία δειγμάτων για τους χρήστες που λαμβάνουν περισσότερα φέροντα. Παρατηρούμε όμως και κάτι αξιοσημείωτο: η ανάθεση καναλιών είναι απεγάδιαστη για τους χρήστες που βρίσκονται στην «ουρά» των διαθέσιμων καναλιών κάθε σταθμού βάσης, όπου η

ανάθεση έχει οριστεί να γίνεται με τρόπο τέτοιο ώστε να ανατίθενται όλα τα κανάλια, καθώς έχουμε 132 PRBs συνολικά. Το CNN λοιπόν επιτυγχάνει λοιπόν να προσδιορίσει αυτήν την συμπεριφορά ανάθεσης με εξαιρετική ακρίβεια για τους χρήστες που λαμβάνουν τα τελευταία κανάλια κάθε σταθμού, σε αντίθεση με όλους τους προηγούμενους χρήστες στους οποίους η ανάθεση καναλιών γίνεται με τυχαίο τρόπο, και στην ακολουθιακή και στην τυχαία περίπτωση.

6. ΕΠΙΛΟΓΟΣ

Σκοπός της παρούσας εργασίας ήταν η μελέτη, αξιοποίηση και αξιολόγηση διαφορετικών αλγορίθμων Μηχανικής Μάθησης, με έμφαση στη Βαθιά Μάθηση και τα συνελκτικά νευρωνικά δίκτυα (CNNs), για την βελτιστοποίηση της παραμετροποίησης ενός κυψελωτού δικτύου κινητών επικοινωνιών. Συγκεκριμένα μας ενδιαφέρει η ανάθεση ραδιοπόρων, πιο συγκεκριμένα φάσματος με τη μορφή υποφερόντων, σε κάθε χρήστη που εισέρχεται επιτυχώς στο δίκτυο, η οποία είναι και ο στόχος προς τον οποίο εκπαιδεύτηκαν τα μοντέλα που χρησιμοποιήσαμε.

Το δίκτυο που χρησιμοποιούμε έχει σχεδιαστεί σύμφωνα με το πρότυπο TR 38.901 (version 16.1.0) του 3GPP, και αποτελεί ένα 5G κυψελωτό δίκτυο στο οποίο ανατίθενται φασματικά υποφέροντα με την μορφή των PRBs κατά την εισαγωγή χρηστών. Καθώς το δίκτυο που επιλέχθηκε αποτελείται από 2 επίπεδα και η χωρητικότητα είναι περιορισμένη, αναλόγως και του αριθμού των PRBs που ανατίθενται ανά χρήστη, για την παραγωγή των datasets χρησιμοποιήθηκαν πολλαπλές επαναλήψεις της διαδικασίας εισαγωγής χρηστών στο δίκτυο, μέχρι αυτό κάθε φορά να αποδώσει όλα τα διαθέσιμα PRBs από κάθε σταθμό βάσης.

Αυτά είναι και τα σύνολα δεδομένων που χρησιμοποιήθηκαν σαν είσοδος στους αλγορίθμους μηχανικής μάθησης που χρησιμοποιήσαμε. Τα datasets αυτά παρουσιάζουν ποικιλομορφία όσον αφορά τον αριθμό των PRBs που λαμβάνουν οι χρήστες, καθώς και το αν ο αριθμός των PRBs είναι σταθερός ή μεταβάλλεται τυχαία για κάθε χρήστη.

Για την αξιολόγηση των ML αλγορίθμων χρησιμοποιήθηκαν οι μετρικές Accuracy και F1-Score, όπου η χρήση του 2^{ου} ήταν απαραίτητη, ώστε να δοθεί έμφαση στις περιπτώσεις όπου επιθυμούμε την ορθή απόδοση καναλιών στους χρήστες. Παρατηρήσαμε ότι είναι ιδιαίτερα σημαντική η παραμετροποίηση των δικτύων που χρησιμοποιήθηκαν, ώστε να αντιμετωπίζεται το φαινόμενο του overfitting. Τα μοντέλα που τελικά εκπαιδεύτηκαν ωστόσο δεν κατάφεραν να πετύχουν ιδιαίτερα υψηλά F1-Score, εκτός από την περίπτωση απόδοσης μεταβλητού αριθμού PRBs ανά χρήστη, όπου το δίκτυο CNN φαίνεται να αναγνωρίζει τη μεθοδολογία απόδοσης PRBs για τις περιπτώσεις των χρηστών που εισάγονται πριν από την πλήρη απόδοση όλων των 132 PRBs ενός σταθμού βάσης.

Μελλοντικές επεκτάσεις

Για την περαιτέρω διερεύνηση της αξιοποίησης τεχνικών ML στο πεδίο των κινητών επικοινωνιών, υπάρχει η δυνατότητα επέκτασης των πλαισίων αυτής της εργασίας, τόσο από τηλεπικοινωνιακή σκοπιά, όσο και από αλγοριθμική (στο κομμάτι του ML). Ο σχεδιασμός του δικτύου είναι εξίσου σημαντικός με την επιλογή αλγορίθμων και των παραμέτρων τους, εφόσον βρισκόμαστε πλέον στην εποχή των Big Data, όπου ένα σωστά προετοιμασμένο dataset μπορεί να κάνει τη διαφορά στην επίδοση που τελικά θα πετύχουν οι αλγόριθμοι μάθησης που χρησιμοποιούνται.

Υπάρχουν επομένως προσθήκες και διαφοροποιήσεις στο δίκτυο που θα μπορούσαν να οδηγήσουν σε καλύτερα αποτελέσματα και όσον αφορά τις τελικές επιδόσεις των αλγορίθμων. Σημαντική διαφοροποίηση θα μπορούσαν να αποφέρουν διαφορετικές μέθοδοι ανάθεσης υποφερόντων στους χρήστες, καθώς και η εισαγωγή

επαχρησιμοποίησης συχνοτήτων στο σύστημα, που χρησιμοποιείται σε συστήματα στην πράξη και μεταβάλλει θεμελιωδώς την διαδικασία επιλογής συχνοτήτων αλλά και σταθμού βάσης.

Όσον αφορά τις τεχνικές Μηχανικής Μάθησης που χρησιμοποιήθηκαν, θα μπορούσαν να δοκιμαστούν και διαφορετικού τύπου νευρωνικά δίκτυα, όπως π.χ. τα αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Networks, RNNs) τα οποία έχουν γνωρίσει σημαντική ανάπτυξη ως προς το πλήθος των εφαρμογών που χρησιμοποιούνται τα τελευταία χρόνια, όπως και τα CNNs. Επίσης υπάρχει πλήθος διαφορετικών μεθόδων ταξινόμησης για την multi-label περίπτωση, όπου μπορεί να γίνει καλύτερη χρήση πιθανής συσχέτισης μεταξύ των διαφορετικών labels, καθώς και ενσωμάτωση αυτού του τύπου πληροφορίας στο στάδιο της εκπαίδευσης του δικτύου. [20][21][22]

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] D. Tse and Pramod Viswanath, *Fundamentals of wireless communication*. Cambridge Up: Cambridge, 2013.
- [2] H. Wu, T. Haustein, and P. A. Hoeher, “On the Information Rate of Single-Carrier FDMA Using Linear Frequency Domain Equalization and Its Application for 3GPP-LTE Uplink,” *EURASIP Journal on Wireless Communications and Networking*, vol. 2009, no. 1, Sep. 2009, doi: <https://doi.org/10.1155/2009/957159>.
- [3] Aicha Alami Hassani, M. Zouak, Mostafa Mrabti, and F. Abdi, “MAI statistics estimation and analysis in a DS-CDMA system,” *IOP conference series*, vol. 353, pp. 012026–012026, May 2018, doi: <https://doi.org/10.1088/1757-899x/353/1/012026>.
- [4] J. F. Kurose and K. W. Ross, *Computer networking : a top-down approach*, 8th ed. Hoboken: Pearson, 2021.
- [5] A. S. Tanenbaum, *Computer networks*. Boston: Pearson Education, 2011.
- [6] Amandeep Singh Bhatia and P. Kaushik, “A cluster based minimum battery cost AODV routing using multipath route for zigbee,” Jan. 2008, doi: <https://doi.org/10.1109/icon.2008.4772594>.
- [7] Houman Zarrinkoub, *Understanding LTE with MATLAB : from mathematical modeling to simulation prototyping*. Chichester, West Sussex, United Kingdom: Wiley, 2014.
- [8] Mo Ghorbanzadeh, A. Abdelhadi, and T. Charles Clancy, “A Utility Proportional Fairness Resource Allocation in Spectrally Radar-Coexistent Cellular Networks,” *arXiv (Cornell University)*, Oct. 2014, doi: <https://doi.org/10.1109/milcom.2014.247>.
- [9] A. Goldsmith, *Wireless communications*. Cambridge ; New York: Cambridge University Press, 2013.
- [10] Afif Osseiran, J. F. Monserrat, P. Marsch, Mischa Dohler, and Takehiro Nakamura, *5G Mobile and Wireless Communications Technology*. Cambridge Cambridge University Press, 2016.
- [11] J. Rodriguez, *Fundamentals of 5G mobile networks*. Chichester, West Sussex, United Kingdom: John Wiley & Sons Ltd, 2015.
- [12] C. A. Balanis, *Antenna theory analysis and design*. Hoboken, New Jersey Wiley, 2016.

- [13] D. Monett *et al.*, “Special Issue ‘On Defining Artificial Intelligence’— Commentaries and Author’s Response,” *Journal of Artificial General Intelligence*, vol. 11, no. 2, pp. 1–100, Feb. 2020, doi: <https://doi.org/10.2478/jagi-2020-0003>.
- [14] A. Turing, “Intelligent Machinery (1948),” *The Essential Turing*, Sep. 2004, doi: <https://doi.org/10.1093/oso/9780198250791.003.0016>.
- [15] Jojo Moolayil, *Learn Keras for Deep Neural Networks : A Fast-Track Approach to Modern Deep Learning with Python*. Berkeley, Ca Apress Apress, 2019.
- [16] A. Géron, *Hands-on machine learning with Scikit-Learn and TensorFlow concepts, tools, and techniques to build intelligent systems*, 2nd ed. O’Reilly Media, Inc., 2019.
- [17] Konstantinos Koutroumbas and S. Theodoridis, *Pattern Recognition*. Academic Press, 2008.
- [18] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*. John Wiley & Sons, 2012.
- [19] T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollar, “Focal loss for dense object detection,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp. 1–1, 2018, doi: <https://doi.org/10.1109/tpami.2018.2858826>.
- [20] A. C. P. L. F. de Carvalho and A. A. Freitas, “A Tutorial on Multi-label Classification Techniques,” *Studies in Computational Intelligence*, pp. 177–195, 2009, doi: https://doi.org/10.1007/978-3-642-01536-6_8.
- [21] F. Charte, A. Rivera, M. J. del Jesus, and F. Herrera, “A First Approach to Deal with Imbalance in Multi-label Datasets,” *Lecture Notes in Computer Science*, pp. 150–160, 2013, doi: https://doi.org/10.1007/978-3-642-40846-5_16.
- [22] A. N. Tarekegn, M. Ullah, and F. A. Cheikh, “Deep Learning for Multi-Label Learning: A Comprehensive Survey,” *arXiv.org*, Mar. 03, 2024. <https://arxiv.org/abs/2401.16549> (accessed May 14, 2024).
- [23] Κωνσταντίνου Φίλιππος, Κανάτας Αθανάσιος, Πάντος Γεώργιος, *Συστήματα Κινητών Επικοινωνιών*, 2η Έκδοση, Εκδόσεις Παπασωτηρίου, 2013
- [24] Παναγιώτης Γ. Κωττής, Παντελής-Δανιήλ Μ. Αράπογλου, *Ασύρματες Επικοινωνίες*, Εκδόσεις Τζιόλα, 2017.